

UNIVERZITET U BEOGRADU
ELEKTROTEHNIČKI FAKULTET

Nikola M. Tomašević

**SIMULACIJA KRATKOTRAJNOG FADINGA
MOBILNOG PROPAGACIONOG KANALA
ZASNOVANA NA VEŠTAČKIM NEURALNIM
MREŽAMA**

- Doktorska disertacija -

Beograd, 2013

UNIVERSITY OF BELGRADE
SCHOOL OF ELECTRICAL ENGINEERING

Nikola M. Tomašević

**ARTIFICIAL NEURAL NETWORK
BASED SIMULATION OF SHORT-TERM
FADING IN MOBILE PROPAGATION
CHANNEL**

- Doctoral dissertation -

Belgrade, 2013

KOMISIJA ZA PREGLED I ODBRANU

Mentor

Dr Aleksandar Nešković, vanredni profesor,
Univerzitet u Beogradu, Elektrotehnički fakultet

Članovi komisije

Dr Irini Reljin, redovni profesor,
Univerzitet u Beogradu, Elektrotehnički fakultet

Dr Budimir Đurađ, *Reader*,
University of Westminster, London

Dr Nataša Nešković, vanredni profesor,
Univerzitet u Beogradu, Elektrotehnički fakultet

Dr Željko Đurović, redovni profesor,
Univerzitet u Beogradu, Elektrotehnički fakultet

Univerzitet u Beogradu
- Elektrotehnički fakultet -



Datum odbrane

PREDGOVOR

Na osnovu rezultata istraživanja koji su izloženi u okviru doktorske disertacije publikovani su sledeći radovi:

- Tomasevic N. M., Neskovic A. M., Neskovic N. J., “Simulacija *short-term fading*-a pomoću veštačkih neuralnih mreža,” 15. Telekomunikacioni forum TELFOR 2007, Beograd, Srbija, pp. 749-752, 2007.
- Tomasevic N. M., Neskovic A. M., Neskovic N. J., “Short-term fading simulator based on artificial neural networks,” IEEE EUROCON 2009 Conference, St. Petersburg, Russia, pp. 1681-1688, 2009.
- Tomasevic N. M., Neskovic A. M., Neskovic N. J., “Short-term fading simulation using artificial neural networks,” AEU - International Journal of Electronics and Communications, vol. 65, no. 7, pp. 641-649, 2011.
- Tomasevic N. M., Neskovic A. M., Neskovic N. J., “Artificial neural network based approach to EEG signal simulation,” International Journal of Neural Systems (IJNS), vol. 22, no. 3, 1250008 (16 pages), 2012.
- Tomasevic N. M., Neskovic A. M., Neskovic N. J., “Artificial neural network based simulation of correlated short-term fading,” AEU - International Journal of Electronics and Communications, *in press*, 2013.

Eksperimentalni deo doktorske disertacije i odgovarajuća istraživanja su sprovedena na Elektrotehničkom fakultetu, Univerziteta u Beogradu, i u laboratoriji SIGMA Medizin-Technik GmbH, u Nemačkoj, u periodu 2008 - 2012.

Istraživački rad doktorske disertacije je delom finansiran od strane Ministarstva telekomunikacija i informatičkog društva Republike Srbije, u periodu 2008 - 2009, a delom u okviru projekata Ministarstva nauke i tehnološkog razvoja Republike Srbije, TR-13004 - “Adaptivna infrastruktura za kontekstno osetljive inteligentne sisteme” (*Adaptive Middleware for Intelligent, Context Aware Systems* - AMICA) i TR-32010 - “Softversko okruženje za inteligentno i adaptivno upravljanje kompleksnim objektima” (*Software Framework for Intelligent and Adaptive Management of Complex Facilities* - SOFIA) (rukovodilac projekata prof. dr Sanja Vraneš, Generalni direktor Instituta Mihajlo Pupin, u Beogradu), u periodu 2010 - 2012.

ZAHVALNICA

Najpre se zahvaljujem mentoru prof. dr Aleksandru Neškoviću na uloženom vremenu i trudu, koji me je strpljivo usmeravao u istraživačkom radu i profesionalnom razvoju. Bez njegovih korisnih sugestija i ideja, tokom mnogobrojnih razgovora i inspirativnih diskusija, istraživački rad na ovoj doktorskoj disertaciji ne bi bio tako plodonosno i prijatno iskustvo. Ujedno mu se zahvaljujem na uzoru koji mi je pružio tokom doktorskih studija. Bila je čast biti doktorant pod njegovim mentorstvom.

Takođe se zahvaljujem prof. dr Nataši Nešković koja me je vodila od studentskih dana, kroz izradu diplomskog rada, kao i kroz značajan deo istraživačkog rada u okviru doktorske disertacije. Najlepše joj se zahvaljujem na neizmernoj podršci i značajnim savetima. Zahvalan sam joj na istraživačkom duhu koji sam uz njenu nesebičnu pomoć izgradio prethodnih godina.

Najiskrenije se zahvaljujem prof. dr Sanji Vraneš na neizmernoj podršci i ukazanom poverenju, koja me je usmeravala na profesionalnom planu, kao deo tima *Fraunhofer - Pupin Joint Project Office*, u Institutu Mihajlo Pupin, od trenutka diplomiranja pa do danas. Zahvaljujem joj se na svim nesebičnim savetima, kako na profesionalnom tako i na privatnom planu. Ponosan sam što sam deo njenog istraživačkog tima.

Zahvaljujem se svim kolegama iz *Fraunhofer - Pupin Joint Project Office* tima (dr Mladenu Stanojeviću, dr Valentini Janev, Jeleni Jovanović-Vasović, Dejanu Paunoviću, Vuku Mijoviću, Marku Batiću i Urošu Miloševiću, kao i bivšim kolegama Jovanu Dudukoviću i Marku Ribariću), koji su doprineli mom profesionalnom vremenu provedenom u Institutu Mihajlo Pupin, na nesebičnoj podršci, kao i za divna prijateljstva koja smo sklopili.

Zahvaljujem se svim kolegama sa Katedre za Telekomunikacije i informacione tehnologije, na Elektrotehničkom fakultetu u Beogradu, a posebno doc. dr Mirjani Simić, mr Nenadu Krajnoviću i dipl. ing. Mladenu Koprivici, na podršci tokom praktičnih eksperimenata sprovedenih na Elektrotehničkom fakultetu.

Takođe sam zahvalan dr Johenu Švindu (*Jochen Schwind*), njegovom timu i laboratoriji SIGMA Medizin-Technik GmbH, u Nemačkoj, na značajnom doprinosu, organizaciji eksperimenata i EEG podacima koji su koiršćeni za verifikaciju istraživačkog rada u okviru ove doktorske disertacije.

Zahvaljujem se Ministarstvu telekomunikacija i informatičkog društva Republike Srbije, koje je u periodu 2008 - 2009 finansiralo moje dotorske studije. Ujedno se zahvaljujem

i Institutu Mihajlo Pupin koji je finansirao moj istraživački rad u periodu 2010-2012. Takođe sam zahvalan na finansiranju koje je omogućilo moj rad na doktorskoj disertaciji u okviru nacionalnih projekata Ministarstva nauke i tehnološkog razvoja Republike Srbije ("Adaptivna infrastruktura za kontekstno osetljive inteligentne sisteme" (AMICA) br. TR-13004 i "Softversko okruženje za inteligentno i adaptivno upravljanje kompleksnim objektima" (SOFIA) br. TR-32010, pod rukovodstvom prof. dr Sanje Vraneš), kao i u okviru brojnih međunarodnih EU projekata Sedmog okvirnog programa.

Najlepše se zahvaljujem svim članovima komisije na uloženom vremenu i značajnim savetima. Takođe, zahvaljujem se i svim anonimnim recenzentima mojih radova proisteklih iz doktorske disertacije u okviru časopisa *AEU - International Journal of Electronics and Communications*, *International Journal of Neural Systems* (IJNS) itd, na korisnim sugestijama i komentarima.

Zahvaljujem se svim bliskim osobama koji su mi pružili nesebičnu i prijateljsku podršku, najpre na privatnom, a potom i na profesionalnom planu, koja mi je jako značila tokom rada na doktorskoj disertaciji.

Posebno se zahvaljujem svojim roditeljima, Gordani i Miodragu, na pruženoj roditeljskoj ljubavi i neizmernoj podršci. Majci Gordani se najiskrenije zahvaljujem na nepresušnim emocijama, ohrabrivanju i podršci u svim mojim nastojanjima. Ocu Miodragu se zahvaljujem na svoj pruženoj pažnji, podsticajima i što je oduvek verovao u mene. Sećanje, njegove reči i saveti će me uvek pratiti. Najlepše im se zahvaljujem pošto su oni najzaslužniji za moje postignute rezultate i za sve što sam danas.

Beograd, 2013.

Mom ocu Miodragu i majci Gordani

REZIME

SIMULACIJA KRATKOTRAJNOG FEDINGA MOBILNOG PROPAGACIONOG KANALA ZASNOVANA NA VEŠTAČKIM NEURALNIM MREŽAMA

U tipičnim propagacionim uslovima savremenih bežičnih komunikacionih sistema do prijemnika dolazi veći broj reflektovanih replika izvornog signala. Superpozicijom dospelih replika signala, rezultujući signal na prijemu postaje slučajan u vremenu i prostoru, odnosno gubi svoje determinističke osobine, što se opisuje pojmom fedinga. Kao posledica stohastičkih fluktuacija signala na prijemu, rezultujući signal može pasti ispod praga prijema čime se narušava kvalitet veze. Ujedno, usled različitog kašnjenja dospelih replika signala i širenja emitovanog impulsa moguća je pojava disperzije koja potencijalno vodi do intersimbolske interferencije.

U cilju procene performansi bežičnih komunikacionih sistema, simulacija, kako pojedinačnih, tako i korelisanih feding procesa, je od interesa već dugi niz godina. Za potebe modelovanja radio kanala, obično se pretpostavlja da feding podleže "čistoj" Rejlijevoj statističkoj raspodeli, što često i nije slučaj u stvarnosti. U više-antenskim sistemima često se pretpostavljaju nekorelisane anvelope fedinga na prijemnim tačkama. Analiza koja je bazirana na ovakvim pretpostavkama ne daje realnu sliku o performansama komunikacionog sistema. Uprkos tome, postojeće simulacione tehnike su uglavnom optimizovane naspram teorijskih karakteristika feding procesa, dok merni podaci u konkretnim sistemima nisu uzimani u obzir.

Naučni doprinos doktorske disertacije ogleda se u razvoju nove simulacione metode pojedinačnih i korelisanih feding procesa sa željenim statističkim karakteristikama, veće tačnosti u poređenju sa postojećim relevantnim simulacionim metodama. Zapravo, predložena je nova metoda simulacije kratkotrajnog fedinga koji poseduje statističke i korelacione karakteristike feding procesa izdvojenog iz prijemnog signala u realnom komunikacionom sistemu. Imajući u vidu kompleksnost zadatka simulacije stohastičkih fluktuacija signala na prijemu, predložena metoda je zasnovana na principima veštačkih neuralnih mreža. Veštačke neuralne mreže su odabrane zbog njihove adaptibilne prirode i sposobnosti "učenja prema primeru". Suprotno postojećim simulacionim metodama, optimizacija predloženog feding simulatora vršena je isključivo nad mernim podacima. Tačnije, obučavanje neuralne mreže je sprovedeno nad podacima izmerenim u zadatom bežičnom komunikacionom sistemu. Osnovna ideja predložene metode je estimacija naredne feding vrednosti propagacijom međusobno korelisanih feding odbiraka, koji joj prethode, kroz neuralnu mrežu. U cilju navođenja simulatora i sprečavanja ulaska u stacionarno stanje, uveden je koncept vodećeg signala koji je stohastički pobuđivao neuralnu mrežu tokom simulacione procedure.

Da bi se verifikovale performanse simulatora, sprovedena je poredbeni analiza sa postojećim relevantnim simulacionim metodama čime su istaknute prednosti i mane svake metode ponaosob. Analizom relevantnih kvalitativnih i kvantitativnih parametara, zaključeno je da je predložena simulaciona metoda u boljem slaganju sa merenjima u poređenju sa postojećim metodama. Pošto je zasnovana isključivo na mernim podacima, fleksibilnost predložene metode se ogleda u mogućnosti simulacije fedinga procesa u, praktično, bilo kom odabranom mernom okruženju. Uprkos činjenici da je treniranje neuralne mreže računski zahtevan proces, predložena metoda je pokazala, nakon optimizacije težinskih koeficijenata mreže, zadovoljavajuće performanse i u pogledu zahteva u realnom vremenu.

Dodatno je ispitana mogućnost primene predložene metode u svrhu simuliranja drugih stohastičkih signala koji pokazuju tzv. kvazi-periodične karakteristike slične kratkotrajnom feding procesu. Kao jedan od kompleksnih stohastičkih procesa sa stanovišta statističke analize, elektroencefalogram, koji predstavlja meru električne aktivnosti ljudskog mozga, je uzet u cilju verifikacije performansi predložene simulacione metode i njene primene.

KLJUČNE REČI: Kratkotrajni feding, Rejljev feding, Veštačke neuralne mreže, Mobilni propagacioni kanal, *Diversity*, Simulacija stohastičkih procesa.

ABSTRACT

ARTIFICIAL NEURAL NETWORK BASED SIMULATION OF SHORT-TERM FADING IN MOBILE PROPAGATION CHANNEL

In a typical propagation environment of the contemporary wireless communication systems, a number of reflected source signal replicas are reaching the receiver. By superposition of the received signal replicas, the resulting signal at the reception becomes incidental in time and space, i.e. it loses its deterministic characteristics, which is described by the notion of fading. As a consequence of these stochastic signal fluctuations at the reception, the resulting signal may drop below the reception threshold which disturbs the connection quality. At the same time, due to the different delays of the received signal replicas and transmitted impulse spread, signal dispersion may occur which might lead to the intersymbol interference.

In order to assess the performance of the wireless communication systems, a simulation of single, as well as correlated fading processes, has been of the interest for many years already. For the purpose of radio channel modelling, it is usually assumed that fading underlies the “clean” Rayleigh statistical distribution, which is not often the case in reality. Uncorrelated fading envelopes at the reception points are often assumed in multiple-antenna systems. The analysis, based on such assumptions, does not give a real picture of the communication system performance. Despite this, the existing simulation techniques have been mainly optimized against the theoretical characteristics of the fading process, while the measurement data in real systems have not been taken into account.

The scientific contribution of this PhD dissertation is the development of a novel simulation method of both single and correlated fading processes having desired statistical characteristics, of greater precision as compared to the existing relevant simulation methods. In fact, a novel method was proposed for simulation of short-term fading characterized by statistical and correlation characteristics of the fading process extracted from the received signal in a real communication system. Having in mind the complexity of the task such as simulation of the stochastic signal fluctuations at the reception, the proposed method was based on the artificial neural network principles. Artificial neural networks have been chosen due to their adaptive nature and capability of “learning by an example”. Contrary to the existing simulation methods, the optimization of the proposed fading simulator was carried out only upon the measurement data. More precisely, training of the neural network was conducted based on the data measured in a given wireless communication system. The main idea of the proposed method was the estimation of the following fading value by processing

inter-correlated, preceding fading samples through the neural network. In order to navigate the simulator and avoid entering the stationary state, concept of driving signal was introduced which stochastically excited the neural network throughout the simulation procedure.

For the verification of the simulator performance, a comparative analysis against the existing relevant simulation methods was conducted based on which the advantages and disadvantages of each method were highlighted. By analyzing relevant qualitative and quantitative parameters, it was concluded that the proposed simulation method was in better agreement with measurements as compared to the existing methods. As it was based only upon the measurement data, the flexibility of the proposed method was reflected in its capability of simulating the fading process experienced in, practically, any chosen measurement environment. Despite the fact that training of the neural network was computationally demanding process, the proposed method showed, after the optimization of the network weight coefficients, a satisfying performance against the real time requirements as well.

Furthermore, a potential application of the proposed method for the simulation of other stochastic signals was investigated, which possess the so-called quasi-periodic characteristics similar to the short-term fading fluctuations. As one of the complex stochastic processes from the perspective of statistical analysis, the electroencephalogram, which represents the measure of electrical activity inside the human brain, was taken into account for the verification of the proposed method performance and its application.

KEYWORDS: Short-term fading, Rayleigh fading, Artificial neural networks, Mobile propagation channel, Diversity, Stochastic process simulation.

SADRŽAJ

1. UVOD	1
1.1. PREDMET I CILJ ISTRAŽIVANJA	2
1.2. METODOLOGIJA	2
1.3. STRUKTURA DOKTORSKE DISERTACIJE	3
2. PROPAGACIONE KARAKTERISTIKE RADIO KANALA.....	5
2.1. PROPAGACIONO SLABLJENJE I SLABLJENJE U SLOBODNOM PROSTORU	7
2.2. KANONIČKA PREDSTAVA BAND-PASS SIGNALA.....	8
2.3. FEDING	9
2.3.1. DUGOTRAJNI (LONG-TERM) FEDING	10
2.3.2. KRATKOTRAJNI (SHORT-TERM) FEDING.....	11
3. STATISTIČKI PARAMETRI FEDINGA	20
3.1. FUNKCIJA GUSTINE VEROVATNOĆE I KUMULATIVNA FUNKCIJA RASPODELE.....	21
3.1.1. TIPIČNE FUNKCIJE GUSTINE VEROVATNOĆE	22
3.1.2. TIPIČNE KUMULATIVNE FUNKCIJE RASPODELE.....	26
3.1.3. PROCENA PARAMETARA TIPIČNIH FUNKCIJA RASPODELE	27
3.2. UČESTANOST PROLASKA FEDINGA KROZ ODREĐENI NIVO I SREDNJE TRAJANJE FEDINGA	29
3.2.1. TEORIJSKA VREDNOST LCR PARAMETRA	30
3.2.2. TEORIJSKA VREDNOST ADF PARAMETRA.....	33
3.2.3. PROCENA LCR i ADF PARAMETARA	34
3.3. AUTOKORELACIONE KARAKTERISTIKE	35
3.3.1. AUTOKORELACIONA FUNKCIJA I KOEFICIJENT AUTOKORELACIJE	35
3.3.2. PROCENA AUTOKORELACIONE FUNKCIJE	40
4. OSNOVNE KARAKTERISTIKE VEŠTAČKIH NEURALNIH MREŽA	41
4.1. NEURONSKA JEDINICA.....	42
4.2. PRAVILA UČENJA.....	45
4.2.1. PERCEPTRON PRAVILO UČENJA	46
4.2.2. μ -LMS PRAVILO UČENJA	49
4.2.3. DELTA PRAVILO	51
4.3. VIŠESLOJNE NEURALNE MREŽE	53
4.3.1. PROPAGACIJA GREŠKE UNAZAD.....	55
4.3.2. KROS-VALIDACIONA PROCEDURA.....	58

5. SIMULACIJA KRATKOTRAJNOG FEDINGA	60
5.1. POSTOJEĆE METODE SIMULIRANJA REJLIJEVOG FEDINGA	61
5.1.1. METODA BAZIRANA NA SUMI SINUSOIDA.....	61
5.1.2. METODA BAZIRANA NA IDFT OPERACIJI	62
5.1.3. METODA BAZIRANA NA WGN FILTRIRANJU.....	63
5.2. PRIKUPLJANJE I OBRADA MERNIH PODATAKA	65
5.2.1. EKSTRAKCIJA ANVELOPE KRATKOTRAJNOG FEDINGA.....	67
5.2.2. KARAKTERISTIKE EKSTRAHOVANE ANVELOPE FEDINGA.....	68
5.3. OPŠTI MODEL ANN SIMULATORA	69
5.4. VODEĆI SIGNAL	70
5.4.1. EKSTRAKTOR VODEĆEG SIGNALA	71
5.4.2. GENERATOR VODEĆEG SIGNALA	72
5.4.3. VALIDACIJA VODEĆEG SIGNALA.....	75
5.5. OPTIMIZACIJA ANN SIMULATORA	76
5.5.1. ULAZI I IZLAZI NEURALNE MREŽE	76
5.5.2. UNUTRAŠNJA STRUKTURA NEURALNE MREŽE.....	76
5.5.3. TRENING I VALIDACIONI PROCES	78
5.6. POREĐENJE PERFORMANSI FEDING SIMULATORA	79
5.6.1. POREĐENJE PDF I CDF FUNKCIJA ANVELOPE FEDINGA	80
5.6.2. POREĐENJE LCR I ADF PARAMETARA ANVELOPE FEDINGA	82
5.6.3. POREĐENJE KORELACIONIH KARAKTERISTIKA	83
5.6.4. POREĐENJE MARGINE SNAGE	84
5.6.5. POREĐENJE WMSAE PARAMETRA.....	86
5.6.6. POREĐENJE U VREMENSKOM DOMENU	86
5.6.7. RAČUNSKA KOMPLEKSNOST.....	88
5.7. ZAKLJUČNI KOMENTARI	89
6. SIMULACIJA KORELISANIH KRATKOTRAJNIH FEDING PROCESA.....	93
6.1. METODA ZASNOVANA NA COLORING MATRICI	95
6.2. MERENJE I OBRADA PRIKUPLJENIH PODATAKA	96
6.2.1. EKSTRAKCIJA ANVELOPE FEDINGA	96
6.2.2. KORELACIONE OSOBINE EKSTRAHOVANOG FEDINGA	96
6.2.3. RAJSOV K-FAKTOR	97
6.3. PREDLOŽENA METODA SIMULACIJE KORELISANIH FEDING PROCESA.....	97
6.4. KONCEPT VODEĆEG SIGNALA U SIMULACIJI KORELISANIH FEDING PROCESA.....	99
6.4.1. EKSTRAKCIJA VODEĆEG SIGNALA.....	99
6.4.2. GENERATOR VODEĆEG SIGNALA	100
6.5. OPTIMIZACIJA ANN SIMULATORA KORELISANIH FEDING PROCESA	100
6.5.1. ARHITEKTURA NEURALNIH MREŽA	101
6.5.2. TRENING I VALIDACIJA NEURALNIH MREŽA.....	102
6.6. PERFORMANSE I EVALUACIJA SIMULATORA KORELISANIH FEDING PROCESA.....	102
6.6.1. POREĐENJE PDF I CDF FUNKCIJA ANVELOPE FEDINGA	103
6.6.2. POREĐENJE LCR i ADF PARAMETARA ANVELOPE FEDINGA.....	106
6.6.3. POREĐENJE KORELACIONIH KARAKTERISTIKA	109
6.6.4. POREĐENJE MARGINE SNAGE	115
6.6.5. POREĐENJE WMSAE PARAMETRA.....	115
6.6.6. POREĐENJE U VREMENSKOM DOMENU	116
6.6.7. RAČUNSKA KOMPLEKSNOST.....	117

6.7. ZAKLJUČNI KOMENTARI	118
7. SIMULACIJA DRUGIH STOHAISTIČKIH PROCESA	122
7.1. EEG SIMULACIJA ARMA FILTRIRANJEM.....	125
7.2. PRIKUPLJANJE EEG PODATAKA.....	126
7.2.1. EKSTRAKCIJA EEG POZADINSKE AKTIVNOSTI	127
7.2.2. KORELACIONE KARAKTERISTIKE SNIMLJENOG EEG PROCESA	128
7.3. ANN PRISTUP EEG SIMULACIJI	128
7.4. KONCEPT VODEĆEG SIGNALA U EEG SIMULACIJI	129
7.4.1. EKSTRAKCIJA VODEĆEG SIGNALA.....	130
7.4.2. GENERATOR VODEĆEG SIGNALA	130
7.5. OPTIMIZACIJA ANN SIMULATORA EEG PROCESA.....	131
7.5.1. ARHITEKTURA NEURALNE MREŽE	131
7.5.2. TRENING i VALIDACIJA NEURALNE MREŽE.....	132
7.6. PERFORMANSE I EVALUACIJA EEG SIMULATORA.....	133
7.6.1. POREĐENJE PDF I CDF PARAMETARA EEG PROCESA.....	133
7.6.2. POREĐENJE LCR I ADF PARAMETARA EEG PROCESA	135
7.6.3. POREĐENJE KORELACIONIH KARAKTERISTIKA	136
7.6.4. POREĐENJE MARGINE SNAGE	137
7.6.5. POREĐENJE WMSAE PARAMETRA	138
7.6.6. EEG SIGNAL U VREMENSKOM DOMENU	138
7.6.7. EEG SIGNAL U FREKVENCIJSKOM DOMENU	139
7.6.8. RAČUNSKA KOMPLEKSNOST.....	140
7.7. ZAKLJUČNI KOMENTARI	141
8. ZAKLJUČAK	144
REFERENCE	148

SKRAĆENICE

ACF - *Autocorrelation Function*

ADF - *Average Duration of Fades*

ADHD - *Attention Deficit Hyperactivity Disorder*

ANN - *Artificial Neural Network*

AR - *Autoregressive*

ARMA - *Autoregressive Moving Average*

CCF - *Cross-Correlation Function*

CDF - *Cumulative Distribution Function*

CW - *Carrier-Wave*

DC - *Direct Current*

DS - *Driving Signal*

EBP - *Error Back-Propagation*

EEG - *Electroencephalogram*

EIRP - *Effective Isotropic Radiated Power*

ERP - *Event Related Potential*

FPGA - *Field-Programmable Gate Array*

GA - *Genetic Algorithm*

IDFT - *Inverse Discrete Fourier Transform*

IIR - *Infinite-Impulse Response*

ISI - *Intersymbol Interference*

LCR - *Level-Crossing Rate*

LoS - *Line-of-Sight*

LTE-A - *Long Term Evolution - Advanced*

LTG - *Linear Threshold Gate*

MCDMA - *Multicarrier Code Division Multiple Access*

MFNN - *Multilayer Feedforward Neural Network*

MPA - *Markov Process Amplitude*

MQAM - *Multilevel Quadrature Amplitude Modulation*

MSE - *Mean Squared Error*

NLoS - *Nonline-of-Sight*

OFDMA - *Orthogonal Frequency-Division Multiple Access*

PDF - *Probability Density Function*

PSD - *Power Spectral Density*

PTG - *Polynomial Treshold Gate*

QTG - *Quadratic Treshold Gate*

RF - *Radio Frequency*

RMS - *Root Mean Square*

SoS - *Sum-of-Sinusoids*

SSE - *Sum of Squared Error*

TDNN - *Time-Delayed Neural Network*

WGN - *White Gaussian Noise*

WiMAX - *Worldwide Interoperability for Microwave Access*

WMSAE - *Weighted Mean-Square Autocorrelation Error*

WSE - *Weighted Sum of Errors*

WSS - *Wide-Sense Stationary*

LISTA SLIKA

Sl. 2.1. Propagaciono slabljenje.....	6
Sl. 2.2. Kriva propagacionog slabljenja u slučaju rastojanja primopredajnih antena od (a) nekoliko kilometara (<i>lognormal</i> feding) i (b) nekoliko metara (Rejlijev feding).	6
Sl. 2.3. Propagacija radio talasa u slobodnom prostoru.	7
Sl. 2.4. Dugotrajni feding.....	10
Sl. 2.5. Urbano okruženje mobilnog radio prijemnika [5].	12
Sl. 2.6. Disperzivne karakteristike radio kanala: (a) impuls na predaji i (b) širenje rezultujućeg impulsa na prijemu.	14
Sl. 2.7. Tipičan impulsni odziv radio kanala.	14
Sl. 2.8. Ilustracija Doplerovog pomeraja.	17
Sl. 2.9. Spektralna gustina snage signala sa izraženim Doplerovim efektom.....	18
Sl. 3.1. Eksperimentalno određivanje gustine raspodele <i>multipath</i> fedinga.	22
Sl. 3.2. Gausova normalna raspodela.	23
Sl. 3.3. Rejljeva raspodela.	24
Sl. 3.4. Gustina Rajsove raspodele za različite vrednosti parametra K	26
Sl. 3.5. Određivanje teorijskih LCR i ADF parametara feding procesa.	31
Sl. 3.6. Određivanje LCR i ADF parametara.	35
Sl. 3.7. Autokorelaciona funkcija Rejljevog fedinga.	39
Sl. 3.8. Određivanje ACF koeficijenta datog uzorka signala [5].	40
Sl. 4.1. Šematski dijagram (a) biološkog neurona i (b) veštačkog neurona [17].	42
Sl. 4.2. LTG jedinica: (a) šematski prikaz i (b) funkcija prenosa.	43
Sl. 4.3. Kaskadna realizacija PTG jedinice.	45
Sl. 4.4. Perceptron jedinica.	47
Sl. 4.5. Geometrijski prikaz perceptron pravila učenja.	49
Sl. 4.6. Adaptivna linearna jedinica.	50
Sl. 4.7. Neuron sa diferencijabilnom sigmoidalnom aktivacionom funkcijom f	51
Sl. 4.8. Hiperbolički tangens kao aktivaciona funkcija f i njen izvod f'	52
Sl. 4.9. Arhitektura dvoslojne potpuno povezane neuralne mreže.	54
Sl. 4.10. Primer progresije trening i validacione greške prilikom treniranja MFNN-a primenom EBP pravila.	59
Sl. 5.1. Merno okruženje (tlocrt Elektrotehničkog fakulteta u Beogradu).	66
Sl. 5.2. Signal na prijemu i dugotrajni feding (merna kampanja).	66
Sl. 5.3. Segment anvelope kratkotrajnog fedinga (merna kampanja).	67

Sl. 5.4. ACF anvelope kratkotrajnog fedinga.	69
Sl. 5.5. ANN feding simulator ($x(t_n)$ – n -ta vrednost fedinga, $d(t_n)$ – n -ta DS vrednost).	70
Sl. 5.6. Šematski prikaz DS ekstraktora ($x(t_n)$ – n -ta vrednost fedinga, $d(t_n)$ – n -ta DS vrednost).	71
Sl. 5.7. Ekstrakcija DS vrednosti.	72
Sl. 5.8. Šematski prikaz DS generatora ($d(t_n)$ – n -ta DS vrednost).	73
Sl. 5.9. Autokorelaciona funkcija DS-a.	73
Sl. 5.10. Segment DS <i>lookup</i> tabele u formi Markovljevog lanca.	75
Sl. 5.11. PDF trajanja (a) pozitivnog i (b) negativnog DS nivoa.	75
Sl. 5.12. Arhitektura implementirane neuralne mreže.	77
Sl. 5.13. Varijacija MSE vrednosti tokom ANN treniranja.	79
Sl. 5.14. Funkcija gustine verovatnoće anvelope fedinga.	81
Sl. 5.15. Kumulativna funkcija raspodele anvelope fedinga.	81
Sl. 5.16. Učestanost prolaska fedinga kroz određeni nivo.	82
Sl. 5.17. Srednje trajanje fedinga.	83
Sl. 5.18. Autokorelacija kvadrata anvelope fedinga.	85
Sl. 5.19. Anvelopa feding procesa u vremenu: (a) merenja, (b) ANN simulacija, (c) klasična Džekova metoda, (d) WSS-poboljšana Džekova metoda, (e) LP IIR filtriranje, (f) IDFT i (g) AR filtar.	87
Sl. 5.20. Vreme potrebno za generisanje jednog feding odbirka.	88
Sl. 5.21. Pregled PDF, CDF, LCR i ADF parametara (za periodu odabiranja od 100ms).	89
Sl. 6.1. ANN simulator korelisanih feding procesa ($x_p(t_i)$, $x_s(t_i)$ – i -ta vrednost primarnog, odnosno sekundarnog feding procesa, $d_p(t_i)$, $d_s(t_i)$ – i -ta primarna, odnosno sekundarna DS vrednost).	98
Sl. 6.2. PDF anvelope fedinga za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$	104
Sl. 6.3. CDF anvelope fedinga za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$	105
Sl. 6.4. LCR za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$	107
Sl. 6.5. ADF za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$	108
Sl. 6.6. ACF kvadrata anvelope fedinga za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$	111
Sl. 6.7. Kros-korelacione funkcije anvelope fedinga za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$	112
Sl. 6.8. Korelisani feding u vremenskom domenu za rastojanje antena $\lambda_c/8$	116
Sl. 6.9. Korelisani feding u vremenskom domenu za rastojanje antena $\lambda_c/4$	117
Sl. 6.10. Simulacija više korelisanih feding signala (r_i – generisana vrednost, R_i – auto-korelisane vrednosti i R_{ij} – kros-korelisane vrednosti feding signala i i j).	120
Sl. 7.1. Izgled EEG signala tokom različitih stanja ispitanika: (a) uzbuđenje, (b) opuštenost, (c) pospanost, (d) san i (e) duboki san [107].	123
Sl. 7.2. Lokacija EEG elektroda (internacionalni 10-20 sistem) [131].	127
Sl. 7.3. Funkcija gustine verovatnoće EEG procesa.	134
Sl. 7.4. Kumulativna funkcija raspodele EEG procesa.	134
Sl. 7.5. LCR parametar EEG procesa.	135
Sl. 7.6. ADF parametar EEG procesa.	136
Sl. 7.7. Autokorelacija kvadrata EEG signala.	137
Sl. 7.8. EEG signal u vremenskom domenu: (a) merenja, (b) ANN metoda i (c) metoda ARMA filtriranja.	139
Sl. 7.9. Jednostrani spektar izmerenog EEG signala i odgovarajuće anvelope spektra dobijenog ANN metodom i ARMA filtriranjem.	140

LISTA TABELA

Tab. 2.1. Tipične vrednosti širine odziva Δ za različite tipove područja.....	15
Tab. 5.1. Segment DS <i>lookup</i> tabele.....	74
Tab. 5.2. DS statistički parametri.....	76
Tab. 5.3. MSE proračunatih PDF, CDF, LCR i ADF parametara.	80
Tab. 5.4. Broj korelisanih odbiraka fedinga.	84
Tab. 5.5. Margine snage i WMSAE.....	86
Tab. 5.6. Pregled najboljih poredbenih rezultata analiziranih metoda simulacije fedinga.	91
Tab. 5.7. Poređenje analiziranih simulacionih metoda.	92
Tab. 6.1. MSE proračunatih PDF, CDF, LCR i ADF parametara.	109
Tab. 6.2. MSE auto-korelacionih funkcija kvadrata anvelope fedinga, margine snage i WMSAE.	113
Tab. 6.3. Srednji broj auto-korelisanih odbiraka fedinga.	114
Tab. 6.4. MSE vrednosti CCF-a anvelope fedinga, broj kros-korelisanih odbiraka fedinga i kros-korelacioni koeficijent.	115
Tab. 6.5. Pregled najboljih poredbenih rezultata analiziranih simulacionih metoda (za rastojanje prijemnih antena $\lambda_c/8$ i $\lambda_c/4$).	121
Tab. 7.1. Težinski faktori W_i fitnes funkcije (F_i - frekvencija i S_i – amplitude simulirane spektralne komponente).....	126
Tab. 7.2. MSE vrednosti PDF, CDF, LCR, ADF parametara i ACF-a kvadrata EEG signala.	137
Tab. 7.3. Margina snage i WMSAE.....	138
Tab. 7.4. Totalna energija i WSE.....	140
Tab. 7.5. Pregled najboljih poredbenih rezultata analiziranih simulacionih metoda.....	143

1. UVOD

Rezime. U okviru uvodne glave opisani su predmet i cilj istraživanja doktorske disertacije. Izložena je analiza primenjene metodologije na kojoj je zasovan istraživački rad. Strukta doktorske disertacije je detaljno opisana na kraju glave.

Savremeno društvo bilo bi gotovo nezamislivo bez postojanja radio sistema. Mobilna telefonija, radio i TV difuzija predstavljaju sastavni deo svakodnevnog života savremenog čoveka. Radio-navigacioni sistemi omogućavaju neometano funkcionisanje morskog i avio saobraćaja, obezbeđujući neophodne podatke o položaju brodova i letelica. Meteorološka služba, satelitski sistemi i astronomska ispitivanja čine samo deo liste mogućih primena radio sistema. Najveći broj današnjih radio sistema pripada grupi mobilnih sistema što podrazumeva da radio predajnik i/ili prijemnik poseduju mogućnost kretanja, bez obzira da li se oni stvarno kreću ili ne. Pri tome, od posebnog interesa su zemaljski radio sistemi kod kojih su i predajnik i prijemnik u neposrednoj blizini tla. Pod pojmom radio kanala u kontekstu mobilnih komunikacionih sistema, podrazumeva se medijum koji se koristi za prenos u zemaljskim mobilnim radio sistemima. Zapravo, njega čine niži slojevi atmosfere, u blizini Zemljine površine. Ovaj medijum je po svojim karakteristikama jedinstven i kompleksan. U tipičnim propagacionim uslovima, bez obzira da li između predajne i prijemne antene postoji direktna optička vidljivost ili ne, do prijemnika, po pravilu, dolazi veći broj reflektovanih replika izvornog signala. Usled njihove superpozicije, signal na prijemu gubi svoje determinističke osobine i postaje slučajan u prostoru i vremenu, što se opisuje pojmom fedinga. S obzirom na činjenicu da za opisivanje fedinga [1] nije moguće koristiti deterministički pristup, analiza se, po pravilu, oslanja na veliki broj merenja i odgovarajuću statističku obradu.

Nestabilnost nivoa signala na prijemu, odnosno stohastička priroda signala, može uzrokovati pad nivoa signala ispod praga prijema, što dovodi do narušavanja kvaliteta veze. Takođe, zbog slučajnog kašnjenja reflektovanih signala dolazi do širenja emitovanog impulsa, odnosno do tzv. disperzije koja potencijalno vodi do intersimbolske interferencije [2] (pp. 195-197). Sa druge strane, različite tehnike prenosa signala, kao što su na primer, *diversity* i MQAM (*Multilevel Quadrature Amplitude Modulation*) sistemi sa više nosioca [2] (pp. 148-149), podležu uticaju korelisanih feding procesa. Stoga su feding simulatori od velike važnosti za procenu performansi bežičnih komunikacionih sistema. Simulacija, kako pojedinačnih, tako i korelisanih feding procesa, je od teorijskog i praktičnog interesa već dugi

niz godina. Zbog simulacije radio kanala obično se pretpostavlja da feding podleže “čisto” Rejlijevoj (*Rayleigh*) statističkoj raspodeli [3] (p. 64), što često i nije slučaj u praksi. Takođe, prilikom analize performansi savremenih komunikacionih sistema, kod kojih su primenjene *diversity* i OFDMA (*Orthogonal Frequency Division Multiplex Access*) metode [2] (pp. 386-388), često se podrazumevaju nekorelisane anvelope fedinga na prijemu. Ovakav pristup za posledicu može imati da sprovedena analiza ne daje realnu sliku performansi komunikacionog sistema. U literaturi su do danas predložene različite tehnike simuliranja feding procesa. Predložene tehnike su uglavnom razvijene i testirane uzimajući u obzir isključivo teorijske karakteristike feding procesa. Merenja u konkretnim sistemima nisu uzimana u obzir.

1.1. PREDMET I CILJ ISTRAŽIVANJA

Kao rezultat složenih zakonitosti propagacije radio talasa i promena propagacionih uslova u vremenu, intenzitet električnog polja na mestu prijema varira. Ove promene je praktično nemoguće predvideti samo na osnovu fizičkih zakona propagacije, ali je moguće proceniti verovatnoću pojavljivanja određenog nivoa polja na prijemu na osnovu velikog broja merenja i odgovarajuće statističke obrade mernih rezultata. Predmet istraživanja doktorske disertacije je simuliranje pojedinačnih i korelisanih feding procesa, odnosno stohastičkih fluktuacija signala na prijemu, pomoću veštačkih neuralnih mreža (*Artificial Neural Network* - ANN) [4]. Zadatak je bio odrediti model simulatora, pogodnu arhitekturu neuralne mreže, optimalne vrednosti parametara simulacije, kao i odgovarajući skup ulaznih podataka.

U okviru doktorske disertacije je predložena nova metoda simulacije kratkotrajnog fedinga sa statističkim i korelacionim karakteristikama feding procesa izdvojenog iz prijemnog signala u realnom komunikacionom sistemu. Suprotno postojećim simulacionim metodama koje su razvijene oslanjajući se na teorijske karakteristike feding procesa, osnovna ideja predložene metode je optimizacija feding simulatora nad mernim podacima dobijenim u realnom bežičnom komunikacionom sistemu.

1.2. METODOLOGIJA

Zbog njihove adaptibilne prirode i sposobnosti “učenja prema primeru”, predložena metoda simulacije kratkotrajnog fedinga zasnovana je na principima veštačkih neuralnih mreža. Zapravo, vrednosti nivoa električnog polja, izmerene u realnom bežičnom komunikacionom sistemu, korišćene su radi ANN treniranja. Osnovna ideja metode je da se na osnovu sukcesivnih odbiraka feding signala, propuštenih kroz neuralnu mrežu, vrši predikcija naredne feding vrednosti. Da bi se izbegao ulazak vrednosti generisanih na izlazu neuralne mreže u stacionarno stanje, predložen je koncept “vodećeg signala” (*Driving Signal* - DS). Drugim rečima, implementiran je generator vodećeg signala koji ukazuje na smer u kom neuralna mreža treba da generiše sledeću feding vrednost. Na taj način je sprovedeno navođenje ANN-a tokom procesa simulacije. Generator vodećeg signala je zasnovan na statističkim karakteristikama izmerenog feding signala i generatoru slučajnih brojeva. Celokupni eksperiment, odnosno implementacija simulatora, sproveden je u četiri koraka. U prvom koraku, vršena su merenja nivoa električnog polja na mestu pokretne prijemne antene.

Drugi korak se sastojao od određivanja odgovarajuće vrste i arhitekture ANN-a i procene optimalnih parametara simulacije, kao što je veličina trening skupa i broj elemenata ulaznog vektora neuralne mreže. Zatim, u trećem koraku, sprovedeni su trening i validacioni postupci u cilju optimizacije i uvida u generalizacione sposobnosti ANN-a. U poslednjem koraku, sprovedena je simulacija, kao i verifikacija dobijenih rezultata.

Da bi se verifikovale performanse simulatora, sprovedena je odgovarajuća statistička analiza, odnosno, utvrđeno je u kojoj meri dobijeni rezultati odgovaraju podacima izmerenim u realnom komunikacionom sistemu. Performanse predložene metode su poređene i u odnosu na postojeće simulacione metode, čime su istaknute prednosti i mane svake metode ponaosob. U cilju utvrđivanja koliko simulirani procesi odstupaju od izmerenih, analiziran je veći broj kvalitativnih i kvantitativnih parametara koji opisuju stohastičke fluktuacije signala na prijemu. Takođe, radi poređenja sa teorijskim karakteristikama modela radio kanala, izmerene i simulirane feding vrednosti su analizirane i u odnosu na teorijske rezultate. Na taj način je ispitana mogućnost primene predložene simulacione metode.

1.3. STRUKTURA DOKTORSKE DISERTACIJE

Plan i metodologija sprovedenog istraživanja sastoje se od teorijskog i praktičnog dela koji su izloženi u okviru doktorske disertacije. Nastavak doktorske disertacije je organizovan po sledećim glavama. Glava 2 razmatra osnovne propagacione karakteristike radio kanala. Najpre je definisan pojam radio kanala. Zatim su uvedeni pojmovi propagacionog slabljenja i fedinga kao ograničavajućih faktora pri korišćenju mobilnih radio sistema. Potom su dati matematički izrazi koji definišu model radio kanala i objašnjeni su pojmovi *multipath* fedinga i Doplerovog (*Doppler*) efekta.

U okviru Glave 3 doktorske disertacije analizirani su karakteristični parametri feding signala. Najpre su definisane osnovne statističke raspodele koje se koriste pri karakterizaciji fenomena fedinga, kao što su Gausova (*Gauss*), Rejljeva i Rajsova (*Rice*) raspodela. Zatim su analizirani parametri koji opisuju intenzitet fedinga poput učestanosti prolaska fedinga kroz određeni nivo (*Level-Crossing Rate* - LCR) i srednjeg trajanja fedinga (*Average Duration of Fades* - ADF). Potom su opisane i autokorelacione karakteristike fedinga. Teorijske vrednosti parametara, kao i metode za procenu vrednosti karakterističnih parametara iz datog uzorka, su takođe razmatrane.

Glava 4 uvodi pojam veštačkih neuralnih mreža u cilju upoznavanja osnovnih karakteristika, strukture, kao i oblasti aplikacija u kojima neuralne mreže zauzimaju značajno mesto. Tačnije, analizirane su računске sposobnosti osnovne neuronske jedinice. Zatim su definisane kategorije učenja mreža, od kojih je “nadgledano” učenje detaljnije analizirano. Takođe, opisan je način funkcionisanja višeslojnih mreža, kao i jedno od najznačajnijih pravila učenja, algoritam propagacije greške unazad (*Error Back-Propagation* – EBP). Zarad analize generalizacionih sposobnosti ANN-a, uveden je i pojam kros-validacione (*cross-validation*) procedure.

U Glavi 5 doktorske disertacije analizirana je problematika simuliranja pojedinačnog feding procesa. Zapravo, predložena je nova metoda simuliranja kratkotrajnog fedinga, koja se zasniva na principima veštačkih neuralnih mreža. Da bi se formirao adekvatni skup trening podataka, sprovedena su merenja jačine prijemnog električnog polja u *indoor* okruženju, u

nonline-of-sight (NLoS) scenariju. Kao ocena kvaliteta predložene metode, sprovedeno je poređenje sa postojećim simulacionim metodama Rejljevog fedinga. Sadržaj Glave 5 je organizovan tako što su, najpre, pobrojane i opisane postojeće metode simuliranja Rejljevog fedinga u literaturi. Zatim je razmatrana merna procedura i obrada mernih podataka, kao i ekstrakcija kratkotrajnog fedinga iz snimljenog uzorka. Potom je detaljno analizirana predložena metoda i opisan opšti model feding simulatora, koji se bazira na neuralnim mrežama. Tačnije, predstavljena je struktura predloženog simulatora, kao i njegove glavne komponente. Da bi se izbegao ulazak ANN-a u stacionarno stanje, uveden je koncept vodećeg signala. Nakon opisa procesa optimizacije i validacije predloženog modela nad mernim podacima, predstavljena je komparativna analiza rezultata i performansi kako predložene, tako i postojećih metoda.

U okviru Glave 6 predložena je nova metoda za simulaciju korelisanih feding procesa, tačnije dve korelisane anvelope kratkotrajnog fedinga. Predložena metoda je, takođe, zasnovana na principima veštačkih neuralnih mreža. Osnovna ideja je da se optimizacija simulatora vrši isključivo nad mernim rezultatima. Stoga je merenje jačine električnog polja sprovedeno u *indoor* okruženju, u NLoS scenariju. Radi verifikacije predložene metode, izvršeno je poređenje performansi u odnosu na jednu od aktuelnih metoda koja se bazira na *coloring* matrici. Struktura Glave 5 započinje, najpre, analizom postojeće metode simulacije korelisanih feding signala u literaturi. Nakon opisa procedure prikupljanja i obrade mernih podataka, detaljno je opisan predloženi model simulatora korelisnog fedinga koji se bazira na veštačkim neuralnim mrežama. Zatim je opisan koncept vodećeg signala za slučaj simulacije korelisanih feding signala. Potom su analizirane glavne komponente simulatora, struktura korišćenih neuralnih mreža, kao i način na koji su mreže optimizovane nad mernim podacima. Radi uvida u performanse, kako predložene tako i postojeće metode, razmatrani su komparativni rezultati sprovedenih simulacija.

U Glavi 7 doktorske disertacije analiziran je primer primene predložene metode za simulaciju drugih stohastičkih signala koji pokazuju tzv. kvazi-periodične karakteristike slične procesu kratkotrajnog fedinga, kao što je to slučaj sa ljudskim moždanim talasima (*Electroencephalogram* - EEG). Zapravo, razmatrana je mogućnost primene predložene metode u cilju simulacije spontane ljudske pozadinske EEG aktivnosti na osnovu eksperimentalno prikupljenih EEG podataka. Da bi se formirao adekvatan skup trening podataka, izvršeno je merenje EEG signala zdrave odrasle osobe. U cilju demonstracije performansi predloženog pristupa, sprovedeno je poređenje u odnosu na postojeću metodu koja se bazira na *autoregressive moving average* (ARMA) filtriranju. Struktura Glave 7 je organizovana tako što je, najpre, dat opis postojeće simulacione metode EEG signala koja se zasniva na filtriranju Gausovog šuma. Potom su opisana merenja sprovedena na ljudskom subjektu i obrada snimljenih EEG vrednosti. Nakon uopštenog pregleda predloženog pristupa EEG simulaciji, uveden je koncept DS-a optimizovan za slučaj EEG simulacije. Zatim je detaljno analizirana arhitektura ANN-a, kao i optimizaciona procedura simulatora nad mernim podacima. U cilju verifikacije predloženog simulacionog pristupa, sprovedeno je poređenje performansi postojećeg i predloženog simulatora.


Zaključna razmatranja i konačna analiza istraživanja sprovedenog u okviru doktorske disertacije izloženi su u završnoj Glavi 8.

2. PROPAGACIONE KARAKTERISTIKE RADIO KANALA

Rezime. U ovoj glavi analizirane su osnovne propagacione karakteristike radio kanala u bežičnim komunikacionim sistemima. Najpre je definisan pojam radio kanala. Zatim su uvedeni pojmovi propagacionog slabljenja i slabljenja u slobodnom prostoru. Potom su dati matematički izrazi koji opisuju model radio kanala. Definisani su pojmovi krakotrajnog i dugotrajnog feding procesa. Zatim je opisan efekat multipath fedinga kao ograničavajućeg faktora u mobilnim radio sistemima. Disperzivne karakteristike kanala sa fedingom i Doplerov efekat su analizirani na kraju glave.

Radio talas značajno slabi prilikom propagacije kroz atmosferu. Drugim rečima, prilikom propagacije radio talasa od predajne do prijemne antene, na rastojanju od nekoliko kilometara, može se primetiti stalno opadanje transmitovane snage (kao što je prikazano na Sl. 2.1). Spomenuto slabljenje radio talasa se naziva propagaciono slabljenje. U idealnom slučaju, ako na putanji između primopredajnih antena nema prepreka, propagaciono slabljenje će približno odgovarati slabljenju u slobodnom prostoru [2] (pp. 31-33). Međutim, u opštem slučaju, snaga radio talasa na prijemu opada značajnije, o čemu će više reči biti u narednim poglavljima.


Propagacione karakteristike radio kanala nisu jedinstveno određene propagacionim slabljenjem. Najčešće, u tipičnim urbanim i suburbanim područjima, između predajne i prijemne antene ne postoji direktna optička vidljivost (*Line-of-Sight* - LoS). Signal stiže do prijemnika složenim propagacionim mehanizmima, odnosno putem refleksije, refrakcije, difrakcije i rasejanja [1]. Refleksija nastaje kada elektromagnetski talas naiđe na prepreku čije su dimenzije znatno veće od talasne dužine posmatranog talasa. U zavisnosti od ugla pod kojim talas nailazi na prepreku i elektromagnetskih osobina same prepreke, elektromagnetski talas trpi slabljenje i promenu faze. Refrakcija je promena smera kretanja elektromagnetskog talasa usled nailaska na graničnu površinu prepreke. Difrakcija predstavlja pojavu prividnog skretanja elektromagnetskog talasa iza prepreke čije su dimenzije srazmerne talasnoj dužini talasa koji na nju nailazi. Rasejanje je proces koji se javlja kada se elektromagnetski talas prostire kroz sredinu koja sadrži veliki broj objekata, dimenzija manjih od talasne dužine. Na ovakvim preprekama talas se rasejava u svim pravcima.



Sl. 2.1. Propagaciono slabljenje.

Dakle, propagacioni mehanizam kojim talas nalazi put do prijemne antene je uslovljen odnosom između njegove talasne dužine i dimenzija prepreke. U suburbanim područjima, zgrade i drugi objekti u proseku su široki 18-30m, odnosno 12-30m visoki. U urbanim područjima dimenzije objekata mogu biti i znatno veće. Na osnovu ovih podataka može se zaključiti da su zgrade, bilo u suburbanim ili urbanim područjima, prirodno reflektujuće površine za većinu frekvencija koje se koriste u savremenim telekomunikacionim sistemima [5] (pp. 1-5).


Iz navedenih razloga, do prijemnika dospeva veliki broj reflektovanih komponenti i, u slučaju direktne optičke vidljivosti sa predajnikom, jedna direktna komponenta koja je relativno jaka u odnosu na reflektovane komponente. Snaga transmitovanog talasa varira sa vremenom i rastojanjem na slučajan način oko srednje, tj. medijanske vrednosti, što se može videti na osnovu izgleda krivih propagacionog slabljenja prikazanih na Sl. 2.2(a) i Sl. 2.2(b), za slučajeve rastojanja između primopredajnih antena od par kilometara i nekoliko metara, respektivno. Karakteristika propagacionog slabljenja da signal na prijemu gubi svoje determinističke osobine i postaje slučajan u prostoru i vremenu, opisuje se pojmom fedinga. Drugim rečima, feding je proces koji opisuje fluktuacije signala na prijemu.



Sl. 2.2. Kriva propagacionog slabljenja u slučaju rastojanja primopredajnih antena od (a) nekoliko kilometara (*lognormal* feding) i (b) nekoliko metara (*Rejljev* feding).

2.1. PROPAGACIONO SLABLJENJE I SLABLJENJE U SLOBODNOM PROSTORU

Na Sl. 2.3 je prikazan pojednostavljeni slučaj propagacije radio talasa u slobodnom prostoru kada postoji LoS između predajnika i prijemnika.



Sl. 2.3. Propagacija radio talasa u slobodnom prostoru.

Ukoliko na primopredajnoj putanji ne postoje značajne prepreke, snaga predata prijemnoj anteni se može izraziti kao:

$$P_r(d) = \frac{P_t G_t G_r \lambda^2}{(4\pi)^2 d^2 L}, \quad d > 0, \quad (2.1)$$

gde su P_t snaga predajnika, G_r i G_t dobici prijemne i predajne antene, λ radna talasna dužina, d rastojanje između predajnika i prijemnika. L predstavlja dodatna slabljenja nevezana za slabljenje na putanji propagacije, kao što su slabljenja *branching* mreža (tj. kola koja povezuju primopredajnike na zajedničku antenu), slabljenja filtara, konektora i slično. Proizvod $P_t G_t$ naziva se efektivna izotropno izračena snaga (*Effective Isotropic Radiated Power* - EIRP).

Slabljenje u slobodnom prostoru dato je sa:

$$L_{free} = \frac{\lambda^2}{(4\pi d)^2}, \quad (2.2)$$

odnosno, izraženo u decibelima:

$$L_{free} [dB] = -20 \log_{10} \left(\frac{\lambda}{4\pi d} \right) = -20 \log_{10} \left(\frac{c/f}{4\pi d} \right). \quad (2.3)$$

Iz navedenih relacija može se zaključiti da je, u idealnom slučaju, propagaciono slabljenje funkcija radne učestanosti i rastojanja između predajne i prijemne antene. Takođe, slabljenje u slobodnom prostoru je obrnuto srazmerno kvadratu rastojanja. Međutim, prilikom propagacije između primopredajnih antena radio signal biva reflektovan, rasejan, difraktovan

i apsorbovan s obzirom na to da prelazi preko terena na kom se nalaze zgrade, vegetacija i razne prirodne prepreke. Navedeni fizički fenomeni dodatno slabe transmitovani signal, što nije uzeto u obzir modelom propagacije u slobodnom prostoru. Stoga, u realnim situacijama, snaga na prijemu ne opada sa kvadratom rastojanja, već sa većim stepenom ν , prema sledećem izrazu:

$$P_r \sim d^{-\nu}, \quad (2.4)$$

gde ν ima vrednost 2 u slobodnom prostoru. U sredinama u kojima ne postoje nesmetani uslovi propagacije kao u slučaju slobodnog prostora, vrednost parametra ν je veća, kao npr. u urbanim sredinama gde može imati i vrednost 4. U slučaju kada ne postoji LoS između predajnika i prijemnika i kada se njihovo rastojanje može smatrati značajnijim, snaga predata prijemnoj anteni se može izraziti kao:

$$P_r = 10 \log_{10} \left[P_r(d_{ref}) \right] + 10\nu \log_{10} \left[\frac{d_{ref}}{d} \right], \quad (2.5)$$

gde je d_{ref} referentna udaljenost koja se bira tako da ima vrednost manju od tipičnih rastojanja u bežičnim sistemima, ali u dalekoj zoni predajne antene, tako da gubici na rastojanjima većim od odabrane vrednosti zavise samo od rastojanja d . Najčešće, referentna udaljenost uzima vrednosti u opsegu 100 – 1000m.

Kao što je prethodno razmatrano, pored radne frekvencije i rastojanja primopredajnih antena, različiti faktori dodatno utiču na izgled krive propagacionog slabljenja, kao što su visina i konfiguracija antena itd. Navedeni faktori dodatno otežavaju određivanje stohastičke prirode nivoa polja na prijemu.

2.2. KANONIČKA PREDSTAVA BAND-PASS SIGNALA

Band-pass signal predstavlja signal čiji se spektar nalazi u opsegu oko određene centralne učestanosti $\pm f_c$. Signali koji se koriste u mobilnim radio-sistemima nastaju modulacijom signala nosioca, učestanosti f_c , korisnim signalom [6] (pp. 52-58). Rezultujući signal upravo predstavlja *band-pass* signal.

Ako pretpostavimo da je *band-pass* signal u vremenu $r(t)$, i njegova Hilbertova transformacija $\hat{r}(t)$ [6] (pp. 47-51), onda je pre-anvelopa ovog signala data po definiciji izrazom:

$$r_+(t) = r(t) + j\hat{r}(t). \quad (2.6)$$

Kompleksna anvelopa $\tilde{r}(t)$ signala $r(t)$ predstavlja frekvencijski pomerenu verziju njegove pre-anvelope $\hat{r}(t)$, i data je sa:

$$\tilde{r}(t) = r_+(t) \exp(-j2\pi f_c t), \quad (2.7)$$

gde je f_c učestanost nosioca *band-pass* signala $r(t)$. Po definiciji, signal $r(t)$ je realni deo pre-anvelope $r_+(t)$. Stoga, uzimajući u obzir jednačine (2.6) i (2.7)), *band-pass* signal u vremenu $r(t)$ može se izraziti preko kompleksne anvelope $\tilde{r}(t)$ na sledeći način:

$$r(t) = \text{Re}[\tilde{r}(t) \exp(j2\pi f_c t)]. \quad (2.8)$$

Anvelopa $a(t)$ signala $r(t)$ jednaka je modulu kompleksne anvelope $\tilde{r}(t)$, odnosno pre-anvelope $r_+(t)$:

$$a(t) = |\tilde{r}(t)| = |r_+(t)|. \quad (2.9)$$

Iz navedenih definicija može se zaključiti da pre-anvelopa $r_+(t)$ *band-pass* signala $r(t)$ predstavlja kompleksni *band-pass* signal, čija vrednost zavisi od učestanosti nosioca f_c . Sa druge strane, anvelopa $a(t)$ je uvek realni signal u osnovnom opsegu (*low-pass*), dok je kompleksna anvelopa kompleksni signal u osnovnom opsegu. Kompleksnu anvelopu, kao kompleksnu veličinu, možemo izraziti na dva načina:

$$\tilde{r}(t) = r_I(t) + jr_Q(t) = a(t) \exp[j\phi(t)], \quad (2.10)$$

gde je $r_I(t)$ komponenta u fazi signala $r(t)$, $r_Q(t)$ komponenta u kvadraturi, $a(t)$ anvelopa, a $\phi(t)$ faza signala. Komponente u fazi i kvadraturi su realni signali u osnovnom opsegu (*low-pass*) za koje važi:

$$r_I(t) = a(t) \cos(\phi(t)), \quad r_Q(t) = a(t) \sin(\phi(t)). \quad (2.11)$$

Na osnovu jednačine (2.8) originalni signal $r(t)$ može se izraziti pomoću navedenih komponenti na sledeći način:

$$r(t) = r_I(t) \cos(2\pi f_c t) - r_Q(t) \sin(2\pi f_c t), \quad (2.12)$$

ili

$$r(t) = a(t) \cos(2\pi f_c t + \phi(t)). \quad (2.13)$$

Poslednja relacija predstavlja hibridnu formu amplitudske i ugaone modulacije.

2.3. FEDING

Kao što je ranije spomenuto, složeno okruženje između predajne i prijemne antene u kom se obavlja komunikacija, nije moguće opisati samo na osnovu zakonitosti propagacionog slabljenja u slobodnom prostoru koje signal trpi pre nego što dospe do prijemnika. Kao posledica složenih zakonitosti propagacije radio-talasa u blizini Zemljine površine i promene uslova prostiranja u vremenu intenzitet električnog polja na mestu prijema varira. Ove promene je praktično nemoguće predvideti samo na osnovu fizičkih zakona propagacije, već

je jedino moguće, na osnovu velikog broja merenja i odgovarajuće statističke obrade, govoriti o verovatnoći pojavljivanja određenog nivoa prijemnog polja.

Posledica fedinga je slučajna anvelopa signala, odnosno slučajna promena intenziteta električnog polja na prijemu. Intenzitet električnog polja predstavlja apsolutnu meru jačine električnog polja u odnosu na $1\mu\text{V/m}$, ili 1mV/m , i izražava se u $\text{dB}\mu$, tj. dBm . Signal na prijemu moguće je predstaviti kao funkciju vremena $r(t)$, ili kao funkciju prostorne koordinate s , $r(s)$. Signal $r(t)$, odnosno $r(s)$, predstavlja stvarni nivo prijemnog polja, izražen u $\text{dB}\mu$ (dBm). Ovaj signal moguće je razdvojiti na dve komponente, tačnije na dugotrajni feding (*long-term fading*), $l(t)$, i kratkotrajni feding (*short-term fading*), $x(t)$, na sledeći način [5] (pp. 7-16):


$$r(t) = l(t)x(t), \quad (2.14)$$

ili

$$r(s) = l(s)x(s). \quad (2.15)$$

2.3.1. DUGOTRAJNI (LONG-TERM) FEDING

Dugotrajni feding $l(s)$, odnosno $l(t)$, zapravo je usrednjeni signal, što je i prikazano na Sl. 2.4. Naziva se i lokalna srednja vrednost (*local-mean*), s obzirom da svaka vrednost dugotrajnog fedinga odgovara srednjoj vrednosti polja u okolini posmatrane tačke. U literaturi se koristi i termin *shadowing* [5].



Sl. 2.4. Dugotrajni feding.

Procenjena lokalna srednja vrednost $\bar{l}(s_1)$ u tački s_1 duž prostorne koordinate s , može se izraziti kao:

$$\bar{l}(s_1) = \frac{1}{W} \int_{s_1 - W/2}^{s_1 + W/2} r(s) ds = \frac{1}{W} \int_{s_1 - W/2}^{s_1 + W/2} l(s)x(s) ds, \quad (2.16)$$

gde W označava dužinu prozora u kom se vrši usrednjavanje vrednosti prijemnog polja.

Ako se pretpostavi da je stvarna srednja vrednost $l(s_1)$ u okolini s_1 :

$$l(s = s_1) = \bar{l}(s = s_1), \quad (2.17)$$

gornja relacija postaje:

$$\bar{l}(s_1) = l(s_1) \cdot \frac{1}{W} \int_{s_1 - W/2}^{s_1 + W/2} x(s) ds. \quad (2.18)$$

Da bi pretpostavka važila, vrednost W se mora odabrati tako da važi:

$$\frac{1}{W} \int_{s_1 - W/2}^{s_1 + W/2} x(s) ds \rightarrow 1. \quad (2.19)$$


O izboru vrednosti W biće više reči u Sekciji 5.2.1.

Dugotrajni feding je prouzrokovao konfiguracijom terena na trasi između primopredajnih antena. Konfiguracija terena može biti ravničarska, brdovita, planinska ili mešovita, a u zavisnosti od načina naseljavanja, područja mogu biti ruralna, suburbana ili urbana. Konfiguracija terena utiče na slabljenje i fluktuaciju, dok tip naseobina utiče na slabljenje dugotrajnog fedinga. Tip naseobina, takođe, uzrokuje kratkotrajni feding, odnosno kratkotrajne fluktuacije prijemnog polja, što je tema narednih poglavlja. Zbog statističkih osobina, promene dugotrajnog fedinga prouzrokovane konfiguracijom terena na trasi mogu se opisati log-normalnom raspodelom. Konfiguracija terena, zapravo, utiče na vrednost standardne devijacije log-normalne krive koja opisuje raspodelu lokalne srednje vrednosti u toj oblasti.

2.3.2. KRATKOTRAJNI (SHORT-TERM) FEDING

Kratkotrajni feding $x(t)$, odnosno $x(s)$, je posledica efekata koji nastaju praktično u svim tipovima područja u kojima je mobilna prijemna stanica okružena zgradama znatno većim od prosečne visine na kojoj se nalazi prijemna antena. Pošto u ovakvim okruženjima najčešće ne postoji LoS između primopredajnih antena, radio talas dospeva do prijemne antene putem refleksije od površine objekata koji je okružuju, i difrakcije preko i/ili oko njih, što je ilustrovano na Sl. 2.5. U ovom slučaju transmitovani signal dospeva do prijemne antene preko više različitih putanja. Fenomen da radio talasi stižu do odredišta iz različitih pravaca i sa različitim vremenskim kašnjenjima, čineći da se rezultujući signal na prijemu menja na slučajan način, naziva se *multipath* feding. Slučaj kada do prijemnika dospeva veliki broj reflektovanih talasa i jedan direktan talas opisuje se Rajsovim statističkim modelom propagacionog kanala. S druge strane, ukoliko direktna komponenta ne postoji, koristi se Rejljev model, kao poseban slučaj Rajsovog modela. Analizirajući spomenute prosečne dimenzije objekata, neophodno je da je radna učestanost transmitovanog signala iznad 30MHz da bi se pojavio *multipath* efekat.

Neophodno je napomenuti da je kratkotrajni feding prouzrokovao *multipath* refleksijom transmitovanog talasa od lokalnih reflektora kao što su kuće, zgrade i drugi objekti. *Multipath* feding najčešće nije posledica postojanja prirodnih prepreka (kao što su planine ili brda) između predajne i prijemne antene.



Sl. 2.5. Urbano okruženje mobilnog radio prijemnika [5].

MULTIPATH FEDING

Zarad lakšeg opisa kako komponente signala dospele iz različitih pravaca do prijemnika utiču na nivo signala na prijemu, polazi se od sledećih pretpostavki: prijemna stanica je nepokretna, komponente signala dolaze do prijemnika nezavisno jedna od druge i ne postoji LoS između primopredajnih antena. Pod navedenim uslovima, signal koji detektuje prijemna antena može se prikazati kao algebarski vektorski zbir reflektovanih komponenti.

Dakle, rezultujući signal na prijemu može se napisati kao suma zakasnelih komponenti:

$$r(t) = \sum_{i=1}^N a_i p(t - t_i), \quad (2.20)$$

gde je a_i amplituda i -te reflektovane komponente, $p(t)$ je forma transmitovanog impulsa, a t_i vremensko kašnjenje i -te komponente. N je broj putanja putem kojih signal dospeva do prijemne antene. Prethodni izraz (2.20) može se napisati u sledećem obliku:

$$r(t) = \sum_{i=1}^N a_i \cos(2\pi f_c t + \phi_i), \quad (2.21)$$

gde je f_c učestanost nocioca, a ϕ_i faza i -te reflektovane komponente. Prethodna jednačina (2.21) može se transformisati tako da se signal predstavi pomoću komponente u fazi i kvadraturi:

$$r(t) = \cos(2\pi f_c t) \sum_{i=1}^N a_i \cos(\phi_i) - \sin(2\pi f_c t) \sum_{i=1}^N a_i \sin(\phi_i). \quad (2.22)$$

Ako su lokacije objekata koji predstavljaju mesta refleksije radio talasa slučajne, realna pretpostavka je da će faze ϕ_i imati uniformnu raspodelu u opsegu $(0, 2\pi)$. Uz ovaj uslov, za veliko N , signal na ulazu u prijemnik može se dalje napisati u obliku:

$$r(t) = X \cos(2\pi f_c t) - Y \sin(2\pi f_c t), \quad (2.23)$$

gde su,

$$X = \sum_{i=1}^N a_i \cos(\phi_i), \quad Y = \sum_{i=1}^N a_i \sin(\phi_i). \quad (2.24)$$

Prema centralnoj graničnoj teoremi (*central limit theorem*) [7] (pp. 164-165) o zbiru slučajnih promenljivih, X i Y su dve nezavisne slučajne promenljive sa Gausovom raspodelom i identičnom vrednošću parametara. U ovom slučaju, anvelopa signala na prijemu, koja predstavlja rezultat procesa demodulacije na izlazu iz prijemnika, data sa $\sqrt{X^2 + Y^2}$, biće slučajna promenljiva sa Rejljevom raspodelom.

Prethodno razmatranje se odnosi na slučaj kada ne postoji direktna komponenta što predstavlja najgori scenario sa stanovišta prijema. Ukoliko postoji LoS između primopredajnih antena, na ulazu u prijemnik javlja se jaka deterministička komponenta, pa se signal na ulazu u prijemnik može predstaviti sa:

$$r(t) = A \cos(2\pi f_c t + \theta) + \sum_{i=1}^N a_i \cos(2\pi f_c t + \phi_i), \quad (2.25)$$


gde su A amplituda i θ faza direktne komponente. Na isti način kao u prethodnom razmatranju, može se pokazati da je anvelopa signala na prijemu, data sa $\sqrt{(X + A \cos \theta)^2 + (Y + A \sin \theta)^2}$, slučajna promenljiva sa Rajsovom raspodelom.

Iz navedenog se može zaključiti da je primljeni signal slučajan i u odsustvu aditivnog belog Gausovog šuma (*White Gaussian Noise* - WGN) koji unose elektronski sklopovi. To je posledica postojanja *multipath* komponenti i slučajne raspodele faze rezultujućeg signala. *Multipath* feding može prouzrokovati da rezultujući signal padne ispod praga prijema. Da bi

se to sprečilo, prilikom proračuna budžeta snage, uvodi se margina fedinga, kao zahtev za neophodni prag prijema, da bi se minimizovala mogućnost prekida komunikacije.


DISPERZIVNE KARAKTERISTIKE KANALA SA FEDINGOM

Slučajna vrednost anvelope signala nije jedina posledica fedinga. *Multipath* feding, takođe, ima uticaja i na oblik impulsa koji se prenosi kroz radio kanal. Zbog postojanja slučajnog kašnjenja reflektovanih komponenti, impulsi dospevaju u prijemnik u različitim vremenskim trenucima. Na ovaj način dolazi do širenja impulsa koji se prenosi, što se može videti na Sl. 2.6. Širenje impulsa, takozvana disperzija, dovodi do moguće pojave intersimbolske interferencije (*Intersymbol Interference* - ISI) [5] (pp. 38-41).



Sl. 2.6. Disperzivne karakteristike radio kanala: (a) impuls na predaji i (b) širenje rezultujućeg impulsa na prijemu.

Disperzivne osobine kanala mogu se kvalitativno opisati na sledeći način. Neka je transmitovani impuls Dirakov (*Dirac*) delta-impuls, $p(t) = a\delta(t)$. Impulsi koji odgovaraju *multipath* putanjama dospevaju u prijemnik u različitim vremenskim trenucima i sa različitom snagom u zavisnosti od prirode refleksije, difrakcije i/ili rasejanja odgovornim za njihovo postojanje. Zapravo, impulсни odziv kanala se određuje na osnovu vremena dolaska i snage kojom impulsi dospeju do prijemne tačke. Tipičan izgled impulsnog odziva kanala $r(t)$ prikazan je na Sl. 2.7. Impulsi koji dospevaju do prijemnika su naznačeni proizvodom odgovarajućeg koeficijenta a_i i Dirakovog impulsa $\delta(t)$.



Sl. 2.7. Tipičan impulсни odziv radio kanala.

Širina odziva Δ (sa Sl. 2.7) može se interpretirati kao razlika između vremena dolaska prve i poslednje *multipath* komponente (iznad definisanog praga). Srednje vreme kašnjenja (*mean delay*) [2], [8] (pp. 42-43) je definisano sa:

$$T_d = \frac{\int_0^\infty tr(t) dt}{\int_0^\infty r(t) dt}, \quad (2.26)$$

odnosno, tzv. RMS (*Root Mean Square*) širine odziva,

$$T_{rms} = \sqrt{\frac{\int_0^\infty t^2 r(t) dt}{\int_0^\infty r(t) dt} - T_d^2}. \quad (2.27)$$

Ako je $\Delta = 0$, neće biti širenja impulsa, odnosno ukoliko Δ ima veliku vrednost, očekuje se znatno proširenje impulsa na prijemu. U ruralnim sredinama impulsi pristižu u gotovo isto vreme, pa je širina odziva mala, dok je u urbanim sredinama ovaj parametar znatno veći. U Tab. 2.1 date su tipične vrednosti parametra Δ za različite tipove područja.

Tab. 2.1. Tipične vrednosti širine odziva Δ za različite tipove područja.

Tip područja	Širina odziva (Δ)
Unutrašnji (<i>indoor</i>)	$<0.1 \mu s$
Spoljašnji (<i>open area</i>)	$<0.2 \mu s$
Suburbani	$0.5 \mu s$
Urbani	$3 \mu s$

Za potrebe određivanja koliko *multipath* feding kanal utiče na širenje impulsa moguće je modelovati kanal filtrom propusnikom niskih učestanosti čiji je propusni opseg obrnuto srazmeran širini odziva. Aproximativno, propusni opseg kanala B_c dat je sa:

$$B_c = \frac{1}{5\Delta}. \quad (2.28)$$

Potrebno je napomenuti da, propusni opseg kanala definisan na ovaj način predstavlja samo pomoćno sredstvo za opisivanje frekvencijski zavisnih svojstava kanala, a ne njegov stvarni propusni opseg.

Ukoliko je propusni opseg kanala B_c veći od korisnog opsega poruke koja se prenosi B_s , sve frekvencijske komponente poruke dospevaju u prijemnik sa vrlo malo izobličenja, tako da će ISI biti zanemarljiva. U ovom slučaju kanal je okarakterisan kao *flat fading* kanal (tzv. kanal sa ravnim fedingom). Takvi kanali imaju male vrednosti parametra Δ , kao što je to slučaj sa ruralnim sredinama. Sa druge strane, ako je B_c znatno manje od B_s , različite frekvencijske komponente signala podleći će disperziji, a kao rezultat doći će do ISI i širenja impulsa. Ovakvi kanali nazivaju se frekvencijsko-selektivni kanali (*frequency-selective*

channels). To su kanali sa širokim impulsnim odzivom. Bitno je obratiti pažnju da je razlika između *flat* i frekvencijsko-selektivnih kanala zasnovana na relativnom odnosu korisnog opsega informacije koja se prenosi i parametra širine odziva. To znači da *flat* kanal može postati frekvencijsko-selektivan ako se poveća protok prenošene informacije.

Za potrebe analize, može se pretpostaviti da vremena kašnjenja pojedinih komponenti podležu eksponencijalnoj raspodeli:

$$p(T_i) = \frac{1}{\Delta} \exp\left(-\frac{T_i}{\Delta}\right), \quad T_i > 0, \quad (2.29)$$


gde je T_i vremensko kašnjenje i -te komponente. Ovaj model pretpostavlja N reflektovanih komponenti istih amplituda, pri čemu najviše njih dolazi do prijema sa manjim kašnjenjima, dok su njihovi dolasci sve ređi kako vreme prolazi, što je posledica eksponencijalne raspodele.

Na osnovu prethodnih razmatranja, može se zaključiti da su slučajna anvelopa i frekvencijska selektivnost kanala nezavisne manifestacije *multipath* fenomena i da mogu postojati samostalno ili u kombinaciji.

DISPERZIJA U VREMENU I DOPLEROV EFEKAT

Dosadašnja analiza se odnosila na slučaj kada se mobilna prijemna stanica ne kreće. Kao što je već opisano, anvelopa signala na prijemu je slučajna veličina. Bitno je imati u vidu da je feding, tj. slučajna promena anvelope signala, suštinski, prostorni fenomen koji se manifestuje u vremenskom domenu kada se prijemnik kreće. Tačnije, usled kretanja prijemnika, svaka od *multipath* komponenti prelazi različit put do prijemne antene što uzrokuje promenu faze određene komponente. Faza svake od komponenti se menja sa promenom mesta prijemnika, različito doprinoseći rezultujućem signalu na različitim mestima. Anvelopa rezultujućeg signala na prijemu menjaće se sada na slučajan način sa rastojanjem i ove promene preslikavaće se u vremenski domen.

Kretanje prijemnika rezultira promenom frekvencije signala na prijemu. Ovaj fenomen je poznat kao Doplerov efekat. Da bi se izračunala vrednost Doplerovog pomeraja u frekvenciji, posmatra se situacija kao na slici 2.8.



Sl. 2.8. Ilustracija Doplerovog pomeraja.

Prijemnik se kreće duž linije AA' konstantnom brzinom V (kao što je prikazano na Sl. 2.8). Pretpostavljeno je da signal na prijemu potiče od talasa reflektovanog od objekta S. Neka je Δt vreme potrebno da prijemnik pređe put d od tačke A do tačke A'. Razlika u putu potrebna talasu da stigne od tačke S do tačke A', u odnosu na put koji talas prelazi od tačke S do tačke A, može se izraziti kao:

$$\Delta l = d \cdot \cos \alpha = V \cdot \Delta t \cdot \cos \alpha, \quad (2.30)$$

gde je α ugao između upadnog talasa i pravca kretanja prijemnika. Fazna razlika prijemnog signala u tačkama A i A' je:

$$\Delta \varphi = -\frac{2\pi}{\lambda_c} \Delta l = -\frac{2\pi V \Delta t}{\lambda_c} \cos \alpha, \quad (2.31)$$

odnosno, odgovarajuća promena u frekvenciji, tj. Doplerov pomeraj,

$$f_q = -\frac{1}{2\pi} \frac{\Delta \varphi}{\Delta t} = \frac{V}{\lambda_c} \cos \alpha. \quad (2.32)$$

Frekvencija na prijemu sada postaje:

$$f_{in} = f_c + f_q. \quad (2.33)$$

Maksimalni Doplerov pomeraj u frekvenciji, f_m , na osnovu relacije (2.32), je:

$$f_m = \frac{V}{\lambda_c} = f_c \frac{V}{c}, \quad (2.34)$$

gde je c brzina prostiranja svetlosti u vakuumu.

Promena faze, kao što se vidi iz navedenih relacija, je funkcija vremena, za razliku od slučaja nepokretnog prijemnika. Rezultujući signal na ulazu u prijemnik se, konačno, može napisati na osnovu jednačine (2.33) kao:


$$r(t) = \cos(2\pi f_c t) \sum_{i=1}^N a_i \cos(2\pi f_m \cos(\alpha_i) t + \phi_i) - \sin(2\pi f_c t) \sum_{i=1}^N a_i \sin(2\pi f_m \cos(\alpha_i) t + \phi_i) \quad (2.35)$$

gde je N broj reflektovanih komponenti i ϕ_i odgovarajuće faze, pod pretpostavkom da ne postoji direktna komponenta. Upoređujući ovu relaciju sa slučajem kada se prijemnik ne kreće, odnosno jednačinom (2.22), može se primetiti da su u ovom slučaju X i Y funkcije vremena, što kao posledicu ima vremensku zavisnost anvelope. Ako se uvede pretpostavka da je N dovoljno veliko, kao i u slučaju nepokretnog prijemnika, može se pokazati da anvelopa prijemnog signala podleže Rejlijevoj raspodeli.

Takođe, moguće je izračunati spektralnu gustinu snage signala na prijemu. Iz jednačine (2.35) može se primetiti da je učestanost nosioca promenjena za pomeraj f_q , koji može biti pozitivan ili negativan u zavisnosti od ugla α . Kada se prijemnik kreće ulicom, taj ugao može imati vrednost između 0 i π , tako da su ekstremne vrednosti Doplerovog pomeraja $\pm f_m$. Ako pretpostavimo da ϕ_i ima uniformnu raspodelu u intervalu $(0, 2\pi)$, spektralna gustina snage (*Power Spectral Density* - PSD) $S_d(f)$ [9], [10] (pp. 52-58) signala $r(t)$, je:

$$S_d(f) = \frac{\Omega_p}{2\pi f_m \sqrt{1 - \left(\frac{f}{f_m}\right)^2}}, \quad |f| \leq f_m, \quad (2.36)$$

gde je Ω_p srednja snaga anvelope. Grafik spektralne gustine snage je prikazan na Sl. 2.9. Sa slike se može primetiti da je najveći deo energije koncentrisan oko maksimalnog Doplerovog pomeraja f_m . Treba napomenuti da stvarni spektar snage, takođe, zavisi od dijagrama zračenja antene i korišćene polarizacije.



Sl. 2.9. Spektralna gustina snage signala sa izraženim Doplerovim efektom.

Ako se posmatra prenos kratkog impulsa dok je prijemnik u pokretu, kretanje prijemnika prouzrokuje promene u kanalu sa frekvencijom f_m . Ako je trajanje impulsa jako kratko, promene usled kretanja biće spore, pa neće imati uticaj na prenos, a samim tim ni na prijem impulsa. Drugim rečima, ako je opseg signala, izražen kao recipročna vrednost trajanja impulsa, mnogo veći od f_m , promene u kanalu biće "spore", i u tom slučaju radi se o tzv. kanalu sa sporim fedingom (*slow-fading channel*). U suprotnom, ako je trajanje impulsa dugačko, promene će biti "brze" i uticaće na prijem. Znači, pri prenosu signala malog protoka, kretanje prijemnika izazvaće pojavu brzog fedinga (*fast-fading channel*) ukoliko je opseg signala manji od maksimalnog Doplerovog pomeraja. Vreme koherencije (*coherence time*) T_c , je parametar koji služi za ocenu da li je feding spor ili brz. Srazmeran je recipročnoj vrednosti maksimalnog Doplerovog pomeraja [8] (eq. (6)):

$$T_c \approx \frac{9}{16\pi f_m} . \quad (2.37)$$

Ako je trajanje impulsa manje od vremena koherencije, radi se o sporom fedingu, tj. ako je trajanje veće od T_c , radi se o kanalu sa brzim fedingom. Zbog toga se smatra da je brzi feding vezan za pojavu vremenske disperzije u kanalu kao posledica relativnog kretanja prijemnika u odnosu na predajnik.

Dakle, feding se može javiti u frekvencijskom ili u vremenskom domenu. Kanal pokazuje frekvencijsko-disperzivne osobine usled *multipath* fenomena. U isto vreme, kada se prijemnik kreće dolazi do disperzije u vremenu. Za male informacione protoke, trajanje impulsa je veliko, pa je kanal istovremeno sa sporim fedingom i *flat*. U slučaju većeg protoka informacija i malih brzina kretanja, kanal je sa sporim fedingom, ali je frekvencijski selektivan. Pri velikim protocima i velikim brzinama javlja se i brzi feding i osobina frekvencijske selektivnosti kanala. Ovakvi kanali zahtevaju dodatne korekcione mere kako bi se rešio problem izobličenja nastalih u prenosu.

3. STATISTIČKI PARAMETRI FEDINGA

Rezime. *Karaktersitični parametri feding procesa su detaljno analizirani u okviru ove glave. Najpre su opisane relevantne statističke raspodele koje se koriste pri karakterizaciji fenomena fedinga (kao što su Gausova, Rejljeva i Rajsova raspodela). Sledi analiza parametara koji opisuju intenzitet feding signala (poput učestanosti prolaska fedinga kroz određeni nivo i srednjeg trajanja fedinga). Autokorelacione karakteristike feding signala su takođe opisane u ovoj glavi. Pored teorijskih vrednosti, razmatrane su i metode za procenu vrednosti karakterističnih parametara iz datog uzorka.*

Kao posledica uslova propagacije pri prostiranju elektromagnetnog talasa u blizini Zemljine površine, prijemni signal se menja na slučajan način sa vremenom. Zapravo, signal na prijemu predstavlja slučajan proces. Zbog toga nije moguće egzaktno opisati vremenske promene signala na prijemu, već se može govoriti samo o verovatnoći pojave određenog nivoa signala, dobijene na osnovu velikog broja merenja i odgovarajućom statističkom obradom.

Familija krivih $x(t)$ koje predstavljaju snimljene realizacije slučajnog procesa, kao npr. kratkotrajnog fedinga, pod istim uslovima čini statistički ansambl. On je opisan funkcijom gustine raspodele trenutnih vrednosti amplituda po ansamblu $p(x)$, odnosno raspodelom verovatnoće da će u zadatom trenutku bilo koji od članova ansambla imati određenu vrednost amplitude. Za slučajan proces kaže se da je stacionaran ukoliko raspodela verovatnoće ne zavisi od izbora trenutka posmatranja. Za stacionaran proces se smatra da se mere srednjih tendencija tog procesa (srednja vrednost, srednja kvadratna vrednost i varijansa) ne menjaju sa vremenom. Ako su srednje vrednosti po ansamblu jednake srednjim vrednostima u vremenu, za takav slučajan proces kaže se da je ergodičan i važi:

$$E[x(t)] = \langle x(t) \rangle, \quad (3.1)$$

$$E[x^2(t)] = \langle x^2(t) \rangle, \quad (3.2)$$

$$E[x^n(t)] = \langle x^n(t) \rangle, \quad (3.3)$$

gde su sa leve strane jednakosti date srednje tendencije računane po ansamblu, a sa desne strane odgovarajuće mere srednjih tendencija procesa u vremenskom domenu izračunate kao:

$$E[x(t)] = \int_{-\infty}^{+\infty} xp(x) dx, \text{ i} \quad (3.4)$$

$$\langle x(t) \rangle = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t) dt. \quad (3.5)$$

U mobilnim radio komunikacijama feding signal se može smatrati ergodičnim slučajnim procesom, pa se procena srednje vrednosti može vršiti na osnovu određenog broja, N , snimljenih odbiraka signala na prijemu x_i kao:

$$\bar{x} = \frac{\sum_{i=1}^N x_i}{N}, \quad (3.6)$$

gde je N dovoljno veliko da se može smatrati $\bar{x} = \langle x(t) \rangle$.

U okviru ove glave dati su najvažniji statistički parametri koji se koriste za opisivanje karakteristika fedinga.


3.1. FUNKCIJA GUSTINE VEROVATNOĆE I KUMULATIVNA FUNKCIJA RASPODELE

Funkcija gustine verovatnoće ili funkcija gustine raspodele (*Probability Density Function* - PDF) $p(x)$, opisuje ponašanje slučajne promenljive. Drugim rečima, to je zapravo funkcija koja predstavlja relativnu verovatnoću da slučajna promenljiva x uzme određenu vrednost. Na Sl. 3.1 je prikazan tipičan izgled *multipath* fedinga. Na osnovu N ekperimentalno dobijenih odbiraka signala moguće je izvršiti procenu njegove funkcije gustine raspodele tako što se najpre vrši podela vertikalne skale (koja je izražena u dB) na određeni broj podintervala, jednake veličine (npr. 1dB po intervalu). Zatim se vrši prebrojavanje odbiraka u svakom od intervala, čime se dobija histogram koji predstavlja broj odbiraka u određenom intervalu. Dobijeni broj odbiraka u svakom intervalu deli se sa ukupnim brojem odbiraka, N , što, zapravo, predstavlja verovatnoću da će se odbirak naći u datom intervalu. Konačna vrednost funkcije gustine raspodele na sredini odgovarajućeg intervala se dobija deljenjem dobijene verovatnoće sa širinom intervala.

Kumulativna funkcija raspodele (*Cumulative Distribution Function* - CDF), $F(x)$, je verovatnoća da je slučajna promenljiva x manja ili jednaka zadatoj vrednosti X . Ako je $p(x)$ funkcija gustine verovatnoće slučajne promenljive x , tada je verovatnoća da će se slučajna promenljiva naći u intervalu $x+dx$ data sa $p(x)dx$. Na osnovu toga kumulativna funkcija raspodele može se izraziti preko gustine raspodele kao:

$$F(x) = P(x \leq X) = \int_c^x p(z) dz, \quad (3.7)$$

gde je c najmanja vrednost za koju je $p(x)$ definisano. Kao i kod funkcije gustine raspodele, moguće je direktno proceniti vrednost $F(x)$ na osnovu eksperimentalno dobijenog uzorka. To se postiže tako što se prebroji koliko odbiraka se nalazi ispod neke zadate vrednosti. Vrednost $F(x)$ u toj tački se dobija deljenjem dobijenog broja odbiraka sa ukupnim brojem odbiraka. Takođe, moguće je, za zadatu vrednost, sabrati eksperimentalno određene vrednosti gustine raspodele ispod te vrednosti.



Sl. 3.1. Eksperimentalno određivanje gustine raspodele *multipath* fedinga.

3.1.1. TIPIČNE FUNKCIJE GUSTINE VEROVATNOĆE

U nastavku su opisane najčešće korišćene teorijske funkcije gustine verovatnoće za opisivanje fenomena fedinga [2].

PDF GAUSOVE (NORMALNE) RASPODELE


Funkcija gustine Gausove raspodele po definiciji je data kao:

$$p(x) = \frac{1}{2\pi\sigma} \exp\left(-\frac{(x-m)^2}{2\sigma^2}\right), \text{ za svako } x. \quad (3.8)$$

Srednja vrednost ove raspodele je označena sa m , a standardna devijacija sa σ .

Često se za opis električnog polja na prijemu, kada su vrednosti prijemnog polja izražene u decibelima (dBμ, tj. dBm), koristi normalna (Gausova) raspodela. Normalna raspodela koristi se za opisivanje osobina dugotrajnog fedinga. Kao uzorci se posmatraju, ne trenutne vrednosti, već usrednjene vrednosti intenziteta prijemnog polja. Usrednjavanje intenziteta prijemnog polja se vrši u kraćim vremenskim intervalima, odnosno u malim zonama u prostoru (u mikrolokacijama). Vrednosti dobijene usrednjavanjem zajedno predstavljaju skup okarakterisan normalnom raspodelom u slučaju srednjeg nivoa polja (izražen u dB), odnosno *log-normalnom* raspodelom u slučaju srednjeg intenziteta polja (izražen u μV/m). Ovo podrazumeva da su u jednačini (3.8) srednja vrednost m i standardna devijacija σ , takođe, izražene u dB.

Na Sl. 3.2 je prikazana kriva gustine normalne raspodele za različite vrednosti m i σ . Može se primetiti da je normalna raspodela uvek simetrična u odnosu na srednju vrednost.



Sl. 3.2. Gausova normalna raspodela.

PDF REJLIJEVE RASPODELE

Definicija funkcije gustine Rejljeve raspodele je:

$$p(x) = \frac{x}{b^2} \exp\left(-\frac{x^2}{2b^2}\right), x \geq 0. \quad (3.9)$$

Srednja vrednost Rejljeve raspodele je data kao:

$$E[X] = b\sqrt{\frac{\pi}{2}}, \quad (3.10)$$

odnosno standardna devijacija:

$$\sigma = b\sqrt{2 - \frac{\pi}{2}}. \quad (3.11)$$

Parametar b predstavlja standardnu devijaciju slučajnih promenljivih X i Y sa normalnom raspodelom, a čijom transformacijom nastaje slučajna promenljiva sa Rejljevom raspodelom, o čemu je bilo reči u prethodnoj Sekciji 2.3.2.


Srednja kvadratna vrednost ove raspodele može se izraziti kao:

$$E[X^2] = 2b^2. \quad (3.12)$$

Relacija (3.12) se često koristi za procenu parametra b Rejljeve raspodele na osnovu eksperimentalno dobijenog uzorka.

Rejljeva raspodela se javlja kad se posmatraju varijacije prijemnog polja u maloj zoni oko tačke posmatranja, tipično u zoni od nekoliko talasnih dužina. Za ovaj slučaj je karakteristično da se pojavljuje veliki broj reflektovanih talasa približno iste snage, tako da je ukupno polje jednako zbiru većeg broja slučajnih komponenti. Rejljeva raspodela se odnosi na slučaj kada se posmatra srednji intenzitet polja (izražen u $\mu\text{V/m}$), što podrazumeva da je u jednačini (3.9) i standardna devijacija b , takođe, izražena u $\mu\text{V/m}$.

Na Sl. 3.3 je prikazan izgled funkcije gustine Rejljeve raspodele.



Sl. 3.3. Rejljeva raspodela.

PDF RAJSOVE RASPODELE

Izraz za funkciju gustine Rajsove raspodele je:

$$p(x) = \frac{x}{\sigma^2} \exp\left(-\frac{x^2 + A^2}{2\sigma^2}\right) J_0\left(\frac{Ax}{\sigma^2}\right), \quad x \geq 0, \quad (3.13)$$

gde je,

$$I_0(z) = \frac{1}{2\pi} \int_0^{2\pi} \exp(z \cos \psi) d\psi, \quad (3.14)$$

modifikovana Beselova (*Bessel*) funkcija prve vrste, nultog reda. Rajsova raspodela predstavlja opšti slučaj Rejljeve raspodele i odnosi se na situaciju kada pored velikog broja reflektovanih talasa postoji i uticaj jake determinističke komponente električnog polja. Parametar σ ove raspodele predstavlja, kao i parametar b kod Rejljeve, standardnu devijaciju Gausovih komponenti u fazi i kvadraturi, nastalih usled prisustva velikog broja reflektovanih komponenti. Parametar A odgovara amplitudi direktne komponente. U slučaju kad je $A = 0$ dobija se Rejljeva raspodela. Rajsova raspodela se odnosi na slučaj kada se posmatra srednji intenzitet polja (izražen u $\mu\text{V/m}$), što podrazumeva da su u jednačini (3.13) amplituda direktne komponente A i standardna devijacija σ , takođe, izraženi u $\mu\text{V/m}$.

Srednja kvadratna vrednost ove raspodele je:

$$\Omega = E[X^2] = A^2 + 2\sigma^2. \quad (3.15)$$

Obično se za Rajsovu raspodelu definiše, tzv. K -faktor na sledeći način:

$$K = \frac{A}{\sigma\sqrt{2}}, \quad (3.16)$$

odnosno, izražen u dB,

$$K[\text{dB}] = 20 \log_{10} K. \quad (3.17)$$

Ovaj parametar može se shvatiti kao svojevrsni odnos signal-šum, gde je signal direktna komponenta, a “šum” komponente nastale *multipath* propagacijom. Sa teorijskog stanovišta, Rejljeva raspodela se dobija kad je $K = 0$.


Gustina Rajsove raspodele može se napisati i u sledećem obliku:

$$p(x) = \frac{2(K^2 + 1)x}{\Omega} \exp\left(-K^2 - \frac{(K^2 + 1)x^2}{\Omega}\right) I_0\left(2\sqrt{\frac{K^2(K^2 + 1)}{\Omega}}x\right), x \geq 0. \quad (3.18)$$

Modifikovana Beselova funkcija $I_0(z)$ se može izraziti kao:

$$I_0(z) = \frac{e^z}{(2\pi z)^{1/2}} \left(1 + \frac{1}{8z} + \frac{9}{128z^3} + \dots\right), \text{ za } z \gg 1. \quad (3.19)$$

Na Sl.3.4 su prikazane krive gustine Rajsove raspodele za različite vrednosti parametra K . Kao što se vidi sa datih grafika, za male vrednosti parametra K , raspodela teži Rejljevoj, dok za veće vrednosti parametra K , raspodela teži Gausovoj raspodeli.



Sl. 3.4. Gustina Rajsove raspodele za različite vrednosti parametra K .

3.1.2. TIPIČNE KUMULATIVNE FUNKCIJE RASPODELE

U nastavku su date definicije kumulativne funkcije raspodele za Gausovu, Rejljevu i Rajsovu raspodelu.

CDF GAUSOVE RASPODELE

Za Gausovu raspodelu kumulativna funkcija raspodele je:

$$F(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(t-m)^2}{2\sigma^2}\right) dt = \frac{1}{2} \left[1 + \operatorname{erf}\left(\frac{x-m}{\sigma\sqrt{2}}\right) \right], \text{ za svako } x. \quad (3.20)$$

gde je,

$$\operatorname{erf}(z) = \frac{2}{\sqrt{\pi}} \int_0^z e^{-t^2} dt. \quad (3.21)$$

Funkcija greške (*error function*) $\operatorname{erf}(z)$ se ne može analitički opisati, pa se zadaje tabelarno ili se aproksimira nekom realnom funkcijom.

CDF REJLIJEVE RASPODELE

Kumulativna funkcija Rejljeve raspodele data je sa:

$$F(x) = \int_0^x \frac{x}{b^2} \exp\left(-\frac{x^2}{2b^2}\right) dx = 1 - \exp\left(-\frac{x^2}{2b^2}\right), \quad x \geq 0. \quad (3.22)$$

CDF RAJSOVE RASPODELE

Neka je data Rajsova raspodela sa parametrima K i Ω . Veze ovih parametara sa parametrima A i σ , na osnovu definicija K i Ω u okviru Sekcije 3.1.1, su:

$$A = \sqrt{\frac{K^2 \Omega}{1 + K^2}}, \quad (3.23)$$

i

$$\sigma = \sqrt{\frac{\Omega}{2(1 + K^2)}}. \quad (3.24)$$

Ako se uvedu sledeće smene:

$$r_0 = \frac{r}{\sigma}, \quad a_0 = \frac{A}{\sigma} \quad \text{i} \quad R_0 = \frac{x}{\sigma}, \quad (3.25)$$

kumulativna funkcija Rajsove raspodele se može napisati u obliku:

$$F(x) = \int_0^x p(r) dr = \int_0^{R_0} r_0 \exp\left(-\frac{r_0^2 + a_0^2}{2}\right) I_0(a_0 r_0) dr_0, \quad (3.26)$$

gde je $p(r)$ gustina Rajsove raspodele definisana u Sekciji 3.1.1. Kao i u slučaju Gausove raspodele, ovaj integral nema analitičkih rešenja. Moguće je samo korišćenjem aproksimativnog izraza (3.19), odbacivanjem članova iza z^{-3} , dati aproksimaciju kumulativne funkcije Rajsove raspodele, uz pretpostavku da je $a_0 r_0 \gg 1$, na sledeći način:

$$F(x) = \frac{1}{2} + \frac{1}{2} \operatorname{erf}\left(\frac{R_0 - a_0}{\sqrt{2}}\right) - \frac{1}{\sqrt{8\pi} a_0} \left[1 - \frac{R_0 - a_0}{4a_0} + \frac{1 + (R_0 - a_0)^2}{8a_0^2} \right] \exp\left[-\frac{(R_0 - a_0)^2}{2}\right], \quad x \geq 0. \quad (3.27)$$

3.1.3. PROCENA PARAMETARA TIPIČNIH FUNKCIJA RASPODELE

Već je rečeno da se slučajan proces može opisati funkcijom gustine raspodele $p(x)$. Sa druge strane, ova funkcija je u potpunosti određena skupom parametara. Na osnovu eksperimentalno dobijenog uzorka je moguće izvršiti estimaciju ovih parametara, uz

pretpostavku da snimljeni odbirci podležu raspodeli sa parametrima čija se procena vrši. Najčešće korišćene metode estimacije parametara na osnovu uzorka su metoda momenata (*method of moments*) [11] (pp. 227-235) i metoda maksimalne verodostojnosti (*maximum likelihood*) [12]. Metoda momenata je zasnovana na oceni n -tog momenta raspodele na osnovu uzorka, i na osnovu veze koja postoji između odgovarajućeg parametra i procenjenog momenta daje se procena datog parametra. Metoda maksimalne verodostojnosti je zasnovana na oceni parametra raspodele pri kojoj je verovatnoća realizacije analiziranog uzorka najveća. Ova metoda u opštem slučaju zahteva često složene matematičke manipulacije, ali daje procene znatno efikasnije od procena dobijenih na bilo koji drugi način.

PROCENA PARAMETARA GAUSOVE RASPODELE

U slučaju Gausove raspodele, i za parametar m i za parametar σ , dobija se isti rezultat primenom obe metode. Neka je dat uzorak dimenzije N , X_i , $i = 1, 2, \dots, N$. Procena parametra m normalne raspodele je:

$$m = \frac{1}{N} \sum_{i=1}^N X_i. \quad (3.28)$$

Procena parametra σ normalne raspodele na osnovu uzorka je:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - m)^2}. \quad (3.29)$$

PROCENA PARAMETARA REJLIJEVE RASPODELE

U slučaju Rejljeve raspodele procena parametra b , metodom maksimalne verodostojnosti, je:

$$b = \sqrt{\frac{1}{2N} \sum_{i=1}^N X_i^2}, \quad (3.30)$$

gde je X_i , $i = 1, 2, \dots, N$, eksperimentalno dobijeni uzorak dimenzije N .

PROCENA PARAMETARA RAJSOVE RASPODELE

U slučaju Rajsove raspodele sa parametrima K i Ω , procena parametra Ω metodom maksimalne verodostojnosti je:

$$\Omega = \frac{1}{N} \sum_{i=1}^N X_i^2, \quad (3.31)$$

gde je X_i , $i = 1, 2, \dots, N$, eksperimentalno dobijeni uzorak dimenzije N .

Međutim, zbog složenog matematičkog izraza koji definiše funkciju gustine Rajsove raspodele, procena parametra K metodom maksimalne verodostojnosti je numerički algoritam, komplikovan za rešavanje. Sa druge strane, metoda momenata pruža znatno jednostavniju

estimaciju parametra K . Jedan od mogućih načina se svodi na numeričko rešavanje sledeće jednačine:

$$\mu = \frac{E[X]}{\sqrt{E[X^2]}} = \frac{\sqrt{\pi}}{2} (K^2 + 1)^{-1/2} \exp\left(-\frac{K^2}{2}\right) \left[(K^2 + 1) I_0\left(\frac{K^2}{2}\right) + K^2 I_1\left(\frac{K^2}{2}\right) \right], \quad (3.32)$$

Gde $E[X]$ i $E[X^2]$ predstavljaju procenjene vrednosti prvog i drugog momenta na osnovu uzorka. Ova jednačina je dobijena iz izraza za moment proizvoljnog reda Rajsove raspodele, s tim što je izabran takav odnos momenata koji zavisi samo od parametra K što omogućava nezavisnu procenu parametra Ω . Zbog kompleksnosti iterativnog procesa rešavanja date jednačine, procena parametra K iz uzorka se može izvršiti primenom sledeće jednačine:

$$\gamma = \frac{\text{Var}[X^2]}{(E[X^2])^2} = \frac{2K^2 + 1}{(K^2 + 1)^2}, \quad (3.33)$$

gde je sa $\text{Var}[\cdot]$ označena varijansa uzorka. Procena parametra K iz poslednje relacije dobija se kao:

$$K = \sqrt{\frac{\sqrt{1-\gamma}}{1-\sqrt{1-\gamma}}}. \quad (3.34)$$

Ovaj vrlo jednostavan izraz za dovoljno veliki uzorak daje zadovoljavajuće rezultate. Kada je uzorak nezadovoljavajuće veličine postoji mogućnost da je proračunata vrednost γ veća od jedinice, a u tom slučaju se K faktor ne može proračunati na osnovu prethodne jednačine.

3.2. UČESTANOST PROLASKA FEDINGA KROZ ODREĐENI NIVO I SREDNJE TRAJANJE FEDINGA

Prilikom analize prijemnog signala dok se prijemnik kreće, može se primetiti da signal u pojedinim vremenskim trenucima značajno opada. Analiza fedinga, u smislu statističke procene verovatnoće pojavljivanja određenog nivoa na prijemu, ne objašnjava u potpunosti koliko se često javljaju padovi nivoa signala ili koliko oni traju jer, po definiciji, funkcije raspodele su vremenski nezavisne. Statistička analiza daje samo ukupan procenat vremena koji signal provodi ispod određenog nivoa.

Podaci o trajanju i intenzitetu pojavljivanja dubokih padova nivoa signala su neophodni kako bi se prilikom dizajniranja sistema odabrali adekvatni informacioni protoci, dužine reči i postupci kodiranja, sa ciljem da se izbegnu neželjeni efekti fedinga. Stoga, padovi nivoa signala se mogu kvantitativno opisati pomoću učestanosti prolaska fedinga kroz određeni nivo (LCR) i srednjeg trajanja fedinga (ADF). LCR predstavlja učestanost kojom anvelopa signala na prijemu prolazi kroz određeni nivo u pozitivnom smeru, dok je ADF srednje vreme koje signal provede ispod određenog nivoa.

3.2.1. TEORIJSKA VREDNOST LCR PARAMETRA

Posmatra se anvelope signala na prijemu dok se prijemnik kreće. U slučaju kad se prijemnik kreće i kad prijemni signal podleže Rejlijevoj raspodeli, teorijska vrednost LCR parametra $L(X)$, za nivo signala X , je data sa:

$$L(X) = L_0 L_X, \quad (3.35)$$

gde je vrednost L_X nezavisna od frekvencije i brzine kojom se prijemnik kreće i u relaciji je sa gustinom raspodele $p(X)$:

$$L_X = \frac{1}{2} X_{rms} \cdot p(X), \quad (3.36)$$

gde je $X_{rms} = \sqrt{E[X^2]}$ i označava RMS nivoa signala X . Faktor normalizacije L_0 je:

$$L_0 = \frac{\beta V}{\sqrt{2\pi}} = \sqrt{2\pi} \frac{V}{\lambda} \approx 2.5 \frac{V}{\lambda}, \quad (3.37)$$

i funkcija je talasne dužine λ i brzine kretanja prijemnika V .

Za izvođenje izraza LCR parametra [2] (pp. 79-82) neophodna je združena PDF funkcija $p(x, \dot{x})$ nivoa anvelope kratkotrajnog fedinga x i njegovog izvoda po vremenu, odnosno nagiba anvelope $\dot{x}$. Uzimajući u obzir feding proces sa Sl. 3.5, očekivano vreme koje feding signal provede u intervalu $(X, X+dx)$ za dati nagib anvelope $\dot{x}$ i vremenski period dt je:

$$p(X, \dot{x}) dx d\dot{x} dt. \quad (3.38)$$

Vreme koje je potrebno da bi se jednom prošao nivo x za dati nagib anvelope $\dot{x}$ u intervalu $(X, X+dx)$ je:

$$dx / \dot{x}. \quad (3.39)$$

Količnik prethodna dva izraza predstavlja očekivani broj prolazaka anvelope x u intervalu $(X, X+dx)$ za dati nagib anvelope $\dot{x}$ i vremenski period dt , odnosno:

$$\dot{x} p(X, \dot{x}) d\dot{x} dt. \quad (3.40)$$

Očekivani broj prelazaka nivoa anvelope X za dati nagib anvelope $\dot{x}$ u vremenskom intervalu T je:

$$\int_0^T \dot{x} p(X, \dot{x}) d\dot{x} dt = \dot{x} p(X, \dot{x}) d\dot{x} T. \quad (3.41)$$


Očekivani broj prelazaka nivoa anvelope X „pozitivnog“ nagiba je:

$$N_x = T \int_0^\infty \dot{x} p(X, \dot{x}) d\dot{x}. \quad (3.42)$$

Konačno, očekivani broj prelazaka nivoa anvelope X u sekundi, odnosno LCR parametar, je dat kao:

$$L(X) = \int_0^\infty \dot{x} p(X, \dot{x}) d\dot{x}. \quad (3.43)$$

Ovo je rezultat opšteg tipa koji se može primeniti na praktično bilo koji slučajni proces.



Sl. 3.5. Određivanje teorijskih LCR i ADF parametara feding procesa.

Združena PDF funkcija $p(x, \dot{x})$ za slučaj sinusnog signala sa Gausovim šumom je izvedena u [13], [14] (Pogl. 2.1). Kanal sa Rajsovim fedingom se sastoji iz dominantne komponente (sinusni signal) i reflektovane komponente (Gausov šum). Stoga, za slučaj kanala sa Rajsovim fedingom važi:

$$p(x, \dot{x}) = \frac{x(2\pi)^{-3/2}}{\sqrt{Bb_0}} \int_{-\pi}^{\pi} d\theta \times \exp \left\{ -\frac{1}{2Bb_0} \left[B(x^2 - 2xs \cos \theta + s^2) + (b_0 \dot{x} + b_1 s \sin \theta)^2 \right] \right\}, \quad (3.44)$$

gde s predstavlja parametar centriranosti Rajsove raspodele, a $B = b_0 b_2 - b_1^2$, gde su b_0 , b_1 , i b_2 , konstante koje zavise od propagacionog okruženja.

Pretpostavljajući da dominantna komponenta kompleksne anvelope signala $r(t)$ ima Doplerovu frekvenciju jednaku $f_q = f_m \cos \theta_0$, gde je $0 \leq |f_q| \leq f_m$, važi da je:

$$b_n = (2\pi)^n \int_{-f_m}^{f_m} S_{rr}^c(f) (f - f_q)^n df = (2\pi)^n b_0 \int_0^{2\pi} \hat{p}(\theta) (f_m \cos \theta - f_q)^n d\theta, \quad (3.45)$$

gde je $\hat{p}(\theta)$ azimutna raspodela (PDF) reflektovane komponente, a $S_{rr}^c(f)$ odgovarajuća kontinualna komponenta Doplerovog spektra snage.

Treba imati u vidu da se $S_{rr}^c(f)$ može predstaviti pomoću Furijeove (*Fourier*) transformacije autokorelacione funkcije kompleksne anvelope signala $r(t)$, odnosno $R_{rr}^c(\tau) = R_{r_I r_I}^c(\tau) + jR_{r_I r_Q}^c(\tau)$, gde je:

$$R_{r_I r_I}^c(\tau) = \frac{\Omega}{2} \int_0^{2\pi} \cos(2\pi f_m \tau \cos \theta) \hat{p}(\theta) d\theta, \quad (3.46)$$

$$R_{r_I r_Q}^c(\tau) = \frac{\Omega}{2} \int_0^{2\pi} \sin(2\pi f_m \tau \cos \theta) \hat{p}(\theta) d\theta. \quad (3.47)$$

U nekim specijalnim slučajevima, PSD (naznačen sa $S_{rr}^c(f)$) je simetričan oko frekvencije $f_q = f_m \cos \theta_0$. Ovaj uslov se pojavljuje, na primer, kada je $f_q = 0$, ($\theta_0 = 90^\circ$) i $\hat{p}(\theta) = 1/(2\pi)$, $-\pi \leq \theta \leq \pi$.

U ovom slučaju, važi da je $b_n = 0$ za sve neparne vrednosti n (a posebno $b_1 = 0$) tako da se združena PDF funkcija $p(x, \dot{x})$ može pojednostaviti na sledeći način:

$$p(x, \dot{x}) = \sqrt{\frac{1}{2\pi b_2}} \exp\left\{-\frac{\dot{x}^2}{2b_2}\right\} \cdot \frac{x}{b_0} \exp\left\{-\frac{(x^2 + s^2)}{2b_0}\right\} I_0\left(\frac{xs}{b_0}\right) = p(\dot{x}) \cdot p(x). \quad (3.48)$$

Pošto je $p(x, \dot{x}) = p(\dot{x}) \cdot p(x)$, sledi da su x i $\dot{x}$ nezavisni.

Kada je $f_q = 0$ i $\hat{p}(\theta) = 1/(2\pi)$, može se izvesti zatvorena forma izraza za LCR anvelope fedinga. Shodno tome, važi da je:

$$b_n = \begin{cases} b_0 (2\pi f_m)^n \frac{1 \cdot 3 \cdot 5 \cdots (n-1)}{2 \cdot 4 \cdot 6 \cdots n}, & n \text{ parno} \\ 0, & n \text{ neparno} \end{cases}. \quad (3.49)$$

Stoga važi da je $b_1 = 0$ i $b_2 = b_0 (2\pi f_m)^2 / 2$, i da je:

$$L(X) = \sqrt{2\pi(K+1)} f_m \rho e^{-K-(K+1)\rho^2} I_0\left(2\rho\sqrt{K(K+1)}\right), \quad (3.50)$$

gde je:

$$\rho = \frac{X}{\sqrt{\Omega}} = \frac{X}{X_{rms}}, \quad (3.51)$$

i $X_{rms} \triangleq \sqrt{E[X^2]}$ predstavlja RMS nivoa anvelope fedinga.

U slučaju da je $K = 0$, odnosno da je u pitanju “čist” Rejljev feding, važi:

$$L(X) = \sqrt{2\pi} f_m \rho e^{-\rho^2}. \quad (3.52)$$

Može se primetiti da je LCR parametar direktno proporcionalan maksimalnoj Doplerovoj frekvenciji f_m , i stoga brzini kretanja prijemnika $V = f_m \lambda_c$. Imajući u vidu karakteristiku Rejljeve raspodele da je $E[X^2] = 2b^2$, lako se iz prethodnog izraza LCR parametra dolazi i do forme:

$$L(X) = \frac{\sqrt{2\pi}}{2} \frac{V}{\lambda_c} X_{rms} p\left(\frac{X}{X_{rms}}\right). \quad (3.53)$$

3.2.2. TEORIJSKA VREDNOST ADF PARAMETRA

U cilju dobijanja izraza ADF parametra feding signala [2] (pp. 79-82), uzet je u obzir vremenski interval dužine T , a trajanje i -tog pada anvelope ispod nivoa X je označeno sa t_i . Ako se u obzir uzmu definicije LCR i ADF parametra, njihov proizvod:

$$L(X) \cdot \bar{t}(X) = \frac{N_X}{T} \frac{\sum_{i=1}^N t_i}{N_X} = \frac{\sum_{i=1}^N t_i}{T} = P(x \leq X), \quad (3.54)$$

daje vrednost kumulativne funkcije raspodele u tački X , $F(X)$, što je zapravo verovatnoća da je nivo anvelope na prijemu manji od X . Stoga se teorijska vrednost ADF parametra, $\bar{t}(X)$, može izraziti kao:

$$\bar{t}(X) = \frac{F(X)}{L(X)} = \frac{P(x \leq X)}{L(X)} = \left(\frac{1}{L_0} \right) \frac{P(x \leq X)}{L_x}, \quad (3.55)$$

odnosno,

$$\bar{t}(X) = \bar{t}_0 \cdot \bar{t}_x, \quad (3.56)$$

gde je $\bar{t}_0$ odgovarajući faktor normalizacije.

Ako anvelopa fedinga ima Rajsovu raspodelu, onda važi:

$$P_x(x \leq X) = \int_0^x p(x) dx = 1 - Q\left(\sqrt{2K}, \sqrt{2(K+1)\rho^2}\right), \quad (3.57)$$

gde $Q(a,b)$ predstavlja Markum (Marcum) Q-funkciju [15] (pp. 93-113).

Ako se pretpostavi da je $f_q = 0$ i $\hat{p}(\theta) = 1/(2\pi)$, onda važi:

$$\bar{t}(X) = \frac{1 - Q\left(\sqrt{2K}, \sqrt{2(K+1)\rho^2}\right)}{\sqrt{2\pi(K+1)} f_m \rho e^{-K-(K+1)\rho^2} I_0\left(2\rho\sqrt{K(K+1)}\right)}, \quad (3.58)$$

gde je ρ definisano izrazom (3.51).

U slučaju kad se dalje pretpostavi da je $K = 0$, odnosno da je u pitanju Rejlijev feding, važi:

$$P(x \leq X) = \int_0^x p(x) dx = 1 - e^{-\rho^2}, \quad (3.59)$$

i da je:

$$\bar{t}(X) = \frac{e^{\rho^2} - 1}{\rho f_m \sqrt{2\pi}}. \quad (3.60)$$

3.2.3. PROCENA LCR i ADF PARAMETARA

Proces određivanja LCR i ADF parametara kratkotrajnog fedinga vrši se tako što se u obzir uzima anvelopa signala na prijemu, snimljena u vremenskom intervalu T , dok je prijemnik bio u pokretu. Najpre je neophodno odrediti koren iz srednje kvadratne vrednosti posmatranog uzorka kratkotrajnog fedinga, takozvanu RMS vrednost. Količnik minimalne, odnosno maksimalne vrednosti uzorka i RMS vrednosti predstavlja donju, odnosno gornju granicu intervala vrednosti nivoa električnog polja u okviru kog se vrši proračun LCR i ADF parametara.

Potom, potrebno je usvojiti „korak” pomoću kog se biraju vrednosti iz datog intervala, na osnovu čega se formira niz relevantnih vrednosti nivoa električnog polja. Na taj način, u slučaju da se usvoji da „korak” iznosi npr. 1dB, karakteristične vrednosti nivoa električnog polja (za koje se vrši proračun LCR i ADF parametara) se biraju na svaki 1dB polazeći od donje granice datog intervala.


Zatim se za svaku od izabranih vrednosti vrši proračun broja prolazaka N_X kroz odabrani nivo električnog polja X u pozitivnom smeru, tj. u smeru viših vrednosti nivoa, i ukupnog vremena T_X koje posmatrani uzorak provede ispod odabranog nivoa X (kao što je ilustrovano na Sl. 3.6). Parametar LCR se konačno dobija deljenjem broja prolazaka N_X sa vremenskim intervalom T , na kome se posmatra uzorak, tačnije prema relaciji (3.61):

$$L(X) = \frac{N_X}{T}. \quad (3.61)$$

Sa druge strane, neka su t_i , $i = 1, 2, \dots, N$, pojedinačni intervali vremena u kojima se signal nalazi ispod nivoa X i N_X broj prolazaka kroz X . Parametar ADF se dobija deljenjem proračunatog vremena T_X sa brojem prolazaka N_X kroz dati nivo električnog polja X , odnosno na osnovu relacije (3.62):

$$\bar{t}(X) = \frac{T_X}{N_X} = \frac{\sum_{i=1}^N t_i}{N_X}. \quad (3.62)$$

Prethodno opisani postupak predstavljen je na Sl. 3.6 za tipični kratkotrajni feding.



Sl. 3.6. Određivanje LCR i ADF parametara.

3.3. AUTOKORELACIONE KARAKTERISTIKE

Autokorelacione karakteristike signala, zapravo, predstavljaju meru korelacije signala sa samim sobom. Autokorelaciona funkcija (*Autocorrelation Function* - ACF) može se posmatrati kao funkcija sličnosti između signala i njegove zakasnele replike u zavisnosti od vremenskog kašnjenja. U statistici se autokorelacija slučajnog procesa koristi za opisivanje stepena korelisanosti između vrednosti procesa u različitim vremenskim momentima, u formi funkcije njihove vremenske razlike. Često se koristi u obradi signala u cilju analiziranja funkcija i signala u vremenskom domenu. Takođe, ACF se može koristiti i kao matematički alat za detekciju periodičnih komponenti analiziranog signala.

3.3.1. AUTOKORELACIONA FUNKCIJA I KOEFICIJENT AUTOKORELACIJE

U obzir je uzet slučajni proces koga čini statistički ansambl vremenskih funkcija $x(t)$. Neka su $x_1 = x(t_1)$ i $x_2 = x(t_2)$ dve slučajne promenljive dobijene posmatranjem slučajnog procesa $x(t)$ u trenucima t_1 i $t_2 = t_1 + \tau$. Autokorelaciona funkcija dobijena usrednjavanjem ansambla dve slučajne promenljive x_1 i x_2 je po definiciji [5] (pp. 33-37):

$$R_{xx}(t_1, t_2) = E[x(t_1)x(t_2)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 x_2 p(x_1, x_2) dx_1 dx_2, \quad (3.63)$$

gde je $E[\cdot]$ oznaka za matematičko očekivanje, a $p(x_1, x_2)$ predstavlja združenu funkciju gustine verovatnoće procesa. Već je napomenuto da za stacionaran proces važi da se

raspodela vrednosti ne menja sa promenom izbora trenutka posmatranja. Ovo znači da za stacionaran proces autokorelaciona funkcija ne zavisi od izbora trenutaka t_1 i $t_2 = t_1 + \tau$ već samo od vremenske razlike između njih τ .

$$R_{xx}(\tau) = R_{xx}(t_1, t_2). \quad (3.64)$$

Autokorelaciona funkcija dobijena usrednjavanjem slučajnih procesa $x(t_1)$ i $x(t_1 + \tau)$ u vremenu je definisana kao:

$$\bar{R}_{xx}(\tau) = \langle x(t_1)x(t_1 + \tau) \rangle = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t_1)x(t_1 + \tau) dt. \quad (3.65)$$

Za stacionaran proces važi:

$$\bar{R}_{xx}(\tau) = \bar{R}_{xx}(t_1, t_2), \quad (3.66)$$

dok za ergodičan proces važi $R_{xx}(\tau) = \bar{R}_{xx}(\tau)$.

Funkcija autokovarijanse je definisana kao:

$$\text{Cov}(\tau) = E[(x_1 - E[x_1])(x_2 - E[x_2])] = R_{xx}(\tau) - (E[X])^2. \quad (3.67)$$

Koeficijent korelacije slučajnih promenljivih X i Y je po definiciji:

$$\rho_c(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)}\sqrt{\text{Var}(Y)}}. \quad (3.68)$$

Za stacionaran proces se može prema prethodnoj jednačini izvesti izraz za koeficijent autokorelacije:

$$\rho_c(\tau) = \frac{\text{Cov}(\tau)}{\text{Var}(X)} = \frac{R_{xx}(\tau) - (E[X])^2}{\text{Var}(X)}. \quad (3.69)$$

Da bi se proračunao ACF kvadrata anvelope fedinaga [10] (pp. 60-61), koji se često koristi u literaturi, pretpostavljeno je da je frekvencija nosioca f_c , i da se prijemnik kreće brzinom V . Ako n -ti reflektovani talas stiže do prijemnika pod uglom $\theta_n(t)$ u odnosu na pravac kretanja prijemnika, Doplerov pomeraj talasa je dat kao:

$$f_{q,n}(t) = f_m \cos \theta_n(t), \quad (3.70)$$

gde je $f_m = V / \lambda_c$, a λ_c predstavlja talasnu dužinu predajnog signala. Ako je predajni signal dat kao $\text{Re}\{u(t)e^{j2\pi f_c t}\}$ gde je $u(t)$ kompleksni *low-pass* signal, onda je primljeni kompleksni *low-pass* signal $r(t)$ dat izrazom:

$$r(t) = \sum_{n=1}^N \alpha_n(t) e^{-j2\pi \{ (f_c + f_{q,n}(t))\tau_n(t) - f_{q,n}(t)t \}} u(t - \tau_n(t)), \quad (3.71)$$

gde je N ukupan broj incidentnih talasa, a $\alpha_n(t)$ i $\tau_n(t)$ su amplituda i vremensko kašnjenje, respektivno, za n -tu putanju.

Jednačina (3.71) se može napisati u obliku:

$$r(t) = \sum_{n=1}^N \alpha_n(t) e^{-j\phi_n(t)} u(t - \tau_n(t)), \quad (3.72)$$

gde je:

$$\phi_n(t) = 2\pi \{ (f_c + f_{q,n}(t))\tau_n(t) - f_{q,n}(t)t \}, \quad (3.73)$$

faza n -tog talasa.

Pošto je pretpostavljeno da je delovanje fedinga na svim frekvencijama uniformno, karakteristike Rejljevog feding procesa mogu se izvesti uzimajući da je poslati signal, zapravo, nemodulisani nosioc. Za nemodulisani nosioc, primljeni kompleksni *low-pass* signal je:

$$r(t) = \sum_{n=1}^N \alpha_n(t) e^{-j\phi_n(t)}, \quad (3.74)$$

ili

$$r(t) = r_I(t) + jr_Q(t), \quad (3.75)$$

gde je:

$$r_I(t) = \sum_{n=1}^N \alpha_n(t) \cos \phi_n(t), \quad (3.76)$$

i

$$r_Q(t) = \sum_{n=1}^N \alpha_n(t) \sin \phi_n(t). \quad (3.77)$$

Ako je broj N dovoljno veliki, može se primeniti centralna granična teorema [7] (pp. 164-165) i stoga se $r_I(t)$ i $r_Q(t)$ mogu posmatrati kao nezavisni Gausovi slučajni procesi sa srednjom vrednošću 0. Na osnovu ovoga može se zaključiti da $r(t)$ predstavlja kompleksni slučajni proces čija su realna i imaginarna komponenta nezavisni Gausovi slučajni procesi. Stoga anvelopa signala $r(t)$ podleže Rejljevoj raspodeli.

Pretpostavljajući da su svi slučajni procesi koji su spomenuti stacionarni u širem smislu, ACF funkcija realnog dela prijemnog signala može se proračunati na osnovu jednačina (3.76), (3.70) i (3.73) kao što je to urađeno u [10]:

$$R_{r_I r_I}(\tau) = E[r_I(t)r_I(t+\tau)] = E[\cos 2\pi f_{q,n}\tau] = E_\theta[\cos(2\pi f_m\tau \cos \theta)]. \quad (3.78)$$

Ovde je pretpostavljeno da važi:

$$E[r_I^2(t)] = E[r_Q^2(t)] = \frac{1}{2} \sum_{n=1}^N E|\alpha_n^2| = 1, \quad (3.79)$$

odnosno, ukupna prosečna snaga primljena od strane svih *multipath* komponenti je jednaka 1. Na sličan način, kroskorelacija $R_{r_I r_Q}(t)$ se može proračunati kao:

$$R_{r_I r_Q}(\tau) = E[r_I(t)r_Q(t+\tau)] = E_\theta[\sin(2\pi f_m\tau \cos \theta)]. \quad (3.80)$$

Za slučaj makro-ćelijskog okruženja, prijemna antena prima signale iz svih pravaca sa jednakom verovatnoćom. Tako da je logična pretpostavka da je ugao θ uniformno raspoređen u okviru intervala $[-\pi, \pi]$. Ovakav model predstavlja, zapravo, Klarkov (*Clarke*) dvodimenzionalni izotropni model [16]. Sa ovom pretpostavkom, jednačina (3.78) postaje:

$$R_{r_I r_I}(\tau) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \cos(2\pi f_m\tau \cos \theta) d\theta = \frac{1}{\pi} \int_0^{\pi} \cos(2\pi f_m\tau \cos \theta) d\theta = J_0(2\pi f_m\tau), \quad (3.81)$$

gde $J_0(x)$ predstavlja Beselovu funkciju nultog reda prve vrste. Autokorelaciona funkcija realnog dela prijemnog signala je prikazana na Sl.3.7. Na sličan način, jednačina (3.80) postaje:


$$R_{r_I r_Q}(\tau) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \sin(2\pi f_m\tau \cos \theta) d\theta = 0. \quad (3.82)$$

Takođe, treba napomenuti da važi:

$$R_{r_I r_I}(\tau) = R_{r_Q r_Q}(\tau), \quad (3.83)$$

i da je,

$$R_{r_I r_Q}(\tau) = R_{r_Q r_I}(\tau). \quad (3.84)$$



Sl. 3.7. Autokorelaciona funkcija Rejlijevog fedinga.

Konačno, ACF kvadrata anvelope feding signala je:

$$R_{|r|^2|r|^2}(\tau) = E[r^2(t)r^2(t+\tau)]. \quad (3.85)$$

Pošto je $|r(t)|^2 = r_I^2(t) + r_Q^2(t)$, sledi da je:

$$R_{|r|^2|r|^2}(\tau) = E[r_I^2(t)r_I^2(t+\tau)] + E[r_Q^2(t)r_Q^2(t+\tau)] + E[r_I^2(t)r_Q^2(t+\tau)] + E[r_Q^2(t)r_I^2(t+\tau)]. \quad (3.86)$$

Pošto je pretpostavljeno propagaciono okruženje u kome procesi $r_I(t)$ i $r_Q(t)$ imaju srednju vrednost 0, na osnovu [10] (Problem 2.6) je ACF kvadrata anvelope fedinga dat izrazom:

$$R_{|r|^2|r|^2}(\tau) = 4R_{r_I r_I}^2(0) + 4R_{r_I r_I}^2(\tau) + 4R_{r_I r_Q}^2(\tau). \quad (3.87)$$

Na osnovu uvedenih pretpostavki dalje se dobija da je:

$$R_{|r|^2|r|^2}(\tau) = 4E[r_I^2(t)] + 4J_0^2(2\pi f_m \tau) = 4(1 + J_0^2(2\pi f_m \tau)). \quad (3.88)$$

3.3.2. PROCENA AUTOKORELACIONE FUNKCIJE

Vrednosti ACF-a kvadrata anvelope fedinga, odnosno datog uzorka signala, mogu se odrediti na način koji je ilustrovan na Sl. 3.8. Zapravo, potrebno je najpre izvršiti kašnjenje originalnog signala, potom množenje odgovarajućih odbiraka originalnog i zakasnelog signala, i konačno usrednjavanje rezultujućeg proizvoda. Drugim rečima, na opisani način se dobija vrednost autokorelacionog koeficijenta za dati vremenski pomeraj τ , što je formulisano po definiciji jednačinom:

$$R_{xx}(\tau) = E[x(t)\bar{x}(t-\tau)], \quad (3.89)$$


gde $E[\cdot]$ označava matematičko očekivanje, dok $x(t)$ predstavlja analiziranu sekvencu vrednosti, a $\bar{x}(t)$ konjugovano kompleksne vrednosti analizirane sekvence pomerene za τ . Očigledno, u slučaju kad se analizira realni signal, odnosno sekvenca realnih vrednosti, umesto sekvence konjugovano kompleksnih vrednosti vrši se kašnjenje originalnog signala.

Za ergodičan diskretan proces, kakvim se može smatrati feding signal, jednačina (3.89) se može dalje predstaviti kao:

$$R_{xx}(k) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=0}^{N-1} x(t_n)x(t_{n-k}), \quad (3.90)$$

gde je sa k označen pomeraj, a $x(t_n)$ predstavlja odbirak analiziranog signala u trenutku t_n .

Na Sl. 3.8 je sa k označen broj odbiraka koji odgovara vremenskom pomeraju τ za koji je signal zakašnjen, odnosno za koji se vrši procena autokorelacionog koeficijenta. Opisani proces proračuna autokorelacionog koeficijenta se ponavlja za različite vremenske pomeraje, odnosno za različita kašnjenja kopije originalnog uzorka signala koji se drži fiksnim. Rezultujući autokorelacioni koeficijenti predstavljaju, zapravo, vrednosti ACF-a analiziranog uzorka signala.



Sl. 3.8. Određivanje ACF koeficijenta datog uzorka signala [5].


4. OSNOVNE KARAKTERISTIKE VEŠTAČKIH NEURALNIH MREŽA

Rezime. U ovoj glavi su analizirane osnovne karakteristike i funkcionisanje veštačkih neuralnih mreža. Najpre je razmatrana računaska sposobnost osnovnih neuronskih jedinica. Potom su opisana neka od relevantnih pravila nadgledanog učenja neuralnih mreža. Zatim su predstavljene višeslojne neuralne mreže, kao i metoda učenja propagacijom greške unazad. Takođe, opisan je i kros-validacioni postupak radi uvida u generalizacione sposobnosti veštačkih neuralnih mreža.

Pojam veštačkih neuralnih mreža (ANN) se odnosi na mreže međusobno povezanih, adaptivnih jedinica, tzv. neurona, koje se mogu primeniti u rešavanju širokog spektra problema. Pomoću ovih mreža mogu se implementirati, kako nelinearni statički, tako i dinamički sistemi. Bitna osobina neuralnih mreža je njihova prilagodljiva priroda, a konvencionalne metode rešavanja problema su zamenjene metodom “učenja prema primeru” što je pokazalo dobre rezultate u rešavanju različitih problema. Navedena osobina čini ANN jako pogodnim za aplikacije u kojima su dostupni podaci za treniranje, odnosno podaci nad kojima se mreža obučava. Druga ključna osobina ovih mreža jeste njihova paralelna arhitektura koja omogućava efikasno proračunavanje rešenja, naročito kada se radi o implementaciji na mikrokontroleru ili na nekom posebno dizajniranom hardveru (kao što je na primer *Field-Programmable Gate Array* (FPGA)).

Neuralne mreže, zapravo, predstavljaju model za rešavanje velikog broja različitih problema, kao što su na primer, šematska klasifikacija, sinteza i prepoznavanje govora, adaptivni interfejs između ljudi i kompleksnih fizičkih sistema, aproksimacije raznih funkcija, kompresija slike, klasterizacija, predikcija, optimizacija, modeliranje i kontrola nelinearnih sistema. Zbog široke lepeze primena, neuralna mreža je odabrana da bude jezgro predložene simulacione metode. Ove mreže su “neuralne” ne iz razloga što predstavljaju verne modele bioloških neuralnih mreža, već u smislu da su inspirisane samom neurologijom, što se može i zaključiti sa Sl. 4.1. koja prikazuje šematski model biološkog i veštačkog neurona. Zapravo, ANN se u većoj meri oslanja na tradicionalne matematičke i/ili statističke modele, kao što su neparametarska klasifikacija, algoritmi za klasterizaciju, nelinearni filtri i statistički regresioni modeli, nego što se oslanja na neurobiološke modele.

Veštački neuron predstavlja osnovnu jedinicu/blok pomoću koje se formiraju veštačke neuralne mreže. Radi razumevanja kako neuralne mreže funkcionišu, najpre je, u narednom Poglavlju 4.1, analizirana računaska sposobnost osnovnih neuronskih jedinica.



Sl. 4.1. Šematski dijagram (a) biološkog neurona i (b) veštačkog neurona [17].

4.1. NEURONSKA JEDINICA

Veštački neuron se koristi kao osnovna gradivna jedinica ANN-a. Funkcionisanje osnovne neuronske jedinice se zasniva na konceptu *linear threshold gate*-a (LTG) [4] (pp. 2-7). Osnovna funkcija LTG-a je razlikovanje, odnosno klasifikacija označenih vektora (tačaka) koji su svrstani po različitim klasama. Zapravo, LTG vrši preslikavanje vektora ulaznih podataka x u posebni binarni izlaz y . Funkcija prenosa LTG-a je data analitički sa:


$$y = \begin{cases} 1 & \text{ako je } \mathbf{w}^T \mathbf{x} = \sum_{i=1}^n w_i x_i \geq T \\ 0 & \text{u suprotnom} \end{cases}, \quad (4.1)$$

gde su $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_n]^T$ i $\mathbf{w} = [w_1 \ w_2 \ \dots \ w_n]^T$ ulazni i vektor težinskih koeficijenata, respektivno, dok T predstavlja konstantu, odnosno definisani prag. Na Sl.4.2(a) je predstavljen šematski prikaz LTG jedinice sa n ulaza. Grafička prezentacija jednačine (4.1)) je predstavljena na Sl.4.2(b). Vektor $\mathbf{x}$ u jednačini (4.1)) je n -dimenzionalni vektor sa binarnim ili realnim komponentama (tj. $\mathbf{x} \in \{0,1\}^n$ ili $\mathbf{x} \in R^n$), dok je $\mathbf{w} \in R^n$. Prema tome, izlaz LTG-a y se može formirati jednim od sledećih preslikavanja:

$$\mathbf{x} \in \{0,1\}^n \Rightarrow y: \{0,1\}^n \rightarrow \{0,1\}, \quad (4.2)$$

ili

$$\mathbf{x} \in R^n \Rightarrow y: R^n \rightarrow \{0,1\}. \quad (4.3)$$



Sl. 4.2. LTG jedinica: (a) šematski prikaz i (b) funkcija prenosa.

Pomoću LTG-a se naravno ne mogu realizovati sve postojeće funkcije prenosa već samo ograničeni broj. Računska sposobnost LTG-a se može izraziti brojem stepeni slobode LTG jedinice koji iznosi $d = n + 1$ (broj težinskih koeficijenata i prag (*threshold*)). Funkcije koje je moguće realizovati pomoću jednog LTG-a su poznate pod nazivom *threshold* funkcije. U cilju povećanja broja funkcija koji se može realizovati LTG-om, a time i računске sposobnosti osnovne neuronske jedinice, uvode se u razmatranje *quadratic threshold gate* (QTG) i *polynomial threshold gate* (PTG) [4] (pp. 7-9) jedinice.

Računska sposobnost LTG jedinice može se povećati proširenjem broja ulaza LTG-a. Ovo se može postići definisanjem novih ulaza u LTG jedinicu uzimanjem proizvoda već postojećih ulaza (kao na primer, grupisanjem postojećih ulaza "I" logičkim elementima). Definisanjem novih ulaza LTG jedinici (tačnije, dodavanjem sloja "I" logičkih elemenata) na veštački način je povećana dimenzionalnost ulaznog prostora LTG-a. Dodavanjem proizvoda parova već postojećih ulaza u LTG dobija se QTG [4] (pp. 7-8). Broj stepeni slobode QTG jedinice iznosi:

$$\frac{n(n+1)}{2} + 1, \text{ za } \mathbf{x} \in \{0,1\}^n, \quad (4.4)$$

i

$$d = \frac{(n+1)(n+2)}{2}, \text{ za } \mathbf{x} \in R^n. \quad (4.5)$$

Iako QTG značajno povećava broj funkcija koje se mogu realizovati, sam QTG i dalje nema sposobnost da realizuje sve moguće funkcije sa n promeljivih. Kako je u ovom slučaju, odnosno za ulaz drugog reda (proizvod parova postojećih ulaza) povećana računaska sposobnost QTG jedinice u odnosu na LTG, za očekivati je dalje poboljšanje dodatnim povećanjem reda ulaza na određeni r -ti red. Ovo rezultuje *polynomial threshold gate*-om koji se označava sa PTG(r). LTG i QTG predstavljaju specijalne slučajeve PTG-a, odnosno važe sledeći izrazi $\text{LTG} \cong \text{PTG}(1)$ i $\text{QTG} \cong \text{PTG}(2)$. Jednačina prenosa PTG(r) jedinice je data izrazom:

$$y = \begin{cases} 1 \text{ ako je } \sum_{i_1=1}^n w_{i_1} x_{i_1} + \sum_{i_1=1}^n \sum_{i_2=1}^n w_{i_1 i_2} x_{i_1} x_{i_2} + \dots \\ + \sum_{i_1=1}^n \sum_{i_2=1}^n \dots \sum_{i_r=1}^n w_{i_1 i_2 \dots i_r} x_{i_1} x_{i_2} \dots x_{i_r} \geq T \\ 0 \text{ u suprotnom} \end{cases} \quad (4.6)$$

Broj stepeni slobode u slučaju PTG(r) jedinice se može definisati kao:


$$d = \sum_{i=1}^r \binom{n}{i} + 1 = \sum_{i=0}^r \binom{n}{i} = \sum_{i=0}^r \frac{n!}{(n-i)!i!}, \quad (4.7)$$

što važi za $\mathbf{x} \in \{0,1\}^n$, i:

$$d = \sum_{i=1}^r \binom{n+i-1}{i} + 1 = \binom{n+r}{r} = \frac{(n+r)!}{n!r!}, \quad (4.8)$$

za $\mathbf{x} \in R^n$. Realizacija PTG-a u kaskadnoj formi (kaskada "I" logičkih elemenata i LTG jedinice) je prikazana na Sl. 4.3. Sa slike se može primetiti da se veća računaska moć PTG-a postiže po cenu veće kompleksnosti implementacije.

Imajući u vidu da je računska sposobnost LTG jedinice (odnosno neurona) povećana proširenjem dimenzionalnosti ulaznog prostora, za očekivati je i veću računsku sposobnost međusobnim povezivanjem onovnih neuronskih jedinica u neuralne mreže.



Sl. 4.3. Kaskadna realizacija PTG jedinice.

4.2. PRAVILA UČENJA

Jedna od značajnijih osobina koju poseduju neuralne mreže jeste sposobnost učenja tokom interakcije sa okolinom ili spoljašnjim izvorom informacija. Učenje ANN-a standardno se odvija u formi adaptivne procedure, poznatijom kao “pravilo učenja” ili “algoritam učenja”, a prilikom koje se težinski koeficijenti mreže inkrementalno prilagođavaju na takav način da se prethodno definisana mera performanse poboljšava kako učenje odmiče, tj. tokom vremena.

U kontekstu ANN-a, proces učenja se može posmatrati kao optimizacioni proces. Zapravo, proces učenja predstavlja jednu vrstu pretrage u multidimenzionalnom prostoru parametara (težinskih koeficijenata) za najoptimalnijim rešenjem, koja postepeno optimizuje prethodno specificiranu ciljnu funkciju, tj. kriterijumsku funkciju J (često se koristi i naziv funkcija greške ili funkcija cene).


Postoji veći broj pravila po kojima se može odvijati ANN učenje, a svrstana su u tri osnovne kategorije: nadgledano (*supervised learning*), sa pojačanjem (*reinforced learning*) i nenadgledano učenje (*unsupervised learning*). Prilikom nadgledanog učenja, koje je, takođe, poznato i kao učenje pomoću učitelja (*learning with a teacher*) ili pridruženo učenje (*associative learning*), svakom ulaznom signalu/vektoru, koji je uzet iz okoline, pridružen je poseban željeni izlazni vektor. Najčešće se korekcija težinskih koeficijenata sprovodi postepeno, tj. inkrementalno. Drugim rečima, svakim korakom tokom procesa učenja koeficijenti se prilagođavaju na taj način da se greška, odnosno razlika između izlaza mreže i

odgovarajućeg željenog cilja, smanjuje. Sa druge strane, nenadgledano učenje vrši klasterizaciju, tj. grupisanje (detekciju sličnosti) neoznačenih ulaznih podataka u okviru trening uzorka. Ideja je da se optimizuje (maksimizuje ili minimizuje) kriterijumska funkcija, odnosno funkcija performanse koja je definisana u zavisnosti od aktivnosti odgovarajućih izlaza mreže. U ovom slučaju najčešće se očekuje da težinski koeficijenti zajedno sa izlazima mreže konvergiraju ka stanju koje oslikava statističku prirodu ulaznih podataka. Učenjem sa pojačanjem se vrši prilagođavanje težinskih koeficijenata mreže u zavisnosti od odziva proračunatog signala pojačanja, što se razlikuje od nadgledanog učenja gde signal pomoću kog se vrši učenje predstavlja željeno i ispravno rešenje. Na pravilo učenja sa pojačanjem se može gledati kao na stohastički mehanizam pretrage koji pokušava da maksimizuje verovatnoću pozitivnog spoljašnjeg pojačanja za dati skup trening podataka.

Kao što je već napomenuto, nadgledano učenje je relevantno u situacijama kada su željeni izlazni vektori dostupni (kao što je to slučaj sa predloženom simulacionom metodom). U okviru kategorije nadgledanog učenja postoje dve vrste pravila koje su od posebnog značaja *error-correction* i *gradient-descent* pravila. *Error-correction* pravila su prvobitno primenjivana samo za treniranje pojedinačnih jedinica. Jedno od relevantnih *error-correction* pravila, tačnije perceptron pravilo učenja, je opisano u narednoj Sekciji 4.2.1.

4.2.1. PERCEPTRON PRAVILO UČENJA

Radi upoznavanja perceptron pravila učenja [4] (pp. 58-65), na Sl. 4.4 je prikazana perceptron jedinica koja je predstavljena pomoću LTG elementa. Pošto vrši preslikavanje ulaznog vektora $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_{n+1}]^T$ u bipolarni binarni izlaz y , perceptron se može primeniti za rešavanje problema klasifikacije ulaznih vektora u dve kategorije. Ulazni element x_{n+1} obično uzima vrednost 1 i vrši ulogu kontrolnog (*bias*) parametra. Sa $\mathbf{w}$ je označen vektor $\mathbf{w} = [w_1 \ w_2 \ \dots \ w_{n+1}]^T \in R^{n+1}$ koji je sačinjen od slobodnih parametara (težinskih koeficijenata) perceptrona. Ulazno/izlazna relacija perceptrona je data sa $y = \text{sgn}(\mathbf{x}^T \mathbf{w})$, gde *sgn* predstavlja signum funkciju koja vraća vrednosti +1 ili -1 zavisno od toga da li je znak skalarnog argumenta pozitivan ili negativan, respektivno.



Sl. 4.4. Perceptron jedinica.

Pod pretpostavkom da se vrši treniranje zadatog perceptrona sa ciljem da budu naučeni trening parovi $\{\mathbf{x}^1, d^1\}, \{\mathbf{x}^2, d^2\}, \dots, \{\mathbf{x}^m, d^m\}$, gde $\mathbf{x}^k$ predstavlja ulazni vektor i važi $\mathbf{x}^k \in R^{n+1}$, dok je $d^k \in \{-1, +1\}$, $k = 1, 2, \dots, m$ željeni cilj koji odgovara k -tom ulaznom vektoru (najčešće se redosled trening parova određuje proizvoljno). Skup svih trening parova naziva se trening skup, odnosno trening uzorak. Cilj je dizajnirati perceptron, takav da se za svaki ulazni vektor $\mathbf{x}^k$ trening skupa, izlaz perceptrona y^k slaže sa željenim izlaznim parametrom d^k , što znači da je potrebno da važi $y^k = \text{sgn}(\mathbf{w}^T \mathbf{x}^k) = d^k$, za svako $k = 1, 2, \dots, m$. Perceptron ispravno klasifikuje trening podatke ako je prethodna relacija zadovoljena. Takođe, dizajniranje pogodnog perceptrona za ispravnu klasifikaciju trening podataka ogleda se u određivanju vektora težinskih koeficijenata $\mathbf{w}^*$ takvog da su zadovoljene sledeće relacije:

$$\begin{cases} (\mathbf{x}^k)^T \mathbf{w}^* > 0 \text{ ako je } d^k = +1 \\ (\mathbf{x}^k)^T \mathbf{w}^* < 0 \text{ ako je } d^k = -1 \end{cases} \quad (4.9)$$

Bitno je napomenuti da skup svih $\mathbf{x}$ koji zadovoljavaju $\mathbf{x}^T \mathbf{w}^* = 0$ definiše multidimenzionalnu površinu u R^n prostoru. Prema tome, potraga za željenim rešenjem, tj. vektorom $\mathbf{w}^*$ jednačine (4.9), ekvivalentna je potrazi za površinom koja razdvaja, odnosno ispravno klasifikuje sve vektore $\mathbf{x}^k$, $k = 1, 2, \dots, m$. Zapravo, tražena multidimenzionalna površina je $\mathbf{x}^T \mathbf{w}^* = 0$ koja razdvaja ulazni prostor na dve oblasti, na jednu koja sadrži sve tačke $\mathbf{x}^k$ za koje važi $d^k = +1$ i na drugu oblast sa svim tačkama $\mathbf{x}^k$ za koje važi $d^k = -1$.

Jedna od mogućih inkrementalnih metoda za rešavanje ovog problema, odnosno pronalaska $\mathbf{w}^*$, dobija se primenom perceptron pravila učenja:

$$\begin{cases} \mathbf{w}^1 \text{ proizvoljno} \\ \mathbf{w}^{k+1} = \mathbf{w}^k + \rho(d^k - y^k) \mathbf{x}^k, k=1, 2, \dots \end{cases} \quad (4.10)$$

gde je ρ pozitivna konstanta kojom je označena stopa učenja (*learning rate*). Da bi se započeo inkrementalni proces učenja, datog jednačinom (4.10)), najpre se vrši selekcija inicijalnog težinskog koeficijenta $\mathbf{w}^1$ (najčešće se selekcija sprovodi nasumično). Zatim se nad m parova trening podataka $\{\mathbf{x}^k, d^k\}$ vrši korekcija vektora težinskih koeficijenata, sve dok se ne pronađe željeno rešenje (što ne mora da se desi sa sigurnošću), odnosno vektor $\mathbf{w}^*$ koji ispravno klasifikuje trening podatke. Obrada kompletnog skupa od m trening parova se naziva krug (epoha ili prolaz). Najčešće je potrebno više od jednog kruga da bi se odredilo optimalno rešenje. Premda je u jednačini (4.10) oznakom k , koja se pojavljuje u $\mathbf{w}^k$, naznačen iteracioni broj, sa druge strane, oznaka k koja se pojavljuje u $\mathbf{x}^k$ i d^k označava trenning par koji je razmatran u k -toj iteraciji. Takođe, ako je broj trening parova m konačan, onda se oznake u $\mathbf{x}^k$ i d^k mogu zameniti sa $[(k-1) \bmod m] + 1$. U navedenom izrazu, $a \bmod b$ vraća ostatak operacije deljenja a sa b .

Može se primetiti da se za $\rho = 0.5$ perceptron pravilo učenja može pisati kao:

$$\begin{cases} \mathbf{w}^1 \text{ proizvoljno} \\ \mathbf{w}^{k+1} = \mathbf{w}^k + \mathbf{z}^k, \text{ ako je } (\mathbf{z}^k)^T \mathbf{w}^k \leq 0, \\ \mathbf{w}^{k+1} = \mathbf{w}^k \text{ u suprotnom} \end{cases} \quad (4.11)$$

gde je:


$$\mathbf{z}^k = \begin{cases} +\mathbf{x}^k & \text{ako je } d^k = +1 \\ -\mathbf{x}^k & \text{ako je } d^k = -1 \end{cases}. \quad (4.12)$$

Što znači, korekcija se preduzima samo ako se dogodi pogrešna klasifikacija, što je naznačeno sa:

$$(\mathbf{z}^k)^T \mathbf{w}^k \leq 0. \quad (4.13)$$

Dodavanjem vektora $\mathbf{z}^k$ vektoru $\mathbf{w}^k$ u jednačini (4.11) težinski vektor se direktno pomera prema, a možda i preko površine razdvajanja $(\mathbf{z}^k)^T \mathbf{w}^k = 0$. Novi vektorski proizvod $(\mathbf{z}^k)^T \mathbf{w}^{k+1}$ je veći od $(\mathbf{z}^k)^T \mathbf{w}^k$ za iznos $\|\mathbf{z}^k\|^2$, a korekcija $\Delta \mathbf{w}^k = \mathbf{w}^{k+1} - \mathbf{w}^k$ očigledno pomera $\mathbf{w}^k$ u ispravnom smeru, odnosno u smeru povećanja $(\mathbf{z}^k)^T \mathbf{w}^k$, što se i može videti sa Sl.4.5. Prema tome, perceptron pravilo učenja pokušava da pronađe rešenje $\mathbf{w}^*$ za sledeći sistem nejednačina:

$$(\mathbf{z}^k)^T \mathbf{w} > 0, \text{ za } k = 1, 2, \dots, m. \quad (4.14)$$



Sl. 4.5. Geometrijski prikaz perceptron pravila učenja.


U slučaju kada je ciljna funkcija $J(w)$ poznata, trenutno stanje w^k se može inkrementalno korigovati svakom narednom iteracijom, i to pomeranjem niz površinu koja je definisana pomoću $J(w)$ u w prostoru. Takođe, funkcija J se može koristiti za primenu diskretne *gradient-descent* pretrage u cilju korigovanja w^k , a na taj način je obezbeđeno da se pomeraji odvijaju u smeru najstrmijeg dela površine $J(w)$ u tački od interesa w^k . Ovo se može postići postavljanjem zahteva da je w^k proporcionalno gradientu J u tački w^k , što se formalno može pisati kao:

$$w^{k+1} = w^k - \rho \nabla J(w) |_{w=w^k} = w^k - \rho \left[\frac{\partial J}{\partial w_1} \frac{\partial J}{\partial w_2} \dots \frac{\partial J}{\partial w_{n+1}} \right]^T |_{w=w^k}. \quad (4.15)$$

Ovde je inicijalna tačka pretrage naznačena sa w^1 , a sa ρ stopa, odnosno korak učenja. Neophodno je da se navedeni parametri definišu pre samog treniranja mreže. Jednačina (4.15) se može nazvati *steepest gradient descent* pravilo pretrage ili prostije, *gradient descent* pravilo. Narednim Sekcijama 4.2.2 i 4.2.3 opisana su dva značajnija pravila učenja koja pripadaju klasi *gradient-descent* pravila. Spomenuta pravila su izvedena tako što je najpre definisana odgovarajuća kriterijumska funkcija, koja je zatim optimizovana iterativnom procedurom gradijentne pretrage.

4.2.2. μ -LMS PRAVILO UČENJA

μ -LMS pravilo [18] je jedno od jednostavnijih i često primenjivanih pravila učenja. Takođe, ono je od posebne važnosti zbog mogućnosti učenja kompleksnijih neuralnih mreža, koje su izgrađene od više osnovnih jedinica. U okviru ove sekcije je opisano μ -LMS pravilo u kontekstu linearne jedinice koja je predstavljena na Sl. 4.6.



Sl. 4.6. Adaptivna linearna jedinica.

Neka je izrazom:

$$J(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^m (d^i - y^i)^2, \quad (4.16)$$

data suma kvadratnih grešaka (*Sum of Squared Error* - SSE), odnosno kriterijumska funkcija gde je:

$$y^i = (\mathbf{x}^i)^T \mathbf{w}. \quad (4.17)$$

Zatim, primenom *steepest gradient-descent* pretrage radi minimiziranja $J(\mathbf{w})$, odnosno jednačine (4.16), dolazi se do izraza:

$$\mathbf{w}^{k+1} = \mathbf{w}^k - \mu \nabla J(\mathbf{w}) = \mathbf{w}^k + \mu \sum_{i=1}^m (d^i - y^i) \mathbf{x}^i. \quad (4.18)$$


Kriterijumska funkcija $J(\mathbf{w})$, data jednačinom (4.16), je kvadratna po težinskim koeficijentima zbog linearne relacije y^i i $\mathbf{w}$. Zapravo, $J(\mathbf{w})$ definiše konveksnu hiperparaboličnu površinu sa jednim minimumom $\mathbf{w}^*$ (i to globalnim minimumom). Zbog toga, ako je pozitivna konstanta μ odabrana kao značajno mala vrednost, onda će *gradient-descent* pretraga implementirana jednačinom (4.18) asimptotski konvergirati ka rešenju $\mathbf{w}^*$ bez obzira na postavku inicijalne tačke pretrage $\mathbf{w}^1$. Pravilo učenja predstavljeno jednačinom (4.18) se često naziva i grupno LMS pravilo (*batch LMS rule*).

Inkrementalna verzija jednačine (4.18), koja je poznata kao μ -LMS ili samo LMS pravilo, data je sledećim izrazom:

$$\begin{cases} \mathbf{w}^1 = 0 \text{ ili proizvoljno} \\ \mathbf{w}^{k+1} = \mathbf{w}^k + \mu(d^k - y^k) \mathbf{x}^k \end{cases} \quad (4.19)$$

4.2.3. DELTA PRAVILO

Delta pravilo takođe pripada kategoriji nadgledanog učenja neuralnih mreža i proizilazi iz μ -LMS pravila sa izuzetkom što dozvoljava i jedinice sa diferencijabilnim, nelinearnim aktivacionim funkcijama f . Na Sl.4.7 je prikazana jedinica sa sigmoidalnom aktivacionom funkcijom. Izlaz jedinice je naznačen kao $y = f(net)$, a promenljiva net je definisana kao vektorski proizvod $\mathbf{x}^T \mathbf{w}$.



Sl. 4.7. Neuron sa diferencijabilnom sigmoidalnom aktivacionom funkcijom f .

U obzir je uzet trening par podataka $\{\mathbf{x}^i, d^i\}$, $i = 1, 2, \dots, m$, gde $\mathbf{x}^i \in R^{n+1}$ ($x_{n+1}^i = 1$ za svako i), i $d^i \in [-1, +1]$. Primenom *gradient descent* pretrage na SSE kriterijumske funkcije $J(\mathbf{w}) = \frac{1}{2}(d - y)^2$ čiji je gradijent dat izrazom:

$$\nabla J(\mathbf{w}) = -(d - y) f'(net) \mathbf{x}, \quad (4.20)$$

dalje vodi do delta pravila:

$$\begin{cases} \mathbf{w}^1 = 0 \text{ ili proizvoljno} \\ \mathbf{w}^{k+1} = \mathbf{w}^k + \rho [d^k - f(net^k)] f'(net^k) \mathbf{x}^k = \mathbf{w}^k + \rho \delta^k \mathbf{x}^k \end{cases} \quad (4.21)$$

gde je $net^k = (\mathbf{x}^k)^T \mathbf{w}^k$, a $f' = \frac{\partial f}{\partial net}$.


Najčešće postoji mogućnost da se izvodi aktivacionih funkcija f izraze u formi samih aktivacionih funkcija. Na primer, ako je funkcija f zadata kao $f(net) = \frac{1}{1+e^{-\alpha net}}$ važi:

$$f'(net) = \alpha f(net)[1 - f(net)], \quad (4.22)$$

dok za funkciju hiperboličkog tangensa $f(net) = \tanh(\beta net)$ važi:

$$f'(net) = \beta [1 - f^2(net)]. \quad (4.23)$$

Na Sl.4.8 su prikazane funkcije f i f' za slučaj hiperboličkog tangensa kao aktivacione funkcije sa parametrom $\beta = 1$. Sa slike se primećuje da se f asimptotski približava granicama od $+1$ i -1 , kako se net približava $+\infty$ i $-\infty$, respektivno.



Sl. 4.8. Hiperbolički tangens kao aktivaciona funkcija f i njen izvod f' .

Kao što se može primetiti sa grafika $f(net)$ koji je prikazan na Sl.4.8, važi da je $f'(net) \approx 0$ za veće vrednosti net parametra (odnosno, $|net| > 3$), što je poznato pod nazivom ravna oblast (*flat spot*) u odnosu na f' . U ovim ravnim oblastima, što je i za očekivati, delta pravilo napreduje veoma sporo (tj. promene težinskih koeficijenata su jako male čak i kada greška ($d - y$) uzima velike vrednosti) pošto veličina promene težinskih koeficijenata u jednačini (4.21) direktno zavisi od veličine $f'(net)$. Iz navedenog razloga, spora konvergencija rezultuje prekomernim vremenom trening procesa u slučaju kada se koristi delta pravilo učenja. Jedna od uobičajenih tehnika eliminacija ravnih oblasti primenjuje dodavanje odgovarajuće male pozitivne vrednosti na vrednost f' . U ovom slučaju, jednačina za korigovanje težinskih koeficijenata izgleda:

$$\mathbf{w}^{k+1} = \mathbf{w}^k + \rho \left[d^k - f(\mathbf{net}^k) \right] \left[f'(\mathbf{net}^k) + \varepsilon \right] \mathbf{x}^k. \quad (4.24)$$

Jedna od bitnijih prednosti delta pravila je ta što postoji mogućnost primene prilikom treniranja višeslojne neuralne mreže. U takvom obliku ovo pravilo je poznato pod nazivom propagacija greške unazad.


4.3. VIŠESLOJNE NEURALNE MREŽE

U okviru ovog poglavlja opisana je primena delta pravila na višeslojne neuralne mreže (*Multilayer Feedforward Neural Network* - MFNN) što rezultuje pravilom učenja koje je poznato kao propagacija greške unazad (*error backpropagation* (EBP), ili prostije *backprop*) koje predstavlja jedno od najčešće korišćenih pravila u mnogobrojnim aplikacijama ANN-a. Zapravo, sam razvoj i unapređenje EBP pravila predstavljaju jedan od razloga interesovanja za oblast ANN-a. EBP algoritam nudi računski efikasan metod za korigovanje težinskih koeficijenata MFNN neuronskih jedinica sa diferencijabilnim aktivacionim funkcijama. MFNN obučen primenom EBP-a se primenjuje uspešno za rešavanje kompleksnih problema različitog tipa, kao što su šematska klasifikacija, aproksimacija funkcija, nelinearno sistemsko modelovanje, vremenska predikcija, kompresija i rekonstrukcija slike.

EBP predstavlja *gradient-descent* algoritam za pretragu koji, nažalost, može pokazati i sporu konvergenciju ka minimumu lokalnog tipa. Sa druge strane, postoji nekoliko metoda za povećanje brzine konvergencije i izbegavanje lokalnog minimuma. Radi shvatanja kako ANN funkcioniše, kao primer je uzeta u obzir dvoslojna arhitektura koja je prikazana na Sl. 4.9. Iako je slikom predstavljena u potpunosti povezana neuralna mreža, zbog jasnosti, prikazane su samo pojedine veze. Neuronske jedinice na ulazu ove mreže prihvataju skup skalarnih signala $\{x_0, x_1, \dots, x_n\}$, gde x_0 označava kontrolni signal (*bias signal*) i u ovom slučaju jednak je jedinici. Ulazni skup signala formira ulazni vektor $\mathbf{x} \in R^{n+1}$ (uključujući i kontrolni signal x_0 koji se obično ne tretira kao deo ulaznog vektora već kao deo strukture neurona). Sloj mreže koji prihvata ulazni vektor naziva se skriveni sloj. Mreža na Sl. 4.9 poseduje jedan skriveni sloj sa J jedinica. Izlaz skrivenog sloja je $(J+1)$ -dimenzionalni vektor sa elementima koji su iz skupa realnih brojeva, $\mathbf{z} = [z_0 \ z_1 \ \dots \ z_J]^T$. Takođe, i ovde z_0 predstavlja kontrolni signal, koji se može posmatrati kao izlaz koji generiše neka virtuelna jedinica (sa indeksom nula), a postavljen je na vrednost 1. Vektor $\mathbf{z}$ predstavlja ulazni signal izlaznog sloja koji poseduje L jedinica. Izlazni sloj generiše L -dimenzionalni vektor $\mathbf{y}$ kao odziv na ulazni vektor $\mathbf{x}$, koji bi, u slučaju trenirane mreže, trebao biti identičan (ili jako sličan) željenom izlazu, odnosno vektoru $\mathbf{d}$ koji je pridružen ulaznom vektoru $\mathbf{x}$.

Pretpostavljeno je da je aktivaciona funkcija f_h neuronskih jedinica skrivenog sloja diferencijabilna nelinearna funkcija. Tipično, f_h je funkcija definisana sa $f_h(\mathbf{net}) = 1/(1 + e^{-\alpha \mathbf{net}})$, ili je funkcija hiperboličkog tangensa $f_h(\mathbf{net}) = \tanh(\beta \mathbf{net})$, sa vrednostima α i β koje su bliske jedinici. Pretpostavljeno je i da svaka jedinica izlaznog sloja ima aktivacionu funkciju označenu sa f_o . Funkcionalna forma funkcije f_o određena je željenom predstavom izlaznog signala/vektora ili tipom aplikacije koja se simulira. Na primer, ako je željeni izlaz predstavljen realnim vrednostima (kao što je to slučaj npr. u aplikacijama funkcijskih aproksimacija), onda je najbolje koristiti linearnu aktivaciju $f_o(\mathbf{net}) = \alpha \mathbf{net}$. Sa druge strane, ako ANN vrši šematsku klasifikaciju gde su pogodne binarne izlazne vrednosti, onda se saturaciona nelinearna funkcija slična f_h može koristiti i za f_o . U ovom slučaju, komponente željenog izlaznog vektora $\mathbf{d}$ moraju biti izabrane u odgovarajućem opsegu u

odnosu na f_o . Bitno je primetiti da ako je f_h linearno, onda se neuralna mreža sa Sl. 4.9 uvek može svesti na mrežu sa samo jednim slojem, što dovodi do gubitka univerzalnosti aproksimacije/mapiranja. Sa w_{ji} je naznačen težinski koeficijent j -te skrivene jedinice kojoj je pridružen ulazni signal x_i . Slično, w_{lj} predstavlja težinski koeficijent l -te izlazne jedinice sa skrivenim signalom z_j .



Sl. 4.9. Arhitektura dvoslojne potpuno povezane neuralne mreže.

Za dalje razmatranje uzet je u obzir skup od m ulazno/izlaznih parova $\{\mathbf{x}^k, \mathbf{d}^k\}$, gde je $\mathbf{d}^k$ L -dimenzionalni vektor koji predstavlja željeni izlaz mreže u odnosu na ulazni podatak $\mathbf{x}^k$. Cilj je da se treniranjem prilagodi $J(n+1) + L(J+1)$ težinskih koeficijenata ove mreže tako da je mapiranje predstavljeno trening skupom aproksimirano, odnosno naučeno. Kako se ovde radi o nadgledanom učenju (odnosno, dostupni su ciljni izlazi), funkcija greške se može definisati da pokazuje stepen aproksimacije za bilo koji skup težinskih koeficijenata. Najčešće se funkcija greške implementira u formi sume kvadratnih grešaka (SSE) ili srednje kvadratne greške (*Mean Squared Error* - MSE), što, naravno, nisu jedine mogućnosti. Postoje različite forme funkcije greške koje se koriste u praksi. Kada se jednom formuliše pogodna funkcija greške, učenje se može posmatrati kao optimizacioni proces. Što znači da funkcija greške vrši funkciju kriterijumske funkcije, a algoritam učenja teži da minimizuje kriterijumsku funkciju u prostoru mogućih težinskih koeficijenata. Na primer, ako se radi o diferencijabilnoj kriterijumskoj funkciji, primenom *gradient-descent* pretrage nad tako zadatom funkcijom dolazi se do pravila učenja [19]-[23]. Zapravo, nadgledano učenje je na taj način primenjeno u cilju korekcije težinskih koeficijenata w_{ji} i w_{lj} , tako da se minimizuje (u lokalnom smislu) funkcija greške koja je definisana kao:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{l=1}^L (d_l - y_l)^2, \quad (4.25)$$

gde w predstavlja skup svih težinskih koeficijenata mreže. Bitno je primetiti da jednačina (4.25) zapravo predstavlja SSE kriterijumske funkcije date jednačinom (4.16), ali u generalisanom obliku za mreže sa više izlaza.

4.3.1. PROPAGACIJA GREŠKE UNAZAD

Pošto su ciljne vrednosti dostupne i eksplicitno zadate, postoji mogućnost direktne primene delta pravila, koje je izvedeno u Sekciji 4.2.3, radi korekcije težinskih koeficijenata w_{lj} . Stoga, može se pisati

$$\Delta w_{lj} = w_{lj}^{new} - w_{lj}^c = -\rho_o \frac{\partial E}{\partial w_{lj}} = \rho_o (d_l - y_l) f_o'(net_l) z_j, \quad (4.26)$$

gde su $l = 1, 2, \dots, L$ i $j = 1, 2, \dots, J$. U navedenoj jednačini $net_l = \sum_{j=0}^J w_{lj} z_j$ predstavlja težinsku sumu

koja odgovara l -toj izlaznoj jedinici, ρ_o stopu učenja, f_o' označava izvod funkcije f_o u odnosu na net , a w_{lj}^{new} i w_{lj}^c predstavljaju korigovanu, odnosno novu i trenutnu vrednost težinskih koeficijenata, respektivno. Vrednosti z_j se dobijaju propagacijom ulaznog vektora x kroz skriveni sloj prema sledećem izrazu:

$$z_j = f_h \left(\sum_{i=0}^n w_{ji} x_i \right) = f_h (net_j), \quad j = 1, 2, \dots, J. \quad (4.27)$$

Pravilo učenja za slučaj korigovanja težinskih koeficijenata skrivenog sloja w_{ji} nije tako očigledno kao što je to slučaj za izlazni sloj pošto ne postoji raspoloživ skup ciljnih vrednosti (vrednosti željenih izlaza) za jedinice skrivenog sloja. Međutim, postoji mogućnost izvođenja pravila učenja za jedinice skrivenog sloja ako se pokuša minimizirati greška samog izlaznog sloja. Ovo, zapravo, podrazumeva propagaciju izlaznih grešaka $(d_l - y_l)$ unazad kroz izlazni sloj prema jedinicama skrivenog sloja u cilju estimacije dinamičkih, ciljnih vrednosti ovih jedinica. Navedeno pravilo učenja je poznato kao algoritam propagacije greške unazad i može se posmatrati kao unapređeno delta pravilo (jednačina (4.26)) koje se primenjuje u slučaju korigovanja izlaznog sloja. Radi kompletiranja izvođenja EBP-a za korigovanje težinskih koeficijenata skrivenog sloja, slično kao i u slučaju koeficijenata izlaznog sloja, primenjuje se *gradient-descent* algoritam nad kriterijumskom funkcijom koja je data jednačinom (4.25), ali ovoga puta gradijent se proračunava za težinske koeficijente skrivenog sloja sledećom jednačinom:

$$\Delta w_{ji} = -\rho_o \frac{\partial E}{\partial w_{ji}}, \quad j = 1, 2, \dots, J; i = 0, 1, 2, \dots, n, \quad (4.28)$$

gde se parcijalni izvod proračunava u odnosu na trenutne vrednosti težinskih koeficijenata. Parcijalni izvod u jednačini (4.28) se može izraziti na sledeći način:

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial z_j} \frac{\partial z_j}{\partial net_j} \frac{\partial net_j}{\partial w_{ji}}, \quad (4.29)$$

gde su:

$$\frac{\partial net}{\partial w_{ji}} = x_i, \quad (4.30)$$

$$\frac{\partial z_j}{\partial net_j} = f'_h(net_j), \quad (4.31)$$

i važi:

$$\begin{aligned} \frac{\partial E}{\partial z_j} &= \frac{\partial}{\partial z_j} \left\{ \frac{1}{2} \sum_{l=1}^L [d_l - f_o(net_l)]^2 \right\} = - \sum_{l=1}^L [d_l - f_o(net_l)] \frac{\partial f_o(net_l)}{\partial z_j} = \\ &= - \sum_{l=1}^L [d_l - y_l] f'_o(net_l) w_{lj} \end{aligned} \quad (4.32)$$

Zatim, zamenom jednačina (4.30), (4.31) i (4.32) u jednačinu (4.29) i primenom jednačine neurona:

$$net_i = (\mathbf{x}_i)^T \mathbf{w}_i, \quad (4.33)$$

dolazi se do željenog pravila učenja koje glasi:

$$\Delta w_{ji} = \rho_h \left[\sum_{l=1}^L [d_l - y_l] f'_o(net_l) w_{lj} \right] f'_h(net_j) x_i. \quad (4.34)$$

Upoređivanjem jednačine (4.34) sa jednačinom (4.26), može se izvršiti procena ciljnog signala d_j koji odgovara j -toj jedinici skrivenog sloja, u pogledu propagacije signala greške unazad, što je dato sledećim izrazom:

$$d_j - z_j = \sum_{l=1}^L [d_l - y_l] f'_o(net_l) w_{lj}. \quad (4.35)$$

Navedene jednačine za učenje se, takođe, mogu primeniti i na MFNN koji poseduje više od jednog skrivenog sloja i/ili mreže sa konekcijama koje preskaču jedan ili više slojeva. Sledi kompletna procedura korigovanja težinskih koeficijenata MFNN-a, za slučaj dvoslojne arhitekture mreže, koja je prikazana na Sl. 4.9. Navedena procedura učenja je naznačena kao inkrementalno EBP pravilo učenja.

1. Inicijalizacija svih težinskih koeficijenata u mreži (trenutne vrednosti koeficijenata w_{lj}^c i w_{ji}^c).
2. Zadavanje vrednosti stope učenja; potrebno je da su ρ_o i ρ_h male, pozitivne vrednosti.
3. Selekcija ulaznog signala, odnosno vektora $\mathbf{x}^k$ iz trening skupa (poželjna je nasumična selekcija) i propagacija signala kroz mrežu; u zavisnosti od trenutnog

skupa težinskih koeficijenata mreže vrši se generisanje izlaza jedinica skrivenog i izlaznog sloja.

4. Proračun korekcije težinskih koeficijenata izlaznog sloja mreže Δw_{lj} pomoću željenog cilja d^k koji odgovara ulaznom signalu x^k i jednačine (4.15).
5. Proračun korekcije težinskih koeficijenata skrivenog sloja mreže Δw_{ji} pomoću jednačine (4.34). Najčešće se u ovim proračunima koriste trenutne vrednosti težinskih koeficijenata mreže. Međutim, veća korekcija greške može se postići primenom korigovanih vrednosti težinskih koeficijenata izlaznog sloja mreže w_{lj} . Rezultat primenjenog postupka su ponovni proračuni vrednosti y_l i $f_o'(net)$.
6. Korekcija svih težinskih koeficijenata mreže na nove vrednosti $w_{lj}^{new} = w_{lj}^c + \Delta w_{lj}$ i $w_{ji}^{new} = w_{ji}^c + \Delta w_{ji}$ koje odgovaraju izlaznom i skrivenom sloju, respektivno.
7. Testiranje konvergencije. Test se sprovodi propagacijom prethodno izabranog signala i proverom da li je vrednost izlazne greške ispod definisanog praga. Ako je vrednost izlazne greške ispod definisanog praga, treniranje se zaustavlja; u suprotnom slučaju, težinski koeficijenti mreže uzimaju vrednosti $w_{ji}^c = w_{ji}^{new}$ i $w_{lj}^c = w_{lj}^{new}$, i sledi prelazak na korak 3. Bitno je napomenuti da postoji mogućnost da EBP ne pronade optimalno rešenje koje prolazi test konvergencije. U tom slučaju, treba pokušati sa reinicijalizacijom procesa pretrage, podešavanjem novih parametara učenja, i/ili promeniti strukturu neuralne mreže, odnosno dodati nove jedinice u skriveni sloj mreže.

Navedena procedura se zasniva na inkrementalnom učenju (*incremental learning*), što znači da se težinski koeficijenti mreže koriguju posle svakog učitavanja ulaznog vektora. Alternativa inkrementalnom učenju je grupno učenje (*batch learning*) pri kojem se primenjuje korekcija težinskih koeficijenata posle učitavanja svih ulaznih vektora (sa pretpostavkom da je trening skup konačan). Grupno učenje se formalno dobija sumiranjem desnih strana jednačina (4.26) i (4.34) nad svim ulaznim signalima x^k , što je, zapravo, predstavljeno kao:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{k=1}^m \sum_{l=1}^L (d_l - y_l)^2. \quad (4.36)$$

Premda grupna korekcija težinskih koeficijenata svakim korakom pomera tačku pretrage $\mathbf{w}$ u ispravnom smeru, primena inkrementalnog korigovanja je poželjnija iz dva razloga: (1) zahteva se manja količina memorije, i (2) sama putanja pretrage u prostoru težinskih koeficijenata je stohastičke prirode (u ovom slučaju se, tokom svakog koraka, ulazni vektor x nasumično bira) čime je omogućena temeljnija pretraga definisanog prostora, što potencijalno vodi do rešenja boljeg kvaliteta. Sa druge strane, jedna od mana je da pomoću EBP pravila težinski koeficijenti konvergiraju ka lokalnom minimumu (a ne ka globalnom minimumu) kriterijumske funkcije, što je karakteristično za svako pravilo učenja koje je *gradient-descent* karaktera u slučaju nekonvexnih površina pretrage. Primenom stohastičke aproksimacione teorije, Finof (*Finnoff*) [24] je pokazao da se za veoma male vrednosti stope učenja (koje se približavaju nuli) inkrementalni EBP približava grupnom pravilu, što pokazuju jako slični rezultati treniranja. Međutim, za male konstantne vrednosti stope učenja postoji stohastički element u trening procesu koji obezbeđuje da inkrementalni EBP izbegne lokalne minimume manjih dimenzija. Problem lokalnog minimuma se može dalje tretirati


dodavanjem šuma težinskim koeficijentima mreže ili ulaznim signalima/vektorima. U oba slučaja, mora se primeniti dinamička redukcija šuma, koja, kako učenje napreduje, smanjuje nivo šuma.

Generalno govoreći, treniranje neuralnih mreža primenom EBP pravila je vremenski zahtevno. Razlog ovome leži u karakteristikama kriterijumske površine definisane greškom (*error surface*). Ova površina je najčešće okarakterisana velikim brojem ravnih i strmih segmenata. Navedene karakteristike dolaze do izražaja kada je reč o problemima klasifikacije, a posebno kada ne postoji dovoljno veliki skup trening podataka. Predložena su brojna poboljšanja i varijacije EBP pravila. Ovo su najčešće heurističke modifikacije radi povećanja brzine konvergencije, izbegavanja lokalnog minimuma, i/ili radi poboljšanja generalizacionih sposobnosti mreže.

4.3.2. KROS-VALIDACIONA PROCEDURA

Sposobnost neuralne mreže da generalizuje, odnosno ponašanje ANN-a nad podacima koji nisu korišćeni za trening proces, procenjuje se greškom validacije (generalizacije). Postoji mogućnost da generalizacione sposobnosti mreže nisu zadovoljavajuće, iako je greška trening skupa ispod definisanog praga. Ovo može biti posledica pojave “prekomernog treniranja” do koje dolazi, na primer, u slučaju predugačkog trening procesa nad podacima za koje je karakterističan šum. Drugim rečima, primenom EBP pravila za treniranje MFNN-a nad takvim podacima, greška validacije se monotonno smanjuje do minimuma, a zatim raste, iako greška trening podataka nastavlja da opada (u trenutku kada ANN počne da ekstrahuje prisutni šum, a “zaboravlja” relevantne karakteristike datog skupa podataka). Opisani fenomen je prikazan na Sl. 4.10.

Pogodna strategija u cilju poboljšanja generalizacije veštačkih neuralnih mreža je da se izbegne “prekomerno treniranje” pažljivim posmatranjem evolucije validacione greške tokom treniranja i zaustavljanjem trening procesa pre nego što validaciona greška počne da raste. Navedena strategija je poznatija kao kros-validacija [4] (pp. 226-230). U ovom slučaju, ceo skup dostupnih podataka podeljen je na tri dela: trening skup, validacioni skup, i predikcioni skup koga čine test podaci. Trening skup se koristi za određivanje vrednosti težinskih koeficijenata neuralne mreže. Validacioni skup se koristi radi odluke kada je potrebno zaustaviti treniranje. Trening se nastavlja sve dok se performansa na validacionom skupu podataka poboljšava. Kada ona prestane da se poboljšava treniranje se zaustavlja. Treći deo podataka, predikcioni skup, se koristi za estimaciju očekivane performanse (generalizacije) trenirane mreže nad novim podacima. Takođe, predikcioni skup se ne koristi za validaciju tokom faze treniranja. Bitno je napomenuti da su za opisani metod treniranja mreže poželjne aplikacije sa velikim brojem dostupnih podataka. U slučaju aplikacija sa nedovoljnim brojem dostupnih podataka, primena kros-korelacionog postupka najčešće ne daje zadovoljavajuće rezultate.



Sl. 4.10. Primer progresije trening i validacione greške prilikom treniranja MFNN-a primenom EBP pravila.

5. SIMULACIJA KRATKOTRAJNOG FEDINGA

Rezime. Nova metoda simulacije kratkotrajnog fedinga je opisana u ovoj glavi. Predloženo rešenje se bazira na principima veštačkih neuralnih mreža. U cilju prikupljanja odgovarajućeg skupa trening podataka, sprovedena su merenja jačine električnog polja u odabranom indoor okruženju. Radi kvalitativne procene i verifikacije predložene metode, izvršeno je poređenje sa postojećim simulacionim metodama Rejljevog fedinga. Statistička analiza kratkotrajnog fedinga generisanog predloženom metodom pokazala je bolje slaganje sa merenjima u poređenju sa ostalim analiziranim metodama.

Karakteristika bežičnog komunikacionog sistema da signal na prijemu gubi svoje determinističke osobine i postaje slučajan u vremenskom i prostornom domenu opisuje se pojmom fedinga. Zapravo, signal na prijemu je rezultat uticaja dugotrajnog (*long-term*), odnosno sporog, i kratkotrajnog (*short-term*), odnosno brzog fedinga [1]. Dugotrajni feding odgovara lokalno usrednjenoj snazi električnog polja i u najvećoj meri je prouzrokovan okruženjem između predajnika i prijemnika. Sa druge strane, kratkotrajni feding je najčešće prouzrokovan *multipath* refleksijama. U praksi je nemoguće predvideti fluktuacije kratkotrajnog fedinga oslanjajući se samo na pravila fizičke propagacije signala.

Simulatori kratkotrajnog fedinga su od velike važnosti zbog ključne uloge u procenjivanju performansi bežičnih komunikacionih sistema. Stoga je simulacija kratkotrajnog fedinga od teorijskog i praktičnog interesa već duži niz godina. U cilju simulacije bežičnog radio kanala mobilnog komunikacionog sistema obično se pretpostavlja da kratkotrajni feding podleže Rejljevoj statističkoj raspodeli. Do danas je za generisanje Rejljevog fedinga predložen veći broj simulacionih metoda koje se baziraju ili na metodi sume sinusoida (*Sum-of-Sinusoids* - SoS) [9], [25]-[31], na algoritmu inverzne diskretne Furijeove transformacije (*Inverse Discrete Fourier Transform* - IDFT) [32], [33] ili na filtriranju belog Gausovog šuma [34]-[42]. Ako bi neograničeni računarski resursi bili dostupni, dve od spomenutih metoda bi mogle da generišu "idealni" Rejljev feding. Ovo je slučaj sa SoS metodom sa beskonačno velikim brojem oscilatora, kao i sa metodom WGN filtriranja sa beskonačnim redom autoregresivnog (*Autoregressive* - AR) filtra. Bitno je naglasiti da su sve spomenute metode razvijene i testirane naspram teorijskih parametara

kratkotrajnog fedinga [2] (pp. 70-82), definisanih u okviru Glave 3, ali ne i naspram podataka prikupljenih realnim merenjima.

U okviru ove glave predložena je nova metoda za simulaciju kratkotrajnog fedinga koja se bazira na principima veštačkih neuralnih mreža (ANN). Suprotno postojećim simulatorima koji su optimizovani isključivo nad teorijskim karakteristikama kratkotrajnog fedinga, predloženi feding simulator je treniran nad mernim podacima koji su dobijeni u realnom komunikacionom sistemu. Cilj je bio simulacija kratkotrajnog fedinga, tačnije anvelope fedinga koja je izdvojena iz prijemnog signala. Osnovni koncept predložene metode je estimacija naredne vrednosti kratkotrajnog fedinga propagacijom prethodnih sukcesivnih vrednosti fedinga kroz ANN. Zarad prikupljanja vrednosti kratkotrajnog fedinga, sprovedena su merenja jačine električnog polja u *indoor* okruženju, bez direktne vidljivosti predajnika i prijemnika, odnosno u NLoS scenariju. Vrednosti kratkotrajnog fedinga izdvojene iz jačine prijemnog električnog polja su korišćene za ANN treniranje i validacionu proceduru. Radi odgovarajuće validacije predložene simulacione metode implementiran je veći broj simulacionih metoda koje su predložene u literaturi [9], [28], [33], [40]. Poređenjem performansi nove metode zasnovane na ANN-u i postojećih metoda u odnosu na karakteristike kratkotrajnog fedinga koje su uočene u mernim podacima, naglašene su prednosti i mane svake metode ponaosob. Zbog kompletnosti, sve simulacione metode su upoređene, takođe, sa teorijskim karakteristikama Rejljevog fedinga [2] (pp. 70-82). Prema dobijenim rezultatima, predložena ANN metoda je pokazala određene prednosti u odnosu na druge simulacione metode.

Nastavak ove glave je organizovan tako što su, najpre, u Poglavlju 5.1 ukratko analizirani postojeći simulatori Rejljevog fedinga. Zatim je u Poglavlju 5.2 opisana merna procedura i obrada snimljenih podataka. Poglavlje 5.3 detaljno razmatra model predloženog feding simulatora koji se zasniva na ANN-u. Koncept vodećeg signala je uveden u okviru Poglavlja 5.4. Dalje, u Poglavlju 5.5, opisane su ANN trening i validacione procedure. Verifikacija predloženog simulatora u pogledu poređenja performansi sa postojećim simulatorima Rejljevog fedinga data je u okviru Poglavlja 5.6. Relevantni zaključci su izneti u Poglavlju 5.7.

5.1. POSTOJEĆE METODE SIMULIRANJA REJLIJEVOG FEDINGA

Do danas je predložen veći broj metoda za simulaciju Rejljevog fedinga. U nastavku poglavlja, opisano je nekoliko postojećih metoda simuliranja Rejljevog fedinga koje se trenutno smatraju najpopularnijim i najefikasnijim metodama.

5.1.1. METODA BAZIRANA NA SUMI SINUSOIDA

Jedan od načina modelovanja Rejljevog fedinga, koji se bazira na Klarkovom dvodimenzionalnom izotropnom modelu [16], jeste superponiranje izlaza nekoliko generatora sinusoida. Zapravo, metodu sume sinusoida je inicijalno predložio Džejk (*Jake*) u okviru [9]. Prema ovoj tzv. klasičnoj Džejkovoj metodi, ako je broj oscilatora (generatora sinusoida) N

oblika $4M+2$, gde je M prirodan broj, kompleksni oblik talasne forme Rejljevog fedinga može se modelovati u zavisnosti od vremena t kao:

$$x(t) = \frac{2}{\sqrt{N}} \left[2 \sum_{k=1}^M e^{j\beta_k} \cos 2\pi f_k t + \sqrt{2} e^{j\alpha} \cos 2\pi f_m t \right], \quad (5.1)$$

gde je $f_k = f_m \cos((2\pi k) / N)$ i f_m maksimalna Doplerova frekvencija izražena u Hz. Sa druge strane, α i β_k predstavljaju proizvoljne parametre. Uz pretpostavku da je $\alpha = 0$ i $\beta_k = (\pi k) / M$, može se obezbediti da komponente u fazi i kvadraturi generisanog Rejljevog fedinga nisu korelisane i da imaju identične autokorelacione funkcije [10] (pp. 81-85). Međutim, može se primetiti da u modelu nema slučajnih promenljivih kad se jednom vrednosti parametara izaberu, što znači da se radi o determinističkom modelu. Zbog toga, primenom ove metode, svaki generisani proces Rejljevog fedinga biće isti. Takođe, pokazano je u [25] da klasični Džejkov simulator nije stacionaran u širem smislu (*Wide-Sense Stationary* - WSS) kada se izvrši usrednjavanje ansambla feding kanala.

Druga često korišćena SoS metoda je WSS-poboljšani Džejkov model [28]. Prema ovoj metodi, normalizovani *low-pass* diskretni feding proces generiše se prema izrazu:

$$x(t) = x_I(t) + jx_Q(t), \quad (5.2)$$

$$x_I(t) = \sqrt{\frac{2}{N}} \sum_{k=1}^N \cos(2\pi f_m t \cos \alpha_k + \phi_k), \quad (5.3)$$

$$x_Q(t) = \sqrt{\frac{2}{N}} \sum_{k=1}^N \cos(2\pi f_m t \sin \alpha_k + \phi_k), \quad (5.4)$$

gde važi da je $\alpha_k = (2\pi k - \pi + \theta) / (4N)$, $k = 1, 2, \dots, N$, i gde su θ i fazni pomeraji ϕ_k , ϕ_k statistički nezavisni i uniformno distribuirani u intervalu $[-\pi, \pi)$ za bilo koju vrednost t . Ako se broj oscilatora poveća i približi beskonačnosti, statističke osobine $x(t)$ se asimptotski približavaju osobinama Klarkovog izotropnog modela [16]. Štaviše, veoma dobra aproksimacija teorijskog Rejljevog fedinga može se dobiti za N koje nije manji od 8 [28]. Međutim, za konačno veliki broj N , WSS feding simulator nije autokorelaciono ergodičan, odnosno usrednjene autokorelacione karakteristike u beskonačnom vremenskom intervalu su slučajne vrednosti [43].

5.1.2. METODA BAZIRANA NA IDFT OPERACIJI

Metoda koja se bazira na IDFT operaciji predstavlja jedan od kvalitetnih i efikasnih generatora kratkotrajnog fedinga [33]. Prema ovoj metodi, neophodno je, najpre, generisati kompleksni Gausov šum sa srednjom vrednošću 0, $A(k)+jB(k)$, sa realnom i kompleksnom komponentom koje su uzajamno nezavisne i identično distribuirane [44] (p. 140). Ovaj kompleksni vektor je dalje multipliciran vektorom realnih vrednosti koji, zapravo, predstavlja vektor koeficijenata filtra $F(k)$. Konačno, IDFT operacija rezultujućeg vektora daje željeni kompleksni proces kratkotrajnog fedinga, $x(n)$, $n = 0, 1, \dots, N-1$:

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} F(k) (A(k) + jB(k)) e^{j(\frac{2\pi kn}{N})}, \quad (5.5)$$

Vrednosti koeficijenata filtra $F(k)$ određuju karakteristike generisanog procesa. Da bi se generisao željeni Rejljev feding, sekvenca koeficijenata filtra data je kao:

$$F(k) = \begin{cases} 0, & k = 0 \\ \sqrt{1 / \left(2 \sqrt{1 - \left(\frac{k}{N f_d} \right)^2} \right)}, & k = 1, 2, \dots, k_d - 1 \\ \sqrt{\frac{k_d}{2} \left[\frac{\pi}{2} - \arctan \left(\frac{k_d - 1}{\sqrt{2k_d - 1}} \right) \right]}, & k = k_d \\ 0, & k = k_d + 1, \dots, N - k_d - 1 \\ \sqrt{\frac{k_d}{2} \left[\frac{\pi}{2} - \arctan \left(\frac{k_d - 1}{\sqrt{2k_d - 1}} \right) \right]}, & k = N - k_d \\ \sqrt{1 / \left(2 \sqrt{1 - \left(\frac{N - k}{N f_d} \right)^2} \right)}, & k = N - k_d + 1, \dots, N - 2, N - 1 \end{cases}, \quad (5.6)$$

gde je $k_d = \lfloor N f_d \rfloor$, a $f_d = f_m / f_s$ predstavlja maksimalnu Doplerovu frekvenciju normalizovanu učestanošću odabiranja.

Opisani algoritam je, zapravo, inicijalna metoda [32] modifikovana kao u okviru [33]. Modifikovana metoda je superiornija u odnosu na inicijalnu u tome što se zahteva tačno upola manji broj IDFT operacija i za trećinu manja memorija za generisanje sekvenci identičnih statističkih karakteristika. Nažalost, pošto se sve potrebne vrednosti fedinga generišu u okviru jedne IDFT operacije, ova metoda nije najprikladnija za potrebe generisanja veoma dugačkih sekvenci kratkotrajnog fedinga.

5.1.3. METODA BAZIRANA NA WGN FILTRIRANJU

Korelisane vrednosti Rejljevog fedinga se mogu generisati filtriranjem kompleksnog WGN signala. Drugim rečima, ovo se svodi na filtriranje dva nezavisna WGN procesa srednje vrednosti 0, a zatim na sabiranje filtriranih procesa u kvadraturi radi formiranja Rejljevog fedinga. Da bi se aproksimirala željena gustina spektralne snage ili ACF, mora se uzeti u obzir odgovarajući dizajn filtra. Prva od dve popularne metode WGN filtriranja zasniva se na *low-pass* (LP) filtru beskonačnog impulsnog odziva (*Infinite-Impulse Response* - IIR) koji se koristi u cilju aproksimacije željenih autokorelacionih karakteristika [45]. Postoje različita rešenja za konstrukciju filtra. Između ostalog, utvrđeno je da Batervortov (*Butterworth*) filter trećeg reda daje zadovoljavajuću aproksimaciju željenih autokorelacionih karakteristika [34], [36]. Stoga je ova metoda u literaturi najčešće implementirana pomoću LP IIR filtra trećeg reda:

$$H(s) = \frac{\omega_0^3}{(s + \omega_0)(s^2 + 2\xi\omega_0 s + \omega_0^2)}, \quad (5.7)$$

gde izbor parametara ω_0 i ξ ima veliki uticaj na karakteristike filtra, a posledično i na generisani feding proces. Takođe, treba imati na umu da primena metoda koje se zasnivaju na WGN filtriranju u praksi zahteva i fazu inicijalizacije u okviru koje je neophodno pokrenuti proces filtriranja u cilju ulaska u stacionarni režim rezultujućeg signala [46].

Druga, često korišćena metoda, zasniva se na filtriranju kompleksnog WGN-a autoregresivnim filtrom [40]. Prednosti ove metode su u jednostavnosti proračuna njenih parametara i u kvalitetnoj aproksimaciji korelacionih karakteristika signala. Zapravo, ova tehnika koristi IIR filtriranje nekorelisanih Gausovih vrednosti u cilju oblikovanja spektra rezultujućeg signala. Za razliku od prethodno opisane metode filtriranja WGN signala, u ovom slučaju moguća je precizna aproksimacija teorijskih statističkih karakteristika generisanog signala povećanjem reda filtra, što sa druge strane komplikuje implementaciju metode. Zapravo, AR filtri reda p se mogu dizajnirati tako da reprodukuju bilo koju ACF funkciju u prvih p tačaka. Veza između željene autokorelacije $R_{XX}[k]$ i AR parametara, $a_1, a_2, \dots, a_p$, je sledeća [47]:

$$R_{XX}[k] = \begin{cases} -\sum_{m=1}^p a_m R_{XX}[k-m], & k \geq 1 \\ -\sum_{m=1}^p a_m R_{XX}[-m] + \sigma_p^2, & k = 0. \end{cases} \quad (5.8)$$

U formi matrica ovo postaje za $k = 1, 2, \dots, p$:

$$\mathbf{R}_{XX} \mathbf{a} = -\mathbf{v}, \quad (5.9)$$

gde je

$$\mathbf{R}_{XX} = \begin{bmatrix} R_{XX}[0] & R_{XX}[-1] & \dots & R_{XX}[-p+1] \\ R_{XX}[1] & R_{XX}[0] & \dots & R_{XX}[-p+2] \\ \vdots & \vdots & \ddots & \vdots \\ R_{XX}[p-1] & R_{XX}[p-2] & \dots & R_{XX}[0] \end{bmatrix}, \quad (5.10)$$

$$\mathbf{a} = [a_1 \ a_2 \ \dots \ a_p]^T, \quad (5.11)$$

$$\mathbf{v} = [R_{XX}[1] \ R_{XX}[2] \ \dots \ R_{XX}[p]]^T, \quad (5.12)$$


sa varijansom WGN-a:

$$\sigma_p^2 = R_{xx}[0] + \sum_{k=1}^p a_k R_{xx}[-k]. \quad (5.13)$$


Na osnovu zadate željene sekvence autokorelacione funkcije, koeficijenti AR filtra $\mathbf{a}$ mogu se odrediti rešavanjem skupa od p Jul-Vokerovih (*Yule-Walker*) jednačina datih u (5.9). Za AR modele velikog reda, data jednačina teži da ima polove izvan jediničnog kruga što model filtra čini nestabilnim. Ovaj problem se može rešiti dodavanjem dijagonalnog pomeraja, na osnovu čega se modifikovana autokorelaciona matrica $\tilde{\mathbf{R}}_{xx} = \mathbf{R}_{xx} + \gamma \mathbf{I}$ koristi u (5.9). Pomeraj γ predstavlja pogodan parametar koji obezbeđuje stabilnost filtra i bira se kao najmanja vrednost koja stabilizuje filter.

5.2. PRIKUPLJANJE I OBRADA MERNIH PODATAKA

Da bi se prikupili podaci o jačini električnog polja na prijemu, sprovedena su NLoS merenja u odabranom *indoor* okruženju. Zgrada Elektrotehničkog fakulteta u Beogradu (prikazana na Sl. 5.1) je odabrana kao merno okruženje zbog kompleksne infrastrukture koja je okarakterisana visokom dinamikom jačine električnog polja (preko 80dB). Sa omnidirekacione antene povezane na stacionarni predajnik Motorola MC Micro emitovan je nemodulisan CW RF (*Carrier-Wave Radio Frequency*) nosioc na frekvenciji od $f_c = 457\text{MHz}$ izlazne snage 25W. Sa druge strane, merna oprema na prijemnoj strani je instalirana na pokretna kolica koja se kreću kroz odabrano *indoor* okruženje konstantnom brzinom od $V = 0.2\text{m/s}$. Kalibrisana polu-talasna dipol antena Anritsu MP663A, vertikalne polarizacije, je povezana na Rohde&Schwarz ESPI test prijemnik (9kHz-7GHz). ESPI prijemnik je podešen da snima vrednosti jačine električnog polja sa periodom odabiranja $t_s = 25\text{ms}$. Kretanjem prijemne merne opreme duž predefinisane putanje, označene zelenom bojom na Sl. 5.1, pređena je ukupna distanca od 720m. Odabir putanje prijemnih antena je analiziran u Sekciji 5.2.2.



Sl. 5.1. Merno okruženje (tlocrt Elektrotehničkog fakulteta u Beogradu).




Sl. 5.2. Signal na prijemu i dugotrajni feding (merna kampanja).

Na Sl. 5.2 je prikazan izgled vremenskih promena snimljenog nivoa električnog polja tokom merne kampanje, kao i odgovarajuće dugotrajne promene. Na priloženom grafiku mogu se uočiti povremeni duboki padovi nivoa električnog polja na prijemu. Na osnovu prikupljenih mernih podataka proračunata je anvelopa kratkotrajnog fedinga koja je prikazana na Sl. 5.3. Sa slike se može uočiti kvazi-periodična priroda kratkotrajnih fluktuacija intenziteta električnog polja na prijemu. Dobijena anvelopa fedinga je kasnije korišćena

delom za ANN treniranje, ali takođe, delom i kao referentna sekvenca fedinga za verifikaciju performansi predložene metode.

Na osnovu prethodnih eksperimentalnih simulacija i optimizacije simulatora nad podacima dobijenim većom periodom odabiranja $t_s = 100\text{ms}$, zaključeno je da su skupovi podataka značajno većih dimenzija neophodni radi precizne verifikacije predložene metode i populacije mera kvaliteta zasnovanih na gustini verovatnoće. Iz tog razloga, da bi se prikupila dovoljno dugačka sekvenca feding procesa, visoke rezolucije, usvojena je perioda odabiranja $t_s = 25\text{ms}$ tokom merne kampanje odgovarajućeg trajanja. Merni podaci dobijeni na taj način su dodatno imali uticaj na ukupni broj neurona ANN-a, kao i na dimenzije ulaznog vektora zahvaljujući korelacionim karakteristikama merne sekvence fedinga, što će biti opisano u nastavku poglavlja.



Sl. 5.3. Segment anvelope kratkotrajnog fedinga (merna kampanja).

5.2.1. EKSTRAKCIJA ANVELOPE KRATKOTRAJNOG FEDINGA

Nad izmerenim vrednostima jačine električnog polja sprovedena je odgovarajuća obrada u cilju ekstrakcije anvelope kratkotrajnog fedinga. Najpre, neophodno je bilo odrediti vrednosti dugotrajnog fedinga usrednjavanjem prijemnog signala pomoću adekvatno izabranog prostornog intervala, tzv. prozora [1]. Ako je jačina električnog polja prijemnog signala označena $r(t)$, dugotrajni feding $l(t)$ u vremenskom momentu $t_i = it_s$ je definisan sa:

$$l(t_i) = \frac{1}{W} \sum_{k=i-\frac{W}{2}}^{i+\frac{W}{2}} r(t_k), \quad (5.14)$$

gde W predstavlja dužinu prozora za usrednjavanje. Određivanje odgovarajuće dužine prozora je od velike važnosti. Na primer, ako su merenja sprovedena u *outdoor* okruženju, optimalni opseg dužine prozora prema literaturi je $20-40\lambda$ [48] (pp. 662-663). Međutim, pošto su merni podaci dobijeni u *indoor* okruženju, dužina prozora koja više odgovara ovom slučaju je u opsegu $4-10\lambda$, kao što je to i predloženo u [49], [50]. Zbog toga je usvojeno da se proces usrednjavanja sprovede u prostornom intervalu od 10λ . Kao rezultat odvajanja dugotrajnog fedinga iz prijemnog signala, dobijene su kratkotrajne varijacije intenziteta električnog polja $x(t)$:

$$x(t) = r(t) - l(t). \quad (5.15)$$

Na opisani način je dobijena sekvenca od 2^{17} odbiraka anvelope kratkotrajnog fedinga. Zbog sažetosti, u nastavku doktorske disertacije pod pojmom fedinga podrazumevaće se koncept kratkotrajnog fedinga.

5.2.2. KARAKTERISTIKE EKSTRAHOVANE ANVELOPE FEDINGA


Rajsov K-faktor [2] (eq. (3.36)), kao jedan od relevantnih parametara radio kanala, je proračunat za snimljeni feding proces pomoću jednostavnog estimatora koji se zasniva na statističkim momentima datog uzorka [51] (eq. (3)). Ovim pristupom analiziran je Rajsov K-faktor signala snimljenog na putanji koja je označena plavom bojom na Sl. 5.1. Tipične vrednosti Rajsovog K-faktora, eksperimentalno dobijene u različitim okruženjima, su publikovane u [52] (pp. 108-110). Imajući u vidu da su merenja sprovedena u NLoS scenariju, prema [52] feding proces se može modelovati kao Rejljev proces ako je Rajsov K-faktor manji od 3dB. Analizom dobijenih rezultata je zaključeno da je deonica označena zelenom bojom na Sl. 5.1 okarakterisana Rejljevim fedingom. Tačnije, Rajsov K-faktor signala ove deonice, posmatran unutar prozora dužine 10λ , bio je u opsegu između -32.74 i 6.15dB, a manji od 3dB u preko 95% slučajeva. U cilju poređenja sa prethodno opisanim simulatorima Rejljevog fedinga, merni podaci snimljeni na ovoj deonici su korišćeni za optimizaciju predloženog simulatora.

Imajući u vidu korelacione karakteristike anvelope fedinga, osnovna ideja predložene metode je procena naredne vrednosti fedinga na osnovu vrednosti fedinga koje joj prethode. Radi uvida u korelacione karakteristike feding procesa, analiziran je ACF dobijene anvelope fedinga. ACF je proračunat kao skup autokorelacionih koeficijenata prema [53] (eq. (2.6)):

$$R_{xx}(k) = \frac{\sum_{i=1}^{N-k} (x(t_i) - \bar{x})(x(t_{i+k}) - \bar{x})}{\sum_{i=1}^N (x(t_i) - \bar{x})^2}, \quad (5.16)$$

gde N predstavlja dužinu analiziranog signala, $\bar{x}$ srednju vrednost signala, a $R_{xx}(k)$ odgovarajući autokorelacioni koeficijent. ACF anvelope izmerenog kratkotrajnog fedinga je prikazan na Sl. 5.4. Zapravo, broj korelisanih odbiraka fedinga je određen kao broj odbiraka za koji je potrebno zakasniti analizirani uzorak da bi ACF pao ispod određenog praga po prvi


put. Usvajanjem da je prag autokorelaciona vrednost 0.2 [5] (p. 49), kao što je prikazano na Sl. 5.4, određeno je da je broj korelisanih odbiraka feding procesa 47, što odgovara prostornom intervalu od 0.36λ .



Sl. 5.4. ACF anvelope kratkotrajnog fedinga.

5.3. OPŠTI MODEL ANN SIMULATORA

Opšti model simulatora koji se bazira na veštačkim neuralnim mrežama je prikazan na Sl. 5.5. Predloženi model se zasniva na neuralnoj mreži treniranoj nad vrednostima fedinga koje su prikupljene merenjima u *indoor* okruženju. Osnovna ideja predložene metode je estimacija naredne feding vrednosti propagacijom L sukcesivnih prethodnih feding vrednosti kroz ANN. Da bi se izbegao ulazak izlaznog ANN signala u stacionarno stanje, uveden je koncept vodećeg signala (DS). Zapravo, svrha DS-a je da odredi smer u kom ANN treba da generiše sledeću vrednost fedinga. Radi navođenja ANN-a kroz simulacioni proces, konstruisan je tzv. DS generator. Tačnije, DS generator je generisao odgovarajuće vrednosti vodećeg signala na osnovu statističkih karakteristika izmerenog feding procesa, što je detaljnije opisano u Poglavlju 5.4.



Sl. 5.5. ANN fading simulator ($x(t_n)$ – n -ta vrednost fedinga, $d(t_n)$ – n -ta DS vrednost).

Tokom inicijalizacije simulacionog procesa, DS generator proizvodi prvu vrednost koja zauzima poziciju poslednjeg elementa ulaznog ANN vektora. U isto vreme, na mesto ostalih elemenata ulaznog vektora postavljaju se nasumično odabrane vrednosti fedinga. Ulazni vektor se zatim propagira kroz ANN i generiše se sledeća vrednost fedinga. Na početku svake naredne iteracije, sekvenca fedinga u okviru ulaznog vektora se pomera na takav način da generisana fading vrednost iz prethodne iteracije zauzme mesto do ulaznog DS elementa. Zatim se pomoću DS generatora generiše nova DS vrednost. Ovo je praćeno propagacijom formiranog ulaznog vektora kroz ANN u cilju estimacije sledeće vrednosti fedinga. Vraćanjem generisane vrednosti sa izlaza neuralne mreže u ulazni vektor, primenjuje se, zapravo, model povratne sprege, predstavljen na Sl. 5.5. Iako je opisani model inspirisan dobro poznatim modelom (*Time-Delayed Neural Network* - TDNN) za estimaciju jednog odbirka unapred [4] (pp. 254-259), povratna sprega je zatvorena sa ciljem da se korelacione osobine izmerenog fading procesa prenesu na simuliranu sekvencu. Ponavljanjem opisane procedure generisana je odgovarajuća sekvenca vrednosti fedinga.

5.4. VODEĆI SIGNAL


Veći broj eksperimentalnih simulacija, sprovedenih nad ulaznim vektorima koji sadrže samo vrednosti fedinga, nije pokazao zadovoljavajući rezultat. Zapravo, generisani signal na izlazu neuralne mreže je pokazao karakteristike prigušenih oscilacija. Da bi se izbegao ulazak generisanog signala u stacionarno stanje uveden je DS element. Svrha DS vrednosti je navođenje simulacionog procesa, odnosno određivanje smera u kom ANN treba da generiše

sledeću vrednost. Stoga, DS može uzeti jedno od dva moguća stanja, -1 i +1, pri čemu pozitivna vrednost signala označava da se feding vrednost koju treba generisati nalazi na uzlaznoj strani anvelope fedinga. U suprotnom, negativna vrednost signala odgovara silaznoj strani anvelope fedinga. Drugim rečima, pozitivna vrednost označava da ANN treba da generiše sledeći odbirak feding procesa većeg nivoa električnog polja u poređenju sa vrednošću koja joj prethodi, dok negativna vrednost označava suprotno. Za navođenje ANN-a tokom treninga korišćen je odgovarajući DS ekstraktor. Tačnije, DS ekstraktor je korišćen u cilju ekstrakcije DS vrednosti iz anvelope fedinga dobijene merenjem. Sa druge strane, DS generator je implementiran za navođenje ANN-a kroz simulacioni proces.

5.4.1. EKSTRAKTOR VODEĆEG SIGNALA

Da bi se proračunala DS vrednost na osnovu datog uzorka fedinga, implementiran je DS ekstraktor koji je prikazan na Sl. 5.6. DS ekstraktor se sastoji iz dve komponente. Ulazna komponenta DS ekstraktora uzima dve susedne vrednosti fedinga i proračunava njihovu razliku:

$$\Delta x(t_n) = x(t_n) - x(t_{n-1}). \quad (5.17)$$




Sl. 5.6. Šematski prikaz DS ekstraktora ($x(t_n)$ – n -ta vrednost fedinga, $d(t_n)$ – n -ta DS vrednost).

Sa druge strane, funkcija prenosa izlazne komponente je signum (*sgn*) funkcija koja postavlja izlazni signal na vrednosti -1 ili +1, zavisno od znaka proračunate razlike:

$$d(t_n) = \text{sgn}(\Delta x(t_n)) = \begin{cases} 1, & \Delta x(t_n) \geq 0 \\ -1, & \Delta x(t_n) < 0 \end{cases} \quad (5.18)$$

Kao rezultat, generisana je DS vrednost na izlazu ekstraktora. Propuštanjem anvelope fedinga kroz ekstraktor dobija se odgovarajuća DS sekvenca (kao što je ilustrovano na Sl. 5.7). Sekvenca vrednosti ekstrahovana na takav način je korišćena za navođenje ANN-a tokom trening procesa.




Sl. 5.7. Ekstrakcija DS vrednosti.

5.4.2. GENERATOR VODEĆEG SIGNALA


Radi generisanja DS vrednosti tokom simulacionog procesa, implementiran je DS generator (prikazan na Sl. 5.8). Zapravo, generator je baziran na statističkim osobinama DS vrednosti koje su ekstrahovane iz anvelope fedinga dobijene merenjem. Ovo podrazumeva proračunavanje verovatnoće P_d da će vrednost -1 ili +1 biti generisana zavisno od DS vrednosti koje joj prethode [54] (eq. 5.2):

$$P_d(d(t_1), d(t_2), d(t_3), \dots, d(t_{n-2}), d(t_{n-1}) | d(t_n) = + / -1) = \frac{P(d(t_1), d(t_2), d(t_3), \dots, d(t_{n-2}), d(t_{n-1}), d(t_n) = + / -1)}{P(d(t_n) = + / -1)}, \quad (5.19)$$

gde $d(t_n)$ predstavlja DS vrednost u trenutku t_n . Drugim rečima, ovo je pitanje uslovne verovatnoće da će se negativni ili pozitivni nivo pojaviti na izlazu generatora nakon određene sekvence S susednih DS vrednosti [54] (eq. (5.2)). Najpre, neophodno je odrediti dužinu S sekvence DS vrednosti na osnovu koje će se vršiti estimacija naredne vrednosti. Ovo podrazumeva određivanje najvećeg broja S , takvog da svaka sekvenca od 2^S mogućih kombinacija vrednosti -1 i +1 postoji u okviru ekstrahovanog DS-a. Zapravo, proračun uslovnih verovatnoća se zasniva na broju pojavljivanja određene sekvence od S vrednosti u ekstrahovanom signalu. Stoga, ako određena sekvenca vrednosti ne postoji, onda se odgovarajuća uslovna verovatnoća za narednu vrednost ne može proračunati. Očigledno, ako broj S raste, broj mogućih sekvenci 2^S takođe raste, a u isto vreme raste i verovatnoća da određena kombinacija vrednosti ne postoji unutar ekstrahovanog DS-a. Imajući ovo na umu, utvrđeno je da proračun uslovnih verovatnoća treba izvršiti na osnovu sekvence od $S = 6$ susednih vrednosti. Zapravo, inicijalna ideja je bila da se broj S sukcesivnih vrednosti određuje na osnovu korelacionih karakteristika same ekstrahovane DS sekvence. Broj S je bio definisan kao broj korelisanih odbiraka DS-a i određen je na isti način kao i broj korelisanih odbiraka fedinga, što je i prethodno opisano u Sekciji 5.2.1. Broj korelisanih odbiraka DS-a je određen na osnovu autokorelacione funkcije DS-a, prikazane na Sl. 5.9, i iznosio je 11. Pošto proračun svih uslovnih verovatnoća u ovom slučaju nije bio moguć iz gore navedenih razloga, zaključeno je da pristup određivanju dužine sekvence koji se bazira na korelisanim DS vrednostima nije odgovarajući i zbog toga je napušten.



Sl. 5.8. Šematski prikaz DS generatora ($d(t_n)$ – n -ta DS vrednost).



Sl. 5.9. Autokorelaciona funkcija DS-a.

Analiziranjem ekstrahovanog DS-a, locirano je svako pojavljivanje određene sekvence od 6 uzastopnih vrednosti. Zapravo, izbrojano je koliko je puta nakon te određene sekvence sledila negativna, a koliko puta pozitivna vrednost. Odgovarajuća uslovna verovatnoća dobijena je deljenjem broja pojavljivanja negativnih, odnosno pozitivnih vrednosti ukupnim brojem pojavljivanja odgovarajuće DS sekvence. Uslovne verovatnoće izračunate na ovaj način za svaku od 2^6 mogućih kombinacija vrednosti su sačuvane u tzv. *lookup* tabeli u okviru DS generatora. Segment *lookup* tabele DS generatora za analizirani feding proces je prikazan u Tab. 5.1.


DS generator je implementiran sa memorijom koja čuva 6 poslednjih sukcesivnih DS vrednosti, tačnije $d(t_{n-6})$, $d(t_{n-5})$... $d(t_{n-1})$. Na početku procesa generisanja vrednosti, memorija se inicijalizuje nasumično izabranim vrednostima. Dodatno, DS generator je implementiran sa generatorom slučajnih vrednosti uniformne raspodele koji generiše slučajne brojeve u opsegu $[0, 1]$ u cilju uvođenja stohastike u proces odlučivanja da li treba generisati pozitivnu ili

negativnu vrednost. Zapravo, vrednost koja je dobijena primenom uniformnog generatora slučajnih brojeva se upoređuje klasičnom rulet metodom [55] (p. 189) sa uslovnom verovatnoćom uzetom iz *lookup* tabele za datu sekvencu vrednosti u memoriji. Zavisno od rezultata poređenja, generiše se negativna ili pozitivna DS vrednost. Generator slučajnih brojeva generiše vrednost u opsegu [0, 1], dok su uslovne verovatnoće proračunate za odgovarajuću sekvencu DS vrednosti predstavljene jednim od dva moguća segmenta unutar spomenutog opsega. Zavisno od segmenta u kom je generator slučajnih brojeva proizveo vrednost, generiše se odgovarajuća vrednost na izlazu DS generatora. Drugim rečima, ako je vrednost proizvedena od strane uniformnog generatora slučajnih brojeva veća od odgovarajuće uslovne verovatnoće, generisana će biti vrednost +1. Sa druge strane, ako je ova vrednost manja od iste uslovne verovatnoće, generisana će biti vrednost -1. Vrednosti unutar memorije se pomeraju na početku svake sledeće iteracije. Kao što se to može videti na Sl. 5.8, pomeranje se izvršava na takav način da generisana DS vrednost ulazi u memoriju dok poslednja vrednost sekvence DS-a izlazi iz nje. Sledeća DS vrednost se proračunava na osnovu nove sekvence koja je u memoriji. Ponavljanjem opisane procedure generisane su vrednosti DS-a tokom celokupnog simulacionog procesa.

Tab. 5.1. Segment DS lookup tabele.

d_{n-6}	d_{n-5}	d_{n-4}	d_{n-3}	d_{n-2}	d_{n-1}	$P_d(d_n=-1)$	$P_d(d_n=+1)$
-1	-1	-1	-1	-1	-1	0.9054	0.0946
-1	-1	-1	-1	-1	1	0.2462	0.7538
-1	-1	-1	-1	1	-1	0.8608	0.1392
-1	-1	-1	-1	1	1	0.2481	0.7519
⋮						⋮	
1	1	1	1	-1	1	0.1173	0.8827
1	1	1	1	1	-1	0.7289	0.2711
1	1	1	1	1	1	0.0921	0.9079

Na osnovu opisa procedure generisanja DS vrednosti može se zaključiti da DS generator predstavlja vid diskretnog Markovljevog (*Markov*) lanca [56] (pp. 213-304) (prikazanog na Sl. 5.10). Tačnije, stanje DS generatora, odnosno trenutna sekvenca DS vrednosti u memoriji, može se predstaviti stanjima Markovljevog lanca. Sa druge strane, veze između stanja Markovljevog lanca su predstavljene proračunatim uslovnim verovatnoćama prelaska iz trenutnog stanja DS generatora u sledeće. Stoga se može reći da je ANN kroz simulacionu proceduru navođen diskretnim Markovljevim procesom.




Sl. 5.10. Segment DS lookup tabele u formi Markovljevog lanca.

5.4.3. VALIDACIJA VODEĆEG SIGNALA

Radi uvida u performanse predloženog DS generatora, sprovedena je poredbeni analiza generisanih i DS vrednosti dobijenih na osnovu izmerenog feding procesa. Najpre je analizirana raspodela vremena koje DS provede na određenom nivou. Proračunata raspodela verovatnoće trajanja negativnog, odnosno pozitivnog nivoa DS-a, je prikazana na Sl. 5.11 za slučaj generisane i ekstrahovane DS sekvence.

Dodatno su proračunati statistički parametri kao što su verovatnoća pojavljivanja pozitivne, odnosno negativne DS vrednosti $P_{ds}(d=+/-1)$, i prosečno trajanje određenog DS nivoa $L_{ds}(d=+/-1)$. Tab. 5.2 prikazuje dobijene rezultate proračunate za ekstrahovani (DS^{ext}) i generisani vodeći signal (DS^{gen}).



Sl. 5.11. PDF trajanja (a) pozitivnog i (b) negativnog DS nivoa.

Tab. 5.2. DS statistički parametri.

	$P_{ds}(d = -1)$	$P_{ds}(d = +1)$	$L_{ds}(d = -1)$ [s]	$L_{ds}(d = +1)$ [s]
DS^{ext}	0.5018	0.4982	0.1555	0.1544
DS^{gen}	0.4907	0.5093	0.1507	0.1564

Na osnovu prikazanih rezultata može se zaključiti da su karakteristike generisanih i ekstrahovanih DS vrednosti u zadovoljavajućem slaganju. Ujedno je sprovedenom statističkom analizom izvršena i verifikacija primene DS generatora u cilju stohastičkog navođenja ANN-a tokom simulacione procedure.

5.5. OPTIMIZACIJA ANN SIMULATORA

Pošto je neuralna mreža odabrana da bude jezgro predloženog simulatora, neophodno je bilo odrediti tip i arhitekturu neuralne mreže koja će biti pogodna za izvršavanje datog zadatka, odnosno simuliranje odgovarajućeg feding procesa. Prema literaturi [4] (pp. 254-259), najuspešnije primenjen tip neuralne mreže u rešavanju problema predikcije signala je MFNN. Imajući na umu strukturu i funkciju koju treba veštačka neuralna mreža da izvršava, MFNN u kombinaciji sa nadgledanim učenjem, tačnije EBP algoritmom [4] (pp. 199-206), kao jednim od najčešće primenjivanih pravila učenja, je izabran kao pogodan za dati problem. U nastavku ovog poglavlja sledi opis kako je definisana arhitektura ANN-a, odnosno, šta su ulazi a šta izlazi mreže, kao i opis njene unutrašnje strukture.


5.5.1. ULAZI I IZLAZI NEURALNE MREŽE

Pitanje dimenzije ulaznog ANN vektora se svodi na određivanje broja sukcesivnih feding vrednosti na osnovu kojih će se vršiti estimacija naredne vrednosti fedinga. Uzimajući u obzir autokorelacione karakteristike fedinga, estimacija na osnovu prevelikog broja sukcesivnih feding vrednosti je nepotrebna i zahtevna sa aspekta kompjuterskih resursa. Zbog toga je u analizu uzet u obzir ACF anvelope fedinga koja je dobijena merenjem. Imajući ovo na umu, određeno je da broj vrednosti fedinga unutar ulaznog ANN vektora bude $L = 47$, pošto je ovo bio broj korelisanih feding odbiraka. Broj korelisanih odbiraka je određen procedurom koja je opisana u Sekciji 5.2.2. Tom prilikom, kao što je predloženo u [5] (p. 49) za donju granicu je uzeta vrednost autokorelacije 0.2. Vrednost DS-a je uzeta kao poslednja vrednost ulaznog ANN vektora. Kao što je već opisano, svrha ovog elementa je gruba navigacija simulirane vrednosti. Sa druge strane, činjenica da se u okviru jedne simulacione iteracije vrši estimacija jedne vrednosti fedinga, uslovljava da se izlazni sloj ANN-a sastoji iz jednog neurona.

5.5.2. UNUTRAŠNJA STRUKTURA NEURALNE MREŽE

MFNN podrazumeva mogućnost postojanja jednog ili više skrivenih slojeva ispred izlaznog sloja. Odabir unutrašnje strukture ANN-a predloženog simulatora podrazumeva

pitanje broja skrivenih slojeva, kao i broja neuronskih jedinica smeštenih unutar tih slojeva. Egzaktna metoda za određivanje optimalne unutrašnje strukture ANN-a ne postoji [4] (pp. 221-226). U literaturi su mogu naći algoritmi za redukciju suvišnih elemenata mreže [4]. Na osnovu ovih algoritama, polazeći od predimenzionisane mreže, dolazi se iterativno do jednostavnijeg rešenja. Zbog kompleksnosti takve procedure, prihvaćen je dobro poznati stav da se broj neurona svakog sledećeg skrivenog sloja smanjuje i konvergira ka broju neurona izlaznog sloja. Takođe, prihvaćeno je da se prvi skriveni sloj sastoji od većeg broja neurona u poređenju sa brojem elemenata ulaznog vektora, da bi se ulazna informacija kvantifikovala i grupisala u manje porcije [57]. Imajući ovo na umu, analizirane su potpuno povezane mreže sa jednim, dva, tri i četiri skrivena sloja. Poređenjem simulacionih rezultata sa anvelopom fedinaga dobijenom tokom merenja, izabrana je troslojna struktura ANN-a. Optimalna arhitektura mreže je prikazana na Sl. 5.12 i sastoji se od 100 neurona u prvom skrivenom sloju, 50 u drugom skrivenom sloju i od jednog izlaznog neurona. Dimenzije ANN-a su sa razlogom odabrane veće nego što je to neophodno. Zapravo, povećanjem broja težinskih koeficijenata ANN-a, povećan je takođe i broj lokalnih minimuma bliskih globalnom u kriterijumskom prostoru, što olakšava proces traženja globalnog minimuma [57]. Svi neuroni, kao na Sl. 4.7, su implementirani sa sigmoidalnom aktivacionom funkcijom (bipolarna funkcija tipa tangensa hiperboličkog), osim izlaznog neurona koji je implementiran sa linearnom aktivacionom funkcijom.




Sl. 5.12. Arhitektura implementirane neuralne mreže.

5.5.3. TRENING I VALIDACIONI PROCES

Na osnovu izloženih principa nadgledanog učenja u okviru Sekcije 4.3.1, tačnije EBP pravila, sprovedena je i optimizacija neuralne mreže predloženog feding simulatora. Polovina odbiraka anvelope fedinga dobijene merenjem je korišćena kao skup trening podataka. Trening podaci su najpre normalizovani na interval $[-1, +1]$ prema konvencionalnoj trening proceduri [4]. Ulazni ANN vektor se sastojao iz odbiraka anvelope fedinga i ekstrahovane DS vrednosti. Povratna sprega modela prikazanog na Sl. 5.5 je raskinuta za potrebe treninga, a umesto DS generatora korišćen je DS ekstraktor. ANN težinski koeficijenti su inicijalizovani prema Engajen-Vidrov (*Nguyen-Widrow*) inicijalizacionom algoritmu [58]. Ovaj algoritam vrši odabir inicijalnih vrednosti koeficijenata tako da je aktivna oblast svakog neurona približno ravnomerno distribuirana po ulaznom prostoru odgovarajućeg sloja. Kao što je napomenuto, algoritam propagacije greške unazad je izabran za trening metodu. Ulazna sekvenca vrednosti fedinga i odgovarajuća ciljna vrednost fedinga su birani na slučajan način iz skupa podataka koji se sastojao od 2^{16} feding vrednosti. Trening proces je sproveden primenom inkrementalnog učenja, što znači da su težinski koeficijenti korigovani nakon obrade svakog slučajno biranog ulazno/izlaznog vektorskog para. Stopa učenja od 0.01 je držana konstantnom tokom celokupne trening procedure. Ona je namerno odabrana kao dovoljno mala vrednost da bi se izbegle oscilacije oko minimuma kriterijumske funkcije po cenu brzine kovergencije [4]. Trening proces je zaustavljen nakon 1000 trening krugova od kojih je svaki trening krug ponaosob analiziran radi evaluacije performansi ANN simulatora.

Istovremeno, pored treninga, sproveden je i validacioni proces da bi se izbegli eventualni problemi prekomernog treniranja i da bi se dobio uvid u generalizacione karakteristike ANN-a. Optimalni ANN težinski koeficijenti se mogu odrediti analiziranjem MSE-a između simuliranih i ciljnih vrednosti fedinga nakon svakog trening kruga. Radi ovakve validacione procedure, simulirana feding vrednost je dobijena propagacijom ulaznog vektora koji se sastojao od isključivo mernih odbiraka fedinga, dok je sledeći merni odbirak fedinga uzet kao ciljna vrednost. Na Sl. 5.13 je prikazana promena MSE vrednosti tokom treniranja neuralne mreže. Analiziranjem performansi ANN simulatora nakon svakog trening kruga, zaključeno je da trening krug sa manjim MSE ne garantuje bolje simuliranu sekvencu feding vrednosti u poređenju sa trening krugom sa većim MSE. Razlog ovome je zapravo postojanje tzv. memorijskog efekta koji je prisutan prilikom simuliranja sekvence feding vrednosti (primenom modela sa zatvorenom povratnom spregom prikazanog na Sl. 5.5), dok je optimizacija ANN težinskih koeficijenata sprovedena naspram jednog feding odbirka koji sledi ulaznu sekvencu. Stoga je MSE proračunat na opisani način odbačen kao merilo performansi simulatora. Iz navedenog razloga je nakon svakog trening kruga, pomoću DS generatora i modela simulatora prikazanog na Sl. 5.5, simulirana sekvenca feding vrednosti. Generisane sekvence fedinga su zatim upoređene sa izmerenom sekvencom u pogledu funkcija raspodele i korelacionih karakteristika, odnosno procenom različitih kvalitativnih parametara. U pogledu raspodele vrednosti fedinga analizirani su PDF i CDF. Upoređeni su LCR i ADF parametri kao jedni od značajnijih parametara koji opisuju učestanost varijacija fedinga. Određen je, takođe, i broj korelisanih odbiraka generisanih feding sekvenci. Analiza dobijenih rezultata je sprovedena upoređivanjem parova simuliranih sekvenci, u pogledu spomenutih kvalitativnih parametara, primenom klasične metode nagrađivanja. Zavisno od rezultata poređenja, bolja sekvenca fedinga je razmatrana za dalje poređenje. Na osnovu sprovedene analize je zaključeno da je optimalni skup ANN težinskih koeficijenata, odnosno da je zadovoljavajuća sekvenca fedinga dobijena nakon 137. trening kruga i da dalje treniranje nije pokazalo značajnije poboljšanje.



Sl. 5.13. Varijacija MSE vrednosti tokom ANN treniranja.

5.6. POREĐENJE PERFORMANSI FEDING SIMULATORA

Zarad verifikacije predložene metode, dobijeni rezultati su upoređeni sa postojećim feding simulatorima koji su opisani u Poglavlju 5.1. Klasična Džekova metoda je implementirana prema jednačini (5.1) za $M = 64$. Parametri $\alpha = 0$ i $\beta_k = \pi k / M$ su izabrani kao što je i preporučeno u [10] (pp. 81-85). WSS-poboljšana Džekova metoda je primenjena na osnovu jednačine (5.2) sa $N = 64$ oscilatora. Simulator zasnovan na IDFT operaciji je implementiran kao što je to opisano u [33]. Zatim, metoda WGN filtriranja pomoću LP IIR filtra trećeg reda je izvršena mapiranjem funkcije prenosa filtra definisane jednačinom (5.7) u diskretan, vremenski domen primenom bilinearne transformacije [61] (eq. (11.2)). Kao što je to i predloženo u [45], parametri $\omega_0 = 2\pi f_m / 1.2$ i $\xi = 0.175$ su uzeti da bi se obezbedila najbolja aproksimacija prvog loba Beselove funkcije nultog reda, prve vrste. AR metoda je implementirana prema jednačini (5.9), korišćenjem AR filtra reda $p = 100$. U okviru [40] je zaključeno da vrednost parametra γ koja obezbeđuje stabilan AR model zavisi pretežno od Doplerove frekvencije, i stoga je izabrana odgovarajuća vrednost $\gamma = 10^{-6}$. Maksimalna Doplerova frekvencija korišćena u ovim metodama je ista kao i tokom merenja, proračunata prema $f_m = V/\lambda_c$, gde V predstavlja brzinu kretanja prijemnika, a λ_c je talasna dužina nosioca. Takođe, u slučaju metoda koje su bazirane na IDFT-u i WGN filtriranju, snaga ulaznog Gausovog šuma je prilagođena tako da snage simulirane i izmerene anvelope fedinga budu jednake. Polovina odbiraka izmerene sekvence fedinga koja nije korišćena za ANN treniranje je uzeta kao referenca za upoređivanje rezultata. Svi rezultati prezentovani u ovom poglavlju


dobijeni su usrednjavanjem ansambla 50 slučajno odabranih sekvenci fedinga pri čemu se svaka sekvenca sastoji od 2^{16} simuliranih feding vrednosti.

5.6.1. POREĐENJE PDF I CDF FUNKCIJA ANVELOPE FEDINGA


Jedan od načina da se izvrši procena kvaliteta simulacione metode je analiziranje verovatnoće pojavljivanja određene vrednosti fedinga na izlazu simulatora. Proračunate funkcije PDF i CDF su prikazane na Sl.5.14 i Sl.5.15, respektivno. Radi potpunijeg poređenja, uzete su u obzir i teorijske vrednosti PDF-a i CDF-a Rejljeve raspodele [2] (eq.(3.32)). Dodatno, MSE je korišćen kao kvantitativna mera odstupanja PDF-a i CDF-a generisanog i referentnog feding procesa dobijenog tokom sprovedenog merenja. Proračunate MSE vrednosti su prikazane u Tab. 5.3. U Tab. 5.3, kao i u nastavku ovog poglavlja, crvenom bojom su naznačeni najbolji rezultati, dok su teorijski definisani parametri naznačeni sivom bojom. Na osnovu prikazanih rezultata može se primetiti da se teorijska Rejljeva raspodela odlično slaže sa merenjima. Takođe, može se primetiti da je filtriranje LP IIR filtrom trećeg reda pokazalo bolje rezultate nego predloženi simulator, dok su Džejkova, WSS-poboljšana Džejkova i IDFT metoda pokazale u neznatnoj meri bolje, ali i dalje uporedive rezultate, samo u slučaju PDF-a.

Tab. 5.3. MSE proračunatih PDF, CDF, LCR i ADF parametara.

	MSE(PDF)	MSE(CDF)	MSE(LCR) [prelaza ² /s ²]	MSE(ADF) [s ²]
ANN	$2.85 \cdot 10^{-5}$	$4.17 \cdot 10^{-4}$	$1.31 \cdot 10^{-3}$	$4.90 \cdot 10^3$
Teorija	$4.75 \cdot 10^{-6}$	$7.30 \cdot 10^{-5}$	$1.58 \cdot 10^{-3}$	$4.77 \cdot 10^3$
Klasični Džejkov (64)	$9.26 \cdot 10^{-6}$	$6.79 \cdot 10^{-4}$	$1.97 \cdot 10^{-3}$	$6.80 \cdot 10^3$
WSS Džejkov (64)	$1.55 \cdot 10^{-5}$	$1.07 \cdot 10^{-3}$	$1.38 \cdot 10^{-3}$	$1.00 \cdot 10^4$
IDFT	$1.06 \cdot 10^{-5}$	$4.39 \cdot 10^{-4}$	$1.54 \cdot 10^{-3}$	$8.08 \cdot 10^3$
LP IIR filtriranje (3)	$7.32 \cdot 10^{-6}$	$1.92 \cdot 10^{-4}$	$1.34 \cdot 10^{-3}$	$5.62 \cdot 10^3$
AR (100)	$1.70 \cdot 10^{-4}$	$9.30 \cdot 10^{-3}$	$1.37 \cdot 10^{-3}$	$9.01 \cdot 10^3$




Sl. 5.14. Funkcija gustine verovatnoće anvelope fedinga.




Sl. 5.15. Kumulativna funkcija raspodele anvelope fedinga.

5.6.2. POREĐENJE LCR I ADF PARAMETARA ANVELOPE FEDINGA

LCR parametar predstavlja očekivanu učestanost kojom anvelopa fedinga prelazi određeni nivo signala u pozitivnom smeru (od manjih ka višim vrednostima nivoa signala). Sa druge strane, ADF ukazuje na prosečno vreme koje prijemni signal provede ispod određenog praga. Razmatrani zajedno, LCR i ADF opisuju intenzitet fedinga tokom vremena. Proračunati LCR i ADF su prikazani na Sl. 5.16 i Sl. 5.17, respektivno. Takođe, u obzir su uzete i teorijski definisane jednačine za LCR i ADF Rejljevog fedinga [2] (eq. (3.44), (3.47)). Dodatno, MSE je uzet kao kvantitativna mera odstupanja proračunatih LCR-a i ADF-a generisanog i referentnog feding procesa dobijenog tokom sprovedenog merenja. Dobijene MSE vrednosti su prikazane u Tab. 5.3. Na Sl. 5.17. može se primetiti da su devijacije ADF-a, za opseg normalizovanog nivoa anvelope fedinga ispod -8dB, veće u slučaju predložene metode u poređenju sa ostalim analiziranim metodama. Međutim, red veličine ovih razlika je manji u poređenju sa odstupanjima u opsegu iznad 6dB koja, zapravo, najviše doprinose ukupnoj MSE vrednosti. Drugim rečima, u ovom opsegu je predložena metoda u odličnom slaganju sa merenjima. Kao posledica navedenog, može se primetiti u Tab. 5.3. da je u slučaju i LCR-a i ADF-a predloženi simulator pokazao najbolje rezultate među analiziranim metodama. Samo je teorijski definisana jednačina ADF-a u neznatno boljem slaganju sa merenjima nego što je to slučaj sa predloženom metodom.



Sl. 5.16. Učestanost prolaska fedinga kroz određeni nivo.



Sl. 5.17. Srednje trajanje fedinga.

5.6.3. POREĐENJE KORELACIONIH KARAKTERISTIKA

Da bi se uporedile korelacione karakteristike generisanih anvelopa fedinga, analiziran je i broj korelisanih odbiraka fedinga. Zapravo, broj korelisanih vrednosti fedinga je određen kao broj odbiraka za koji je potrebno pomeriti sekvencu fedinga da bi ACF pao po prvi put ispod 0.2. Broj korelisanih odbiraka fedinga generisanog analiziranim metodama je prikazan u Tab.5.4. Kao što se može i primetiti, sve analizirane metode, uključujući i predloženu, pokazale su manji broj korelisanih vrednosti u poređenju sa merenjima. Međutim, među analiziranim metodama jedino je Džejkova metoda pokazala neznatno bliže rezultate merenjima nego što je to slučaj sa predloženim simulatorom. Teorijski rezultati nisu uzeti u obzir pošto matematički izraz ACF-a anvelope fedinga nije moguće izračunati.

Tab. 5.4. Broj korelisanih odbiraka fedinga.

	Broj odbiraka
Merenja	47
ANN	33.70
Teorija	-
Klasični Džejkov (64)	36.80
WSS Džejkov (64)	33.00
IDFT	33.40
LP IIR filtriranje (3)	33.42
AR (100)	32.88

5.6.4. POREĐENJE MARGINE SNAGE


Margine snage (*power margin*) su kao mere kvaliteta predložene u okviru [59] i daju procenu odstupanja generisane od idealne raspodele. Prva mera, koja se naziva *Mean Basis Power Margin*, je data kao:

$$\mathcal{G}_{mean} = \frac{1}{\sigma_x^2 l} \text{trace} \{ C_x C_{\bar{x}}^{-1} C_x \}. \quad (5.20)$$

Druga mera, *Maximum Basis Power Margin*, definisana je kao:

$$\mathcal{G}_{max} = \frac{1}{\sigma_x^2} \max \{ \text{diag} \{ C_x C_{\bar{x}}^{-1} C_x \} \}. \quad (5.21)$$

U jednačinama (5.20) i (5.21), σ_x^2 je varijansa referentne raspodele, $C_{\bar{x}}$ predstavlja $l \times l$ matricu kovarijanse bilo kog podskupa l susednih vrednosti generisanih od strane analizirane metode, dok C_x predstavlja željenu matricu kovarijanse l vrednosti idealne raspodele. Matrice kovarijanse su proračunate na osnovu ACF-a kvadrata anvelope fedinga prikazanog na Sl. 5.18. Teorijske vrednosti ACF-a kvadrata anvelope fedinga [10] (eq. 2.71) su takođe prikazane. ACF kvadrata anvelope fedinga dobijenog merenjem je uzet kao referenca. Autokorelaciona sekvenca dužine $l = 200$ je korišćena prilikom proračuna jednačina (5.20) i (5.21). Dobijeni rezultati su prikazani u Tab. 5.5. Teorijska analiza nije uzeta u obzir jer proračun inverzne matrice kovarijanse nije bio moguć usled njene singularnosti. Radi lakšeg uvida u dobijene rezultate, idealno generisani feding proces odgovara vrednosti 0dB za obe margine snage. Prema prikazanim rezultatima ANN metoda je u boljem slaganju sa merenjima nego ostale metode.



Sl. 5.18. Autokorelacija kvadrata anvelope fedinga.

Tab. 5.5. Margine snage i WMSAE.

	$\mathcal{G}_{mean}$ [dB]	$\mathcal{G}_{max}$ [dB]	Γ [dB]
ANN	0.21	0.24	-22.56
Teorija	-	-	-16.40
Klasični Džejkov (64)	0.31	0.36	-21.44
WSS Džejkov (64)	0.27	0.30	-22.06
IDFT	0.28	0.31	-21.97
LP IIR filtriranje (3)	0.32	0.37	-22.18
AR (100)	0.30	0.33	-20.13

5.6.5. POREĐENJE WMSAE PARAMETRA


Mera poredenja koja je korišćena za proračun kvaliteta generisanog slučajnog procesa u [60] je *weighted mean-square autocorrelation error* (WMSAE). Ova mera poredenja je definisana kao:

$$\Gamma(p) = 10 \log \left(\frac{\|\mathbf{R}^e - \mathbf{R}^a\|_F}{\|\mathbf{R}^e\|_F} \right) = 10 \log \left(\frac{\sum_i \sum_j (r_{ij}^e - r_{ij}^a)^2}{\sum_i \sum_j (r_{ij}^e)^2} \right), \quad (5.22)$$

gde $\|\cdot\|_F$ označava Frobeniusovu (*Frobenius*) normu [62], $\mathbf{R}^e$ i $\mathbf{R}^a$ su egzaktna i aproksimirana korelaciona matrica sa elementima $r_{ij}^e = R^e(|i - j| \tau_s)$ i $r_{ij}^a = R^a(|i - j| \tau_s)$, respektivno. $\mathbf{R}^e$ i $\mathbf{R}^a$ korelacione matrice su formirane na osnovu ACF-a kvadrata anvelope fedinga dobijene eksperimentalnim merenjima R^e , i primenom analiziranih metoda R^a , respektivno. Sve proračunate WMSAE vrednosti su prikazane u Tab.5.5. Treba imati na umu da je aproksimacija bolja što je parametar $\Gamma(p)$ manji. Na osnovu pomenutog, može se primetiti da su rezultati dobijeni primenom predloženog simulatora znatno bolji u poređenju sa ostalim analiziranim metodama.

5.6.6. POREĐENJE U VREMENSKOM DOMENU


Radi kvalitativne vizuelne inspekcije anvelope feding procesa u vremenskom domenu, analizirani su nasumično odabrani segmenti generisanih feding procesa (prikazani na Sl. 5.19). Na osnovu dobijenih rezultata može se primetiti da je predložena metoda u boljem slaganju sa merenjima u poređenu sa postojećim metodama i po frekventnosti i po amplitudi fluktuacija generisanog signala.



Sl. 5.19. Anvelopa fedinga procesa u vremenu: (a) merjenja, (b) ANN simulacija, (c) klasična Džejkova metoda, (d) WSS-poboljšana Džejkova metoda, (e) LP IIR filtriranje, (f) IDFT i (g) AR filtar.

5.6.7. RAČUNSKA KOMPLEKSNOŠT


U cilju procene računске kompleksnosti analiziranih simulacionih metoda, sprovedeno je poređenje vremena potrebnog za izvršavanje simulacionog procesa. Stoga su generisane sekvence od 10^6 feding odbiraka implementacijom predložene i postojećih metoda u Matlab-u na računaru sa Intel Core i7 CPU-om (Q 820 @ 1.73GHz). Na Sl. 5.20 su prikazani rezultati sprovedene analize normalizovani po jednom odbirku fedinga, odnosno vremena potrebna za generisanje jedne vrednosti fedinga. Na osnovu prikazanih rezultata može se zaključiti da su postojeće simulacione metode pokazale bolje performanse u odnosu na ANN metodu. Najkraće vreme od $0.3125\mu\text{s}$ za generisanje jednog feding odbirka pokazala je IIR metoda. Sa druge strane, predloženoj ANN metodi bilo je potrebno 3.6011ms za generisanje jedne feding vrednosti, pri čemu je sam ANN model implementiran u paraleli sa DS generatorom. Za generisanje jedne DS vrednosti, DS generatoru je bilo potrebno 0.0232ms . Uzimajući u obzir da su merni podaci odabirani periodom od 25ms , može se zaključiti da predložena metoda zadovoljava potrebe simulacija u realnom vremenu.



Sl. 5.20. Vreme potrebno za generisanje jednog feding odbirka.

Dodatno je u analizu uzet i slučaj mernog signala čiji su odbirci, odnosno vrednosti nivoa električnog polja na prijemu, uzimani znatno većom periodom odabiranja koja je iznosila 100ms . U okviru ove merne kampanje je prijemna dipol antena Anritsu MP663A, vertikalne polarizacije, povezana na Anritsu merni prijemnik ML522B (300-1000MHz) koji je snimao varijacije nivoa električnog polja na prijemu. Veća perioda odabiranja rezultovala je manjim ulaznim ANN vektorom koji se sastojao od 26 sukcesivnih feding vrednosti (kao broj korelisanih odbiraka), što je dodatno pojednostavilo arhitekturu ANN-a. Treniranje i validaciona procedura su ovog puta sprovedeni nad manjim skupom vrednosti koji se sastojao

od 5000 odbiraka mernog feding procesa. Rezultati statističke analize generisanih i izmerenih feding vrednosti, tačnije PDF, CDF, LCR i ADF parametri, su prikazani na Sl.5.21. Na osnovu prikazanih rezultata, može se zaključiti da je veća perioda odabiranja rezultovala jednostavnijim modelom simulatora po cenu većeg odstupanja generisanih od izmerenih feding vrednosti, naročito u slučaju PDF i CDF parametara. Ujedno se može primetiti nedovoljna populisanost poredbenih metrika (naročito izražena u slučaju PDF-a) što je posledica manjeg skupa trening i verifikacionih podataka. Stoga se može zaključiti da je za zadovoljavajuće performanse predloženog simulatora od velikog značaja imati na raspolaganju dovoljno veliki skup trening/verifikacionih podataka snimljenih dovoljno malom periodom odabiranja.



Sl. 5.21. Pregled PDF, CDF, LCR i ADF parametara (za periodu odabiranja od 100ms).

5.7. ZAKLJUČNI KOMENTARI

U literaturi je do danas predložen veći broj simulacionih metoda za generisanje kratkotrajnog fedinga koje se baziraju ili na SoS metodi, na IDFT algoritmu, ili na WGN filtriranju. Sve ove metode su optimizovane i testirane u odnosu na teorijske karakteristike kratkotrajnog fedinga, ali ne i naspram podataka dobijenih merenjima. U ovoj glavi je predložena nova metoda za simulaciju kratkotrajnog fedinga koja se zasniva na ANN-u. Cilj predložene metode je simuliranje kratkotrajnog fedinga, tačnije anvelope fedinga koja je izdvojena iz prijemnog signala u realnom komunikacionom sistemu. Stoga, u cilju prikupljanja mernih podataka, sprovedena su odgovarajuća merenja jačine električnog polja u

odabranom *indoor* okruženju, u NLoS scenariju. Pošto je ideja bila da se predložena metoda bazira na mernim podacima, vrednosti fedinga koje su ekstrahovane na osnovu jačine prijemnog električnog polja su korišćene za ANN treniranje.

Radi demonstracije performansi predložene metode, sprovedeno je poređenje u odnosu na postojeće simulatore Rejljevog fedinga. U cilju potpunijeg poređenja, analizirane su takođe i teorijske karakteristike Rejljevog fedinga. Niz značajnijih komparativnih mera je uzet u obzir da bi se izvršila verifikacija predloženog simulatora. Ovo je podrazumevalo proračun PDF, CDF, LCR i ADF parametara generisanih feding procesa. Korelacione karakteristike, margine snage i WMSAE su takođe uzete u obzir. Takođe je razmatrana i računaska kompleksnost simulacionih metoda. Analiziranjem dobijenih rezultata, može se zaključiti da se predložena metoda generalno bolje slaže sa merenjima u poređenju sa drugim metodama. Predložena metoda je pokazala slične performanse kao i druge metode samo po nekoliko aspekata. Radi uvida u prednosti i mane analiziranih metoda simulacije fedinga, pregled rezultata poređenja kvantitativnih parametara je dat u Tab. 5.6 (štiklirani su najbolji rezultati). Na osnovu Tab. 5.6 može se zaključiti da je od ukupno 9 poredbenih parametara ANN metoda pokazala najbolje rezultate u slučaju pet parametara. Dodatno su simulacione metode upoređene i jedna protiv druge u Tab. 5.7 (štiklirani su bolji rezultati, a naznačen je i broj parametara za koji je data metoda pokazala bolje performanse). Na osnovu prikazanih rezultata u Tab. 5.7 može se zaključiti da je predložena ANN metoda pokazala najbolje rezultate. Sa druge strane, LP IIR filter trećeg reda je pokazao najbolje performanse uzimajući u obzir samo postojeće metode. Trebalo bi naglasiti da se na osnovu odličnog slaganja merenja i teorijskih karakteristika Rejljevog fedinga može potvrditi da je prijemni signal u izabranom okruženju bio izložen Rejljevom fedingu. Imajući u vidu dobijene rezultate, može se doneti zaključak da se predložena metoda može uspešno koristiti za potrebe simulacije Rejljevog kratkotrajnog fedinga. Isto tako, za očekivati je i uspešnu primenu predložene metode za simulaciju drugih tipova fedinga. Međutim, ovo podrazumeva da je adekvatni skup mernih podataka dostupan radi odgovarajućeg treniranja neuralne mreže. Pošto su merenja sprovedena u *indoor* okruženju koje je okarakterisano nepravilnim mehanizmima propagacije i različitim talasnim propagacionim efektima, može se očekivati da će predloženo rešenje, nakon odgovarajućeg ANN treniranja, takođe pokazati zadovoljavajuće rezultate i u *outdoor* okruženju.

Tab. 5.6. Pregled najboljih poredbenih rezultata analiziranih metoda simulacije fedinga.

Simulaciona metoda	ANN	Klasični Džejkov (64)	WSS Džejkov (64)	IDFT	LP IIR filtriranje (3)	AR (100)
PDF					✓	
CDF					✓	
LCR	✓					
ADF	✓					
Broj kor. odbiraka		✓				
$\mathcal{G}_{mean}$	✓					
$\mathcal{G}_{max}$	✓					
Γ	✓					
Računska kompl.					✓	
Rezultat	5	1	0	0	3	0

Tab. 5.7. Poređenje analiziranih simulacionih metoda.

Simulaciona metoda	AR (100)	LP IIR filtriranje (3)	IDFT	WSS Džekov (64)	Klasični Džekov (64)
ANN	1 ✓ 8	3 ✓ 6	2 ✓ 7	2 ✓ 7	3 ✓ 6
Klasični Džekov (64)	4 ✓ 5	6 ✓ 3	6 ✓ 3	4 ✓ 5	
WSS Džekov (64)	3 ✓ 6	7 ✓ 2	5 ✓ 4		
IDFT	1 ✓ 8	7 ✓ 2			
LP IIR filtriranje (3)	3 ✓ 6				

6. SIMULACIJA KORELISANIH KRATKOTRAJNIH FEDING PROCESA

Rezime. U okviru ove glave opisana je nova metoda simulacije dve korelisane anvelope kratkotrajnog fedinga mobilnog radio kanala. Predstavljena metoda je zasnovana na veštačkim neuralnim mrežama. Osnovna ideja je bila da se simulacioni pristup bazira isključivo na mernim rezultatima. Da bi se dobio adekvatni skup mernih podataka, sprovedena su merenja jačine elektičnog polja u odabranom indoor okruženju. Za potrebe verifikacije predložene metode, izvršeno je poređenje performansi naspram postojeće metode koja se bazira na coloring matrici. Na osnovu kvantitativne i kvalitativne statističke analize može se zaključiti da je predložena metoda u boljem slaganju sa korelisanim procesima kratkotrajnog fedinga u stvarnom propagacionom okruženju.

Pojam kratkotrajnog fedinga označava fluktuaciju signala na prijemu u mobilnim radio sistemima [1]. Kao što je napomenuto u Sekciji 2.3.2, feding, zapravo, opisuje karakteristiku prijemnog signala da postaje slučajan u vremenu i prostoru. Fluktuacije kratkotrajnog fedinga se ne mogu okarakterisati samo na osnovu propagacionih mehanizama. Međutim, na osnovu adekvatne statističke analize ovih fluktuacija, moguće je izvršiti procenu verovatnoće pojavljivanja određene jačine električnog polja na prijemu. Brojni komunikacioni sistemi podležu uticaju više međukorelisanih feding procesa. Na primer, takvi sistemi su višestruki antenski *diversity* sistemi, podkanalni signali u M-arnom kvadraturnom amplitudskom modulacionom sistemu sa više nosioca i signali nosioca u ortogonalnom frekvencijski podeljenom sistemu višestrukog pristupa (OFDMA). Kao posledica navedenog, pretpostavka nekorelisanih anvelopa fedinga pri analizi kao i simulaciji takvih komunikacionih sistema rezultuje greškom u proceni *diversity* dobitka i nerealnom slikom performansi sistema. Razlog takvih pretpostavki je nedostatak procedura koje mogu da generišu, sa zadovoljavajućom tačnošću, anvelope fedinga željenih kros-korelacionih karakteristika.

Zbog ključne uloge u proceni performansi mobilnih radio sistema, simulatori kratkotrajnog fedinga su od velike važnosti. Zapravo, simulatori korelisanih feding procesa su od teorijskog i praktičnog interesa već dugi niz godina. Za potrebe simulacije se obično pretpostavlja da signal na prijemu podleže Rejljevom fedingu. U literaturi je do danas predložen veći broj simulacionih metoda za generisanje korelisanih odbiraka Rejljevog

fedinga [63]-[68]. Jedna od popularnih metoda za generisanje korelisanih anvelopa Rejljevog fedinga podjednake snage, sa proizvoljnim kros-korelacionim koeficijentom, opisana je u [63]. Prema ovoj metodi, korelisani odbirci su generisani primenom *coloring* matrice dobijene Čoleski (*Cholesky*) dekompozicijom [69] (p. 34) željene korelacione matrice na osnovu dva nekorelisana kompleksna Gausova signala, jedinične snage i Rejljeve anvelope. Primena ove tehnike je proširena u [64] tako da je *coloring* matrica generalizovana i fizički interpretirana u cilju modelovanja željenog propagacionog kašnjenja (*delay spread*) prema eksponencijalnoj raspodeli kašnjenja i željenoj frekvencijskoj separaciji. Metoda za generisanje više kros-korelisanih anvelopa Rejljevog fedinga predložena u [65] je posebno dizajnirana za *multicarrier code division multiple access* (MCDMA) sisteme. Sa druge strane, metoda predložena u [66], koja se oslanja na metodu iz [64], koristi aproksimacije zatvorene forme za određivanje kvadraturnih komponenti kros-korelacije, dok [65] koristi *lookup* tabelu ili interpolaciju. Takođe, u okviru [67] predstavljen je i algoritam za generisanje korelisanih anvelopa Rejljevog fedinga podjednake snage, željene kovarijanske matrice izabrane na osnovu uslova u kanalu sa pretpostavkom izotropnog rasejavanja (*isotropic scattering*). Bitno je naglasiti da su sve pomenute metode razvijene i testirane naspram teorijskih karakteristika kratkotrajnog fedinga [2] (pp. 70-82), a ne naspram podataka dobijenih stvarnim merenjima.

U okviru ove glave predložena je nova metoda za simulaciju dve korelisane anvelope kratkotrajnog fedinga. Predložena metoda je zasnovana na veštačkim neuralnim mrežama (ANN) treniranim nad mernim podacima koji su dobijeni u realnom komunikacionom sistemu. Cilj je bio da se dizajnira simulator dva korelisana procesa kratkotrajnog fedinga sa statističkim karakteristikama anvelopa fedinga ekstrahovanih iz prijemnih signala. Koncept predložene metode je, zapravo, estimacija naredne vrednosti kratkotrajnog fedinga propagacijom prethodnih sukcesivnih feding vrednosti kroz ANN (po jedna neuralna mreža je korišćena za simulaciju svakog procesa). Zapravo, predložena metoda se zasniva na osnovnoj ideji pristupa opisanog u Glavi 5. za simulaciju pojedinačnog feding procesa. Za dobijanje adekvatnog skupa mernih podataka, sprovedena su merenja jačine električnog polja u odabranom *indoor* okruženju, u NLoS scenariju. Nasuprot postojećim simulacionim metodama, prednost predložene metode je u tome što se zasniva na mernim podacima, a ne isključivo na teorijskim karakteristikama. Stoga je fleksibilnost predložene metode sposobnost simuliranja feding procesa u bilo kom odabranom mernom okruženju. Dodatno, predloženo rešenje je pogodno za generisanje izuzetno dugih sekvenci fedinga pošto je implementirano u formi iterativne simulacione procedure. Radi verifikacije i procene kvaliteta predložene metode, sprovedeno je poređenje performansi u odnosu na metodu zasnovanu na *coloring* matrici predloženu u [63]. Ulazne sekvence fedinga za metodu zasnovanu na *coloring* matrici dobijene su WSS-poboljšanim Džejkovim simulatorom [28] koji je odabran kao jedna od najefikasnijih metoda simuliranja fedinga.

Nastavak glave je organizovan tako što je najpre u okviru Poglavlja 6.1 opisana postojeća metoda zasnovana na *coloring* matrici za simulaciju korelisanih sekvenci Rejljevog fedinga. U Poglavlju 6.2 je detaljnije opisana merna procedura kao i obrada snimljenih podataka. Poglavlje 6.3 uvodi predloženu ANN metodu za simulaciju korelisanih procesa kratkotrajnog fedinga. Da bi se izbegao ulazak neuralnih mreža u stacionarno stanje, koncept vodećeg signala (DS) je opisan u Poglavlju 6.4 zajedno sa načinom na koji su neuralne mreže navođene kroz treniranje i simulaciju. ANN trening i validacioni procesi su opisani u Poglavlju 6.5. Verifikacija predloženog simulatora u pogledu poređenja performansi sa postojećom metodom baziranom na *coloring* matrici je data u Poglavlju 6.6. Poglavlje 6.7 iznosi relevantne zaključke.

6.1. METODA ZASNOVANA NA COLORING MATRICI

Jedna od često korišćenih metoda za generisanje dva korelisana, kompleksna procesa Rejljevog fedinga je predložena u [63]. Ovom metodom se na osnovu dva nekorelisana Gausova signala, jedinične snage i Rejljeve anvelope, generišu dva procesa Rejljevog fedinga, jednake snage i odgovarajućeg kros-korelacionog koeficijenta. Odgovarajuća korelaciona matrica kompleksnih Gausovih odbiraka može se odrediti na osnovu željenog kros-korelacionog koeficijenta Rejljevih anvelopa [63]. Konačno, korelisani Rejljevi odbirci su generisani primenom *coloring* matrice, koja je dobijena Čoleski dekompozicijom [69] odgovarajuće korelacione matrice. Drugim rečima, korelisani signali Rejljevog fedinga mogu se generisati na osnovu:

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = C \begin{bmatrix} w_1 \\ w_2 \end{bmatrix}, \quad (6.1)$$

gde x_1 i x_2 predstavljaju željene korelisane odbirke Rejljevog fedinga, dok w_1 i w_2 predstavljaju dva nekorelisana signala Rejljevog fedinga jedinične snage. *Coloring* matrica je označena sa C i definisana je kao:

$$C = \begin{bmatrix} \sigma_x & 0 \\ \frac{1}{\sqrt{2}}\eta\sigma_x(1+j) & \sigma_x\sqrt{1-\eta^2} \end{bmatrix}. \quad (6.2)$$

Imaginarna jedinica je označena sa j , željena snaga signala σ_x , dok je η željeni kros-korelacioni koeficijent između signala Rejljevog fedinga koji je definisan u [9].

Kao ulaz metode bazirane na *coloring* matrici potrebno je generisati dva nekorelisana signala Rejljevog fedinga. Kao što je opisano u Poglavlju 5.1, u literaturi postoji veći broj metoda simulacije Rejljevog fedinga [28]-[42]. Jedna od efikasnih metoda za generisanje procesa Rejljevog fedinga je zasnovana na Klarkovom dvo-dimenzionalnom modelu izotropnog rasejavanja [16] i superpoziciji izlaza sinusoidalnih generatora (SoS). Inicijalno, SoS metoda je predložena u formi tzv. klasične Džejkove metode [9] (opisane u okviru Sekcije 5.1.1). Pošto klasična Džejkova metoda nije WSS prilikom usrednjavanja ansambla feding kanala, za potrebe metode zasnovane na *coloring* matrici uzeta je u obzir druga široko prihvaćena SoS metoda, tzv. WSS-poboljšani Džejkov model predložen u [28]. Na osnovu WSS-poboljšanog Džejkovog modela mogu se generisati nekorelisani feding procesi. Tačnije, k -ti normalizovani *low-pass* proces Rejljevog fedinga $x_k(t)$ može se generisati kao:

$$x_k(t) = \sqrt{\frac{2}{N}} \sum_{n=1}^N \left(\cos(2\pi f_m t \cos \alpha_n + \phi_{n,k}) + j \cos(2\pi f_m t \sin \alpha_n + \phi_{n,k}) \right), \quad (6.3)$$

gde je $\alpha_n = (2\pi n - \pi + \theta_k)/(4N)$, $n = 1, 2, \dots, N$, maksimalna Doplerova frekvencija je označena kao f_m , dok su θ_k i fazni pomeraji $\phi_{n,k}$, $\phi_{n,k}$ statistički nezavisni i uniformno distribuirani u intervalu $[-\pi, \pi)$ za svako t . Štaviše, zadovoljavajuća aproksimacija teorijskog procesa Rejljevog fedinga se postiže već za $N = 8$ [28].

6.2. MERENJE I OBRADA PRIKUPLJENIH PODATAKA

Zarad snimanja dva korelisana feding procesa sa dve prijemne tačke, sprovedena je NLoS merna kampanja u *indoor* okruženju. Zgrada Elektrotehničkog fakulteta u Beogradu je odabrana kao merno okruženje (prikazano na Sl. 5.1) zbog kompleksne infrastrukture, visoko reflektujućih unutrašnjih pregradnih zidova i visoke dinamike električnog polja (preko 80dB). Imajući u vidu da su merenja sprovedena u takvom kompleksnom NLoS *indoor* okruženju koje odgovara realnom scenariju savremenih mobilnih sistema, pretpostavljen je izotropni model rasejavanja [9]. Nemodulisani CW RF signal je emitovan na frekvenciji od $f_c = 457\text{MHz}$ sa omnidirekcionom antenom, sa dobitkom od 0dBd, povezane na stacionarni predajnik Motorola MC Micro izlazne snage 25W. Sa druge strane, dva Rohde&Schwarz ESPI test prijemnika su montirana na kolica koja su se kretala predefinisanom rutom konstantnom brzinom $V = 0.2\text{m/s}$. Perioda odabiranja oba prijemnika je postavljena na $t_s = 25\text{ms}$ pomoću eksternog *triggering* uređaja. Dve kalibrisane polutalasne dipol Anritsu MP663A antene, vertikalne polarizacije, povezane su na prijemnike koji su snimali ulaznu jačinu električnog polja. U okviru prve merne kampanje prijemne antene su pozicionirane na horizontalnu ravan na razdaljini od $\lambda_c/8$, dok su u okviru druge pozicionirane na razdaljini od $\lambda_c/4$, gde $\lambda_c = c/f_c$ označava talasnu dužinu signala. Svaka iteracija merne kampanje trajala je oko jedan sat, a kretanjem prijemne opreme u odabranom okruženju pokrivena je ukupna razdaljina od 720m.

6.2.1. EKSTRAKCIJA ANVELOPE FEDINGA

Na osnovu snimljenih vrednosti jačine električnog polja izvršena je ekstrakcija odgovarajućih anvelopa kratkotrajnog fedinga. Najpre su proračunate vrednosti dugotrajnog fedinga usrednjavanjem prijemne jačine električnog polja unutar adekvatno odabranog pokretnog prostornog intervala, takozvanog prozora. Usrednjavanje je izvršeno prema (5.14), gde W označava dužinu prozora za usrednjavanje, $r(t)$ predstavlja jačinu prijemnog električnog polja i $l(t_i)$ označava dugotrajni feding u trenutku $t_i = it_s$, pri čemu t_s označava periodu odabiranja. Pošto su merenja sprovedena u *indoor* okruženju, usvojeno je da dužina prozora iznosi $10\lambda_c$, kao što je predloženo u [49], [50]. Vrednosti kratkotrajnog fedinga $x(t)$ su dobijene oduzimanjem proračunatih vrednosti dugotrajnog fedinga od mernih vrednosti intenziteta električnog polja na prijemu prema (5.15).

6.2.2. KORELACIONE OSOBINE EKSTRAHOVANOG FEDINGA

Pošto je ideja predložene metode da se estimacija vrši na osnovu prethodnih vrednosti fedinga, broj korelisanih odbiraka fedinga je uzet u obzir kao broj vrednosti koji značajnije utiče na sledeću vrednost koju treba proceniti. Da bi se stekao uvid u korelacione osobine izmerenog feding procesa, proračunat je ACF fedinga u formi autokorelacionih koeficijenata prema (5.6). Kros-korelacione osobine feding procesa su analizirane proračunom kros-korelacione funkcije (*Cross-Correlation Function* - CCF) prema [53] (pp. 156-159). Broj korelisanih feding odbiraka je uzet kao broj odbiraka za koji je potrebno zakasniti analizirani uzorak da bi ACF, odnosno CCF, pao ispod odabranog praga po prvi put. Za prag je odabrana vrednost korelacione funkcije od 0.2, kao što je predloženo u [5] (p. 49). Opisanim pristupom je određeno da broj auto-korelisanih vrednosti, usrednjen nad primarnim i sekundarnim feding procesom, iznosi 65 za rastojanje prijemnih antena $\lambda_c/8$, odnosno 60 za rastojanje $\lambda_c/4$ (što se


neznatno razlikuje od broja auto-korelisanih odbiraka određenog u okviru Sekcije 5.2.2 usled specifičnosti samih mernih kampanja i mernog okruženja). Na sličan način je određeno da je broj kros-korelisanih vrednosti 72 za rastojanje prijemnih antena $\lambda_c/8$, odnosno 13 za rastojanje $\lambda_c/4$.

6.2.3. RAJSOV K-FAKTOR

Primenom estimatora koji je predložen u [51] (eq. 3) procenjen je Rajsov K-faktor [2] (eq. 3.36) kao jedan od relevantnih parametara kanala koji opisuje raspodelu feding procesa. Rajsov K-faktor je računat nad feding vrednostima u okviru prozora dužine $10\lambda_c$. Analiziranjem feding procesa, za oba slučaja rastojanja prijemnih antena $\lambda_c/8$ i $\lambda_c/4$, zaključeno je da su dobijene vrednosti K-faktora u opsegu od -29.22 do 5.62dB, i da su manje od 3dB u 94.36% slučajeva. Prema [52] (pp. 108-110), feding proces se može modelovati kao proces Rejljeve raspodele ako je Rajsov K-faktor manji od 3dB. Imajući ovo u vidu i činjenicu da su merenja sprovedena u NLoS scenariju, predložena ANN metoda je upoređena sa postojećim pristupom simulaciji korelisanih feding procesa Rejljeve raspodele [63].

6.3. PREDLOŽENA METODA SIMULACIJE KORELISANIH FEDING PROCESA

Suprotno postojećim simulacionim metodama [63]-[68], predložena ANN metoda se oslanja isključivo na eksperimentalno dobijene podatke. Zbog toga je ANN trening procedura sprovedena nad skupom mernih podataka. Na taj način, ideja je da se optimizacijom ANN koeficijenata ekstrahuju karakteristike mernih feding procesa. Arhitektura predloženog simulatora korelisanih feding procesa je predstavljena na Sl. 6.1. Kao što se može primetiti, predložena arhitektura simulatora se sastoji od dve neuralne mreže, primarne i sekundarne, optimizovane za simuliranje po jednog od dva korelisana feding procesa. Time je cilj bio da se korelacione osobine ekstrahovane iz mernih podataka prenesu na generisane feding vrednosti. Pored L primarnih feding vrednosti, ulazni vektor primarnog ANN-a je sadržao i element, označen kao primarni DS, za stohastičku navigaciju izlazne vrednosti. Primarni DS element je označavao smer u kom je potrebno generisati sledeću vrednost primarnog fedinga, u odnosu na prethodni, tj. poslednji element sekvence primarnog fedinga koja se propagira kroz ANN. Ulazni vektor sekundarnog ANN-a je sadržao sekvencu primarnog fedinga od M odbiraka. Pored vrednosti primarnog fedinga, sadržao je i sekvencu sekundarnog fedinga od N odbiraka. Izlazna vrednost sekundarnog fedinga je usmerena na osnovu sekundarnog DS elementa. Sekundarni DS je usmeravao izlaznu vrednost u odnosu na poslednju vrednost sekvence sekundarnog fedinga. Dva DS generatora, primarni i sekundarni, su generisala odgovarajuće vrednosti DS-a na osnovu statističkih osobina mernih feding procesa i ugrađenih generatora slučajnih brojeva. Koncept DS-a, primenjen u slučaju simulatora korelisanih feding procesa, je opisan detaljnije u Poglavlju 6.4.



Sl. 6.1. ANN simulator koreliranih fading procesa ($x_p(t_i)$, $x_s(t_i)$ – i -ta vrednost primarnog, odnosno sekundarnog fading procesa, $d_p(t_i)$, $d_s(t_i)$ – i -ta primarna, odnosno sekundarna DS vrednost).

Simulacija korelisanih feding procesa počinje inicijalizacijom ulaznih vektora. Odbirci fedinga ulaznih vektora su inicijalizovani nasumično odabranim vrednostima. Poslednji ulazni elementi uzimaju vrednosti generisane odgovarajućim DS generatorima. Ulazni vektori su zatim propagirani kroz trenirane neuralne mreže i generisane su izlazne vrednosti. Izlazne vrednosti primarnih i sekundarnih neuralnih mreža predstavljaju vrednosti primarnog i sekundarnog fedinga, respektivno. Na početku sledeće iteracije, vrednosti ulaznih sekvenci primarnog i sekundarnog fedinga pomeraju se na takav način da su generisane vrednosti uzete kao odgovarajući elementi ulaznih vektora, dok su poslednji elementi sekvenci izostavljeni. Vraćanjem izlazne vrednosti na ulaz odgovarajućeg ANN-a, uspostavljen je model sa zatvorenim povratnom spregom koji je inspirisan dobro poznatim TDNN modelom [4] (pp. 254-259). U isto vreme, poslednji ulazni elementi uzeli su nove vrednosti DS-a proizvedene odgovarajućim DS generatorima. Konačno, propagacijom kreiranih ulaznih vektora kroz ANN, generisane su nove izlazne vrednosti fedinga.

6.4. KONCEPT VODEĆEG SIGNALA U SIMULACIJI KORELISANIH FEDING PROCESA

Pre uspostavljanja arhitekture simulatora prikazane na Sl. 6.1, sproveden je veći broj eksperimentalnih simulacija sa ulaznim ANN vektorima koji su se sastojali samo od feding vrednosti. Kao i u Poglavlju 5.4, rezultati dobijeni na taj način, odnosno izostavljanjem ulaza DS-a, nisu bili zadovoljavajući. Tačnije, oba generisana feding procesa su pokazala karakteristike prigušenih oscilacija. Zbog toga je, u skladu sa zaključcima iznetim u Poglavlju 5.4, uveden koncept DS-a, a odgovarajući DS elementi su dodati ulaznim ANN vektorima. Konstantnim pobuđivanjem neuralne mreže izbegnut je ulazak generisanog procesa u stacionarno stanje.

U skladu sa konceptom DS-a uvedenim u Poglavlju 5.4, DS element je mogao uzeti jednu od dve moguće vrednosti, -1 i +1. Ako je vrednost DS-a iznosila -1, onda je narednu feding vrednost bilo potrebno generisati na opadajućoj strani anvelope fedinga, odnosno nižeg intenziteta u poređenju sa vrednošću koja joj prethodi. U slučaju da je vrednost DS-a +1, onda je narednu vrednost fedinga bilo potrebno generisati na uzlaznoj strani, odnosno većeg intenziteta u poređenju sa prethodnom vrednošću. Da bi se uveo koncept DS-a u predloženi simulator, implementirani su odgovarajući DS ekstraktori i DS generatori što je opisano u nastavku.

6.4.1. EKSTRAKCIJA VODEĆEG SIGNALA

Za dobijanje DS vrednosti iz originalnih vrednosti fedinga implementiran je DS ekstraktor prikazan na Sl. 5.6. Propagacijom dve susedne vrednosti fedinga kroz ekstraktor, generisana je odgovarajuća DS vrednost naznačavajući relaciju između ulaznih vrednosti. Prema Poglavlju 5.4, DS ekstraktor se sastoji od dve jedinice. Prva jedinica je odgovorna za određivanje razlike dve ulazne vrednosti fedinga (5.17). Rezultat $\Delta x(t_n)$ prve jedinice je uzet kao ulaz druge jedinice.

Zadatak druge jedinice je da odredi znak njene ulazne vrednosti, odnosno razlike dve vrednosti fedinga. Zbog toga je funkcija prenosa druge jedinice DS ekstraktora data kao

(5.18). Propuštanjem anvelope fedinga, odnosno dve po dve susedne feding vrednosti, generisana je odgovarajuća DS sekvenca. DS ekstraktor je korišćen za navigaciju ANN-a tokom trening procedure. Zapravo, ekstraktor je usmeravao ANN proračunavanjem DS vrednosti na osnovu poslednjeg odbirka fedinga u ulaznom ANN vektoru i ciljne vrednosti. Na taj način, ideja je bila da se ANN obuči kako da interpretira ulaznu DS vrednost i kako da odgovarajuće usmeri izlaznu vrednost.

6.4.2. GENERATOR VODEĆEG SIGNALA

Za generisanje DS vrednosti u cilju navigacije neuralne mreže tokom simulacione procedure implementiran je odgovarajući DS generator. Konceptualna šema implementiranog DS generatora prikazana je na Sl. 5.8. Ideja je bila da se sledeća DS vrednost generiše na osnovu statističke analize prethodnih DS vrednosti. Ovo podrazumeva proračun uslovnih verovatnoća P_d da će DS vrednost $d(t_n)$ uslediti nakon određene sekvence od S sukcesivnih DS vrednosti prema (5.19). Kao što je to opisano u Poglavlju 5.4, bitno je odrediti optimalnu dužinu sekvence sukcesivnih DS vrednosti koja je, zapravo, najveći broj S takav da svaka od 2^S mogućih sekvenci postoji unutar ekstrahovanog DS-a. Imajući pomenuto u vidu, određeno je da optimalna dužina sekvence za estimaciju sledeće DS vrednosti, u slučaju i primarnog i sekundarnog ANN-a, iznosi $S = 6$.

Nakon određivanja optimalne dužine S , izbrojeno je koliko je puta nakon određene DS sekvence usledila negativna, a koliko puta pozitivna DS vrednost. Za proračun odgovarajućih uslovnih verovatnoća, broj slučajeva kad je nakon odgovarajuće DS sekvence usledila određena DS vrednost podeljen je sa ukupnim brojem pojavljivanja te DS sekvence. Dobijeni rezultati za svaku od 2^6 mogućih sekvenci sačuvani su u okviru *lookup* tabele DS generatora (primer *lookup* tabele je prikazan u Tab. 5.1).

Pored *lookup* tabele, DS generator je implementiran sa memorijom, odnosno pomeračkim registrom koji u svakom trenutku sadrži 6 poslednjih DS vrednosti. Na početku simulacione procedure, DS generator je najpre inicijalizovan popunjavanjem memorije nasumičnim DS vrednostima. U skladu sa opisom u Poglavlju 5.4, DS generator je implementiran sa generatorom slučajnih brojeva koji je korišćen u statističkoj estimaciji sledeće DS vrednosti. Izlazna vrednost generatora slučajnih brojeva je upoređena sa odgovarajućim uslovnim verovatnoćama unutar *lookup* tabele. Poređenje je sprovedeno primenom klasične rulet metode [55] (p. 189). Zavisno od rezultata poređenja, odnosno zavisno od uslovne verovatnoće koja je zadovoljena, generisana je odgovarajuća DS vrednost. Nakon generisanja DS vrednosti, izvršeno je pomeranje DS elemenata unutar memorije. Pomeranje je izvršeno na takav način da je generisana DS vrednost ušla u memoriju, dok je poslednja izašla iz nje. Sledeća DS vrednost je procenjena u skladu sa novom DS sekvencom u memoriji.

6.5. OPTMIZACIJA ANN SIMULATORA KORELISANIH FEDING PROCESA

U dizajn fazi ANN simulatora, određeni su tip i arhitektura primarne i sekundarne neuralne mreže. Prema literaturi [4] (pp. 254-259), MFNN je često korišćen za rešavanje

zadataka kao što su modelovanje, estimacija i predikcija signala. Zbog toga, a i na osnovu zaključaka iznetih u Poglavlju 5.5, primarni i sekundarni segment simulatora su zasnovani na MFNN-u koji je odabran kao odgovarajući za simulaciju korelisanih feding procesa.

6.5.1. ARHITEKTURA NEURALNIH MREŽA

Radi određivanja tipa i arhitekture neuralnih mreža, neophodno je, između ostalog, definisati optimalni broj ANN ulaza i izlaza. U ovu svrhu, uzeta je u obzir analiza korelacionih osobina mernih feding procesa opisana u Sekciji 6.2.2. Kao što je to i razmatrano u Sekciji 5.5.1, propagacija redundantnih odbiraka fedinga, nekorelisanih sa odbirkom koji treba da se generiše, je nepotrebno i računski zahtevno. Zbog toga je broj elemenata koji sačinjava ulazni vektor primarne neuralne mreže definisan kao broj auto-korelisanih odbiraka primarnog fedinga. Na taj način je odabrano da se za rastojanje prijemnih antena $\lambda_c/8$ sledeći odbirak primarnog fedinga procenjuje na osnovu $L = 65$ prethodnih odbiraka, dok za rastojanje $\lambda_c/4$ na osnovu $L = 60$ prethodnih odbiraka. Ulazni vektor sekundarne neuralne mreže se sastojao od auto-korelisanih odbiraka sekundarnog fedinga, ali u isto vreme i od odbiraka primarnog fedinga kros-korelisanih sa odbirkom sekundarnog fedinga koji treba da se generiše. Na taj način je za rastojanje prijemnih antena $\lambda_c/8$ odabrano da se sledeći odbirak sekundarnog fedinga generiše na osnovu prethodnih $M = 72$ odbiraka primarnog i $N = 65$ odbiraka sekundarnog fedinga. Slično, za rastojanje prijemnih antena $\lambda_c/4$ je odabrano da se sledeći odbirak sekundarnog fedinga procenjuje na osnovu prethodnih $M = 13$ odbiraka primarnog i $N = 60$ odbiraka sekundarnog fedinga. Pored odbiraka fedinga, odgovarajuće DS vrednosti su uzete kao poslednji elementi ulaznih vektora. Sa druge strane, broj ANN izlaza određen je činjenicom da ANN treba da generiše jednu feding vrednost u okviru jedne simulacione iteracije. Zbog toga su obe neuralne mreže konstruisane sa samo jednim izlazom.

Pošto je MFNN odabran kao tip neuralne mreže, neophodno je bilo odrediti i broj skrivenih slojeva ispred izlaznog sloja. Prihvaćeno je dobro poznato stanovište da se, polazeći od ANN ulaza, broj neurona smanjuje i konvergira ka broju neurona izlaznog sloja. Takođe, usvojeno je i da broj neurona u prvom skrivenom sloju bude veći u poređenju sa brojem elemenata ulaznog ANN vektora. Time je omogućeno da ANN kvantifikuje i grupiše ulaznu informaciju na manje porcije čime je olakšana procedura učenja [57]. Optimalne strukture primarnog i sekundarnog ANN-a su određene empirijskom analizom različitih ANN struktura [4]. Kao i u Sekciji 5.5.2, analizirane su ANN strukture sa jednim, dva, tri i četiri sloja sprovođenjem eksperimentalnih trening/simulacionih procedura. Broj neuronskih jedinica u svakom sloju je takođe variran. Vrednosti generisane primenom različitih ANN struktura (u okviru modela zatvorene sprege sa Sl.6.1) upoređene su sa mernim feding vrednostima analiziranjem skupa kvalitativnih i kvantitativnih mera opisanih u Poglavlju 6.6. Na osnovu sprovedene analize zaključeno je da su primarni i sekundarni ANN modeli sa dva skrivena sloja pokazali najbolje rezultate. Zapravo, za oba rastojanja prijemnih antena, optimalni model primarne neuralne mreže se sastojao od 100 neurona u prvom skrivenom sloju, 50 neurona u drugom i od jednog izlaznog neurona. Optimalni model sekundarne neuralne mreže za rastojanje prijemnih antena $\lambda_c/8$ se sastojao od 200 neurona u prvom skrivenom sloju, 100 neurona u drugom i od jednog izlaznog neurona. Slično, za rastojanje prijemnih antena $\lambda_c/4$ optimalni model sekundarne neuralne mreže se sastojao od 160 neurona u prvom skrivenom sloju, 80 neurona u drugom i od jednog izlaznog neurona. Imajući u vidu zadatak koji neuralne mreže treba da izvrše, svi neuroni su implementirani sa sigmoidalnom aktivacionom funkcijom (bipolarna funkcija tipa tangensa hiperboličkog), osim izlaznog koji je implementiran sa linearnom aktivacionom funkcijom.

6.5.2. TRENING I VALIDACIJA NEURALNIH MREŽA

Težinski koeficijenti primarne i sekundarne neuralne mreže su optimizovani kroz odvojene trening i validacione procedure. Vrednosti primarnog i sekundarnog fedinga iz prvog skupa mernih podataka, odnosno sekvence od $6.0 \cdot 10^4$ sukcesivnih odbiraka, su korišćene za treniranje neuralnih mreža. Za oba slučaja rastojanja prijemnih antena, primarna i sekundarna neuralna mreža su optimizovane odvojeno. Povratne sprege neuralnih mreža sa Sl. 6.1 su rastavljene tokom trening procedura. Takođe, DS generatori su zamenjeni odgovarajućim DS ekstraktorima. Za svaki trening krug, ulazno/izlazni trening parovi su nasumično birani iz skupa trening podataka. Kao što je preporučeno prema konvencionalnoj trening proceduri [4], trening podaci su normalizovani na interval $[-1, +1]$. Kao ciljne vrednosti uzeti su odbirci fedinga koji slede nakon sekvence feding vrednosti ulaznog ANN vektora. Engajen-Vidrov algoritam [58] je korišćen za inicijalizaciju ANN težinskih koeficijenata i kontrolnih signala. U skladu sa predloženim u Sekciji 5.5.3, EBP pravilo učenja [4] je odabrano kao trening metoda. Kao kriterijumska funkcija za optimizaciju ANN težinskih koeficijenata, korišćen je MSE računat između generisanih i ciljnih feding vrednosti. Korekcija ANN težinskih koeficijenata je sprovedena nakon obrade svakog nasumično odabranog ulazno/izlaznog vektorskog para. Drugim rečima, trening procedura je sprovedena inkrementalno. Kao što je i definisano u Sekciji 5.5.3, stopa učenja je držana konstantnom 0.01 tokom celokupnog trening procesa. Po cenu brzine konvergencije, stopa učenja je odabrana kao dovoljno mala vrednost da bi se izbegle oscilacije oko minimuma kriterijumske fnkcije [4]. Trening procedure su trajale 1000 krugova, pri čemu je trening krug podrazumevao obradu svih ulazno/izlaznih parova skupa trening podataka.

Validaciona procedura je sprovedena u cilju izbegavanja prekomernog treniranja. Prema validacionom postupku predloženom u Sekciji 5.5.3, sekvence primarnog i sekundarnog fedinga su generisane nakon svakog trening kruga pomoću simulatora prikazanog na Sl. 6.1. Pošto su trening vrednosti normalizovane, sprovedena je i odgovarajuća denormalizacija vrednosti generisanih na izlazu neuralnih mreža. Vrednosti generisane na taj način su statistički upoređene sa mernim sekvencama od $4.0 \cdot 10^4$ sukcesivnih odbiraka iz skupa validacionih podataka. Poređenje je sprovedeno analiziranjem skupa kvantitativnih i kvalitativnih parametara opisanih u Poglavlju 6.6. Generisane sekvence feding vrednosti su procenjene primenom klasične metode bodovanja. Tačnije, parovi generisanih sekvenci su upoređeni tako da je odgovarajućoj sekvenci dat bod za svaki poredbeni parametar za koji je pokazala bolje performanse. Sekvenca feding vrednosti sa više bodova je uzeta u obzir za dalje poređenje. Kao rezultat validacione procedure, zaključeno je da su za rastojanje prijemnih antena $\lambda_c/8$ optimalni ANN težinski koeficijenti dobijeni nakon 413. trening kruga u slučaju primarne i nakon 258. trening kruga u slučaju sekundarne neuralne mreže. Sa druge strane, za rastojanje prijemnih antena $\lambda_c/4$ optimalni ANN težinski koeficijenti su dobijeni nakon 897. trening kruga u slučaju primarne i nakon 915. trening kruga u slučaju sekundarne neuralne mreže.


6.6. PERFORMANSE I EVALUACIJA SIMULATORA KORELISANIH FEDING PROCESA

Kao deo verifikacione faze, sprovedeno je poređenje performansi ANN metode i metode koja se zasniva na *coloring* matrici [63] opisane u Poglavlju 6.1. Primenom postojeće


metode [63], tačnije korekcijom ulaznih nekorelisanih sekvenci Rejljevog fedinga, generisane su korelisane sekvence Rejljeve raspodele. Da bi se generisale ulazne nekorelisane sekvence Rejljevog fedinga za potrebe uporedne analize, implementirana je WSS-poboljšana Džejkova metoda prema (6.3) sa $N=64$ oscilatora [28]. Maksimalna Doplerova frekvencija je definisana u skladu sa merenjima, odnosno proračunata kao $f_m = V/\lambda_c$, gde V predstavlja brzinu prijemnika, a λ_c talasnu dužinu CW-a. Sekvence primarnog i sekundarnog fedinga od $4.0 \cdot 10^4$ sukcesivnih odbiraka iz skupa verifikacionih podataka, koje nisu korišćene prethodno za trening i validacionu proceduru, uzete su kao referenca za poređenje performansi. U cilju verifikacije generisanih vrednosti, rezultati poređenja analizirani u nastavku dobijeni su usrednjavanjem ansambla pojedinačnih poredbenih rezultata računatih za 10 nasumično odabranih simulacionih procedura. Sekvenca od $4.0 \cdot 10^4$ vrednosti je generisana u okviru svake simulacione procedure. Radi potpunije analize, obe metode, predložena i postojeća metoda bazirana na *coloring* matrici, upoređene su, takođe, sa teorijskim karakteristikama Rejljevog fedinga [2] (pp. 70-82).

6.6.1. POREĐENJE PDF I CDF FUNKCIJA ANVELOPE FEDINGA

PDF funkcije proračunate za primarni i sekundarni feding, za rastojanja prijemnih antena $\lambda_c/8$ i $\lambda_c/4$, prikazane su na Sl. 6.2. Odgovarajuće CDF funkcije su prikazane na Sl. 6.3. Pored vizuelnog uvida u karakteristike raspodele verovatnoće, proračunate su i MSE vrednosti PDF i CDF funkcija anvelope fedinga, prikazane u Tab. 6.1. U Tab. 6.1, kao i u nastavku ovog poglavlja, crvenom bojom su naznačeni najbolji rezultati, dok su teorijski definisani parametri naznačeni sivom bojom. Na osnovu dobijenih rezultata, može se primetiti da je predložena ANN metoda pokazala bolje performanse u poređenju sa metodom koja se zasniva na *coloring* matrici. Takođe, primećeno je da je teorijska Rejljeva raspodela u dobrom slaganju sa merenjima. U slučaju sekundarnog feding procesa teorijska Rejljeva raspodela bila je u boljoj saglasnosti sa mernim podacima u poređenju sa predloženom metodom za oba rastojanja prijemnih antena, dok je u slučaju primarnog feding procesa to bio slučaj samo za rastojanje $\lambda_c/4$.




Sl. 6.2. PDF anvelope fedinga za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$.




Sl. 6.3. CDF anvelope fedinga za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$.

6.6.2. POREĐENJE LCR i ADF PARAMETARA ANVELOPE FEDINGA

LCR parametri proračunati za primarni i sekundarni feding, u slučaju rastojanja prijemnih antena $\lambda_c/8$ i $\lambda_c/4$, prikazani su na Sl. 6.4. Dodatno, odgovarajući ADF parametri su predstavljeni na Sl. 6.5. Kao kvantitativna mera razlike generisanog i referentnog feding procesa dobijenog merenjima, proračunate su MSE vrednosti dobijenih LCR i ADF parametara i prikazane u Tab. 6.1. Predložena ANN metoda je dala pretežno bolje rezultate u poređenju sa metodom koja se zasniva na *coloring* matrici. Tačnije, postojeća metoda je pokazala neznatno bolje performanse samo u slučaju ADF parametra sekundarnog feding procesa za oba rastojanja prijemnih antena.



Sl. 6.4. LCR za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$.



Sl. 6.5. ADF za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$.

Takođe, primećeno je da su teorijski definisane jednačine LCR i ADF parametara u dobrom slaganju sa merenjima. U slučaju sekundarnog feding procesa teorijski definisani LCR i ADF parametri pokazali su neznatno bolje rezultate u poređenju sa predloženom

metodom za oba rastojanja prijemnih antena, dok je za primarni feding proces to bio slučaj samo za LCR parametar kada je rastojanje antena bilo $\lambda_c/4$.

Tab. 6.1. MSE proračunatih PDF, CDF, LCR i ADF parametara.

Rastojanje antena	Simulaciona metoda	MSE(PDF)	MSE(CDF)	MSE(LCR) [prelaza ² /s ²]	MSE(ADF) [s ²]
$\lambda_c/8$	ANN simulirani primarni feding	$3.4468 \cdot 10^{-5}$	$8.6271 \cdot 10^{-5}$	$7.4452 \cdot 10^{-4}$	$2.5676 \cdot 10^1$
	Color simulirani primarni feding	$4.8247 \cdot 10^{-4}$	$3.7681 \cdot 10^{-3}$	$1.6490 \cdot 10^{-2}$	$7.7411 \cdot 10^1$
	Teorija	$5.9371 \cdot 10^{-5}$	$4.4464 \cdot 10^{-4}$	$1.0979 \cdot 10^{-3}$	$1.5992 \cdot 10^3$
	ANN simulirani sekundarni feding	$1.3029 \cdot 10^{-4}$	$1.3834 \cdot 10^{-3}$	$1.2957 \cdot 10^{-3}$	$8.7621 \cdot 10^2$
	Color simulirani sekundarni feding	$8.2196 \cdot 10^{-4}$	$5.4906 \cdot 10^{-3}$	$2.2364 \cdot 10^{-2}$	$8.5931 \cdot 10^2$
	Teorija	$4.1243 \cdot 10^{-5}$	$7.5989 \cdot 10^{-5}$	$8.0616 \cdot 10^{-4}$	$3.5998 \cdot 10^2$
$\lambda_c/4$	ANN simulirani primarni feding	$3.8232 \cdot 10^{-5}$	$1.9213 \cdot 10^{-4}$	$1.6042 \cdot 10^{-3}$	$5.0200 \cdot 10^2$
	Color simulirani primarni feding	$4.1647 \cdot 10^{-4}$	$3.9327 \cdot 10^{-3}$	$1.7739 \cdot 10^{-2}$	$5.2737 \cdot 10^2$
	Teorija	$2.3144 \cdot 10^{-5}$	$1.3088 \cdot 10^{-4}$	$1.3670 \cdot 10^{-4}$	$9.0344 \cdot 10^2$
	ANN simulirani sekundarni feding	$1.9515 \cdot 10^{-4}$	$2.4446 \cdot 10^{-3}$	$1.5074 \cdot 10^{-3}$	$2.9141 \cdot 10^3$
	Color simulirani sekundarni feding	$7.1350 \cdot 10^{-4}$	$5.0801 \cdot 10^{-3}$	$1.7146 \cdot 10^{-2}$	$2.3312 \cdot 10^3$
	Teorija	$3.0215 \cdot 10^{-5}$	$3.6594 \cdot 10^{-5}$	$1.1440 \cdot 10^{-4}$	$1.8916 \cdot 10^2$


6.6.3. POREĐENJE KORELACIONIH KARAKTERISTIKA

ACF i CCF sekvenci primarnog i sekundarnog fedinga su proračunati radi uvida u korelacione karakteristike generisanih vrednosti. Proračunate auto-korelacione funkcije kvadrata anvelope primarnog i sekundarnog fedinga, u slučaju rastojanja prijemnih antena $\lambda_c/8$ i $\lambda_c/4$, prikazane su na Sl. 6.6. Kao kvantitativna mera razlike između auto-korelacionih funkcija kvadrata generisane i referentne anvelope fedinga, proračunate su odgovarajuće MSE vrednosti, prikazane u Tab. 6.2. Kao što se može i primetiti, predložena metoda je pokazala


bolje rezultate za oba rastojanja prijemnih antena u poređenju sa metodom koja se zasniva na *coloring* matrici. U isto vreme, analiziran je i broj korelisanih odbiraka primarnog i sekundarnog fedinga. Rezultati analize broja auto-korelisanih odbiraka, usrednjeni nad ansamblom primarnih i sekundarnih feding procesa, prikazani su u Tab. 6.3.

Odgovarajuće kros-korelacione funkcije feding procesa za oba rastojanja prijemnih antena prikazane su na Sl. 6.7. Analiziranjem CCF-a, razmatrani su broj kros-korelisanih odbiraka i kros-korelacioni koeficijent za nulti pomeraj (prikazani u Tab. 6.4). Dodatno, proračunate su odgovarajuće MSE vrednosti, prikazane u Tab. 6.4, kao kvantitativna mera razlike CCF-a generisanih i referentnih feding procesa dobijenih merenjima.

Kao što se primećuje iz Tab. 6.3, u slučaju rastojanja antena $\lambda_c/8$, predložena ANN metoda je pokazala manje odstupanje broja auto-korelisanih odbiraka od merenja, dok je u slučaju rastojanja antena $\lambda_c/4$, pokazala slične rezultate u poređenju sa metodom koja se zasniva na *coloring* matrici. Anvelopa teorijskog Rejljevog fedinga nije uzeta u obzir pošto u ovom slučaju ACF nije moguće izraziti numerički.



Sl. 6.6. ACF kvadrata anvelope fedinga za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$.



Sl. 6.7. Kros-korelacione funkcije anvelope fedinga za rastojanje antena (a) $\lambda_c/8$ i (b) $\lambda_c/4$.

Tab. 6.2. MSE auto-korelacionih funkcija kvadrata anvelope fedinga, margine snage i WMSAE.

Rastojanje antena	Simulaciona metoda	MSE (ACF kvadrata anvelope)	$\mathcal{G}_{mean}$ [dB]	$\mathcal{G}_{max}$ [dB]	Γ [dB]
$\lambda_c/8$	ANN simulirani primarni feding	0.0020	0.4198	0.4677	-19.7667
	Color simulirani primarni feding	0.0095	1.3016	1.4161	-12.7733
	Teorija	0.0175	-	-	-9.8209
	ANN simulirani sekundarni feding	0.0020	0.6970	0.7942	-21.4655
	Color simulirani sekundarni feding	0.0111	0.9640	1.1165	-13.3396
	Teorija	0.0083	-	-	-12.7434
$\lambda_c/4$	ANN simulirani primarni feding	0.0025	0.1827	0.2347	-18.2480
	Color simulirani primarni feding	0.0104	1.1396	1.2425	-12.6462
	Teorija	0.0197	-	-	-9.3054
	ANN simulirani sekundarni feding	0.0045	1.0856	1.2504	-20.0201
	Color simulirani sekundarni feding	0.0309	0.6871	0.7447	-9.9769
	Teorija	0.0077	-	-	-13.0212

Tab. 6.3. Srednji broj auto-korelisanih odbiraka fedinga.

Rastojanje antena	Simulaciona metoda	Broj auto-korelisanih odbiraka
$\lambda_c/8$	Originalni feding	65
	ANN simulirani feding	66
	Color simulirani feding	33
	Teorija	-
$\lambda_c/4$	Originalni feding	60
	ANN simulirani feding	88
	Color simulirani feding	32
	Teorija	-

Kao što se može primetiti iz Tab. 6.4, u slučaju rastojanja antena $\lambda_c/8$ metoda bazirana na *coloring* matrici je pokazala bolje rezultate u pogledu broja kros-korelisanih odbiraka i kros-korelacionog koeficijenta za nulti pomeraj analiziranih vrednosti. Međutim, analiziranjem MSE vrednosti proračunatog CCF-a može se zaključiti da je predložena metoda generalno pokazala bolje poklapanje sa merenjima. Sa druge strane, predložena metoda dala je bolje rezultate za rastojanje antena $\lambda_c/4$.

Tab. 6.4. MSE vrednosti CCF-a anvelope fedinga, broj kros-koreliranih odbiraka fedinga i kros-korelacioni koeficijent.

Rastojanje antena	Simulaciona metoda	MSE(CCF)	Broj kros-koreliranih odbiraka	Kros-korelacioni koeficijent za nulti pomeraj (η)
$\lambda_c/8$	Originalni feding	-	72	0.5454
	ANN simulirani feding	0.0074	22	0.3261
	Color simulirani feding	0.0088	30	0.6763
$\lambda_c/4$	Originalni feding	-	13	0.2300
	ANN simulirani feding	0.0025	19	0.2658
	Color simulirani feding	0.0028	20	0.3804

6.6.4. POREĐENJE MARGINE SNAGE

Drugi pristup proceni odstupanja generisane od referentne raspodele, u ovom slučaju dobijene merenjima, je proračun mera kvaliteta predloženih u [59], takozvanih *mean basis* i *maximum basis* margina snage (definisane prema jednačinama (5.20) i (5.21)). ACF kvadrata anvelope fedinga, tačnije odgovarajuće autokorelacione sekvence dužine $l = 200$, korišćen je za proračun margine snage. Dobijeni rezultati su prikazani u Tab.6.2 (označeni kao $\mathcal{G}_{mean}$ i $\mathcal{G}_{max}$). Teorijski slučaj nije uzet u obzir pošto nije bilo moguće proračunati margine snage usled nestabilnosti inverzne kovarijanske matrice. U slučaju idealno generisanog procesa obe margine snage bile bi 0dB. Na osnovu dobijenih rezultata može se zaključiti da je predložena ANN metoda najčešće u boljem slaganju sa merenjima u poređenju sa metodom koja se bazira na *coloring* matrici. Zapravo, predložena metoda je pokazala lošije rezultate samo za sekundarni feding u slučaju rastojanja antena $\lambda_c/4$.


6.6.5. POREĐENJE WMSAE PARAMETRA

Još jedna poredbeni metrika za evaluaciju kvaliteta generisanog slučajnog procesa predložena u [60] je WMSAE (definisana jednačinom (5.22)). Proračunate vrednosti WMSAE parametra su prikazane u Tab.6.2 (označene sa Γ). Treba imati u vidu da što je manja vrednost WMSAE parametra, aproksimacija postaje bolja. Stoga se može zaključiti da


je predloženi ANN simulator pokazao bolje performanse u poređenju sa metodom zasnovanom na *coloring* matrici za oba rastojanja prijemnih antena.

6.6.6. POREĐENJE U VREMENSKOM DOMENU

Da bi se sprovedla kvalitativna vizuelna inspekcija fedinga u vremenskom domenu, nasumično odabrani segmenti feding procesa za rastojanje prijemnih antena $\lambda_c/8$ i $\lambda_c/4$ prikazani su na Sl. 6.8 i Sl. 6.9, respektivno. Analiziranjem prikazanih sekvenci fedinga može se zaključiti da je ANN metoda pokazala bolje slaganje sa merenjima u poređenju sa metodom koja se zasniva na *coloring* matrici.



Sl. 6.8. Korelisani feding u vremenskom domenu za rastojanje antena $\lambda_c/8$.



Sl. 6.9. Korelisani feding u vremenskom domenu za rastojanje antena $\lambda_c/4$.

6.6.7. RAČUNSKA KOMPLEKSNOŠT

Radi procene računskih resursa potrebnih za implementaciju analiziranih simulacionih metoda, sprovedena je analiza njihove računске kompleksnosti. Kompleksnost ANN modela zavisi od njegove infrastrukture (broja neurona i broja elemenata ulaznog vektora). Pošto je infrastruktura ANN-a zadata, ANN modelu je potrebno “konstantno vreme” $O(1)$ da generiše jedan odbirak fedinga. Stoga se može zaključiti da je sam ANN model linearne kompleksnosti $O(n)$ u odnosu na broj generisanih odbiraka n . U isto vreme, kompleksnost DS generatora je definisana algoritmom pretrage sprovedenim nad *lookup* tabelom fiksnih dimenzija $2^S \times S$ (gde je S broj elemenata DS memorije, dok je 2^S broj svih mogućih kombinacija S vrednosti DS-a), koji je, npr. u slučaju binarnog algoritma pretrage [70], kompleksnosti $O(\log 2^S) = O(S)$. Pošto je S fiksno, (tačnije $S = 6$ kao što je definisano u Sekciji 6.4.2), potrebno je “konstantno vreme” $O(1)$ za generisanje jedne DS vrednosti. Stoga je kompleksnost DS generatora linearna $O(n)$ u odnosu na broj generisanih fading odbiraka n .

Sa druge strane, kompleksnost metode zasnovane na *coloring* matrici je analizirana kao kompleksnost WSS-poboljšanog Džejkovog simulatora i kompleksnost *coloring* operacija. Kompleksnost WSS-poboljšanog Džejkovog simulatora zavisi od broja N superponiranih oscilatora u (6.3). Pošto je definisano da je $N = 64$, za generisanje jedne vrednosti fedinga (kao rezultat superpozicije) potrebno je “konstantno vreme” $O(1)$. Stoga je, u odnosu na broj generisanih odbiraka fedinga n , WSS-poboljšani Džejkov simulator linearne kompleksnosti $O(n)$. U isto vreme, kompleksnost metode koja se zasniva na *coloring* matrici je određena operacijom množenja matrica u (6.1) dimenzija 2×2 (*coloring* matrica C) i $2 \times n$ (dve nekorelisane fading sekvence od po n odbiraka) što je takođe linearne kompleksnosti

$O(2 \times 2 \times n) = O(n)$. Imajući u vidu da su obe simulacione metode linearne kompleksnosti $O(n)$ u odnosu na broj generisanih odbiraka n , zaključeno je da je vreme potrebno za generisanje jednog feding odbirka dovoljno za uvid u kompleksnost njihovih implementacija.

Za procenu računске kompleksnosti analiziranih metoda, sekvence od 10^6 feding odbiraka su generisane u Matlab-u na računaru sa Intel Core i7 CPU-om (Q 820 @ 1.73GHz). Najgori scenario ANN metode bio je slučaj sekundarnog ANN modela za rastojanje prijemnih antena od $\lambda_c/8$ kojem je bilo potrebno 3.5927ms za simulaciju jednog feding odbirka. DS generatoru je bilo potrebno 0.0236ms da generiše jednu DS vrednost što nije uticalo na celokupno vreme simulacije zbog paralelne implementacije izvršavanja rada DS generatora i ANN modela. Sa druge strane, metodi koja se zasniva na *coloring* matrici sa WSS-poboljšanim Džekovim simulatorom bilo je potrebno samo 0.0102ms. Iako je ANN metoda računski zahtevnija, ona zadovoljava zahteve u realnom vremenu pošto su merni podaci snimljeni sa periodom odabiranja od 25ms.


Kao jedan od pokazatelja računskih resursa potrebnih za implementaciju predložene metode, analiziran je i broj neophodnih računskih elemenata. Za implementaciju svakog ANN bloka bilo je potrebno W množača, $W \times N$ sabirača (operacije sa dva operanda), N aktivacionih funkcija od kojih je izlazna funkcija linearna, dok su ostale sigmoidalne funkcije, gde W označava broj težinskih koeficijenata (uključujući i kontrolne (*bias*) parametre), N broj neurona, a L dužinu ulaznog vektora. Dodatno, pomerački registar od L stanja je bio potreban radi pomeranja elemenata ulaznog vektora. Za implementaciju sekundarnog ANN modela za $\lambda_c/8$ rastojanje prijemnih antena, što je bio i najzahtevniji slučaj, bilo je potrebno 48,001 množača, 47,700 sabirača, 301 aktivacionih funkcija (od kojih je jedna linearna a ostale sigmoidalne) i pomerački registar od 138 elemenata. U isto vreme, za implementaciju DS generatora, pored generator slučajnih brojeva, bio je neophodan pomerački registar od K poslednjih DS vrednosti i *lookup* tabela od $2^K \times (K+1)$ elemenata što je iznosilo ukupno 454 memorijskih elemenata. Štaviše, prednost predloženog rešenja je simulacija jedne vrednosti fedinga po iteraciji i mogućnost generisanja dugačkih feding sekvenci tokom iterativnog procesa. Sa druge strane, metoda zasnovana na *coloring* matrici je nepogodna za generisanje dugačkih sekvenci, pošto su ulazne feding sekvence konačne dužine neophodne za operaciju množenja matrica. Zbog toga se kompleksnost implementacije *coloring* metode povećava sa povećanjem dužine ulaznih feding sekvenci.

6.7. ZAKLJUČNI KOMENTARI

Do danas je veći broj metoda za simulaciju korelisanih procesa Rejljevog fedinga predložen u literaturi. Međutim, ove metode su optimizovane i testirane samo naspram teorijskog Rejljevog fedinga, dok realni podaci dobijeni merenjima nisu uzeti u obzir. U ovoj glavi je predložena nova metoda za simulaciju korelisanih procesa kratkotrajnog fedinga koja se zasniva na ANN principima. Cilj je bio simuliranje dva korelisana feding procesa sa statističkim i korelacionim karakteristikama feding procesa izdvojenih iz prijemnih signala u realnom komunikacionom sistemu. Predloženi simulator se sastoji od dve neuralne mreže, primarne i sekundarne. Svaki ANN bio je odgovoran za generisanje jednog od dva korelisana feding procesa. Zapravo, primarni ANN je uzet kao vodeći na osnovu kog je sekundarni ANN generisao korelisani signal. Pošto je ideja bila da se ANN simulator isključivo zasniva na mernim podacima, feding vrednosti izdvojene iz jačine prijemnog električnog polja korišćene su za ANN treniranje.

Da bi se predložena metoda verifikovala, sprovedeno je poređenje performansi naspram metode koja se zasniva na *coloring* matrici [63] kao jedne od često korišćenih metoda za generisanje korelisanih feding signala. Ova metoda generiše korelisane signale Rejljevog fedinga korekcijom dva ulazna nekorelisana signala Rejljevog fedinga. U sklopu verifikacije predložene metode, analizirano je nekoliko značajnih poredbenih metrika. Ovo je podrazumevalo analiziranje PDF, CDF, LCR i ADF parametara generisanih feding signala. Korelacione osobine, margine snage i WMSAE su takođe analizirane. Osobine teorijskog Rejljevog fedinga su uzete u obzir radi kompletnosti poređenja. Takođe, analizirana je i računaska kompleksnost simulacionih metoda. Na osnovu dobijenih rezultata, može se zaključiti da je predložena ANN metoda najčešće u boljem slaganju sa merenjima u poređenju sa metodom zasnovanoj na *coloring* matrici za čije su potrebe ulazne sekvence fedinga generisane pomoću WSS-poboljšanog Džekovog simulatora. Radi uvida u perdnosti i mane analiziranih simulacionih metoda, pregled rezultata poređenja kvantitativnih parametara je dat u Tab. 6.5 (štiklirani su najbolji rezultati). Na osnovu Tab. 6.5 može se zaključiti da je od ukupno 21 poredbenih parametara metoda koja se zasniva na *coloring* matrici pokazala bolje rezultate samo za četiri parametra u oba slučaja rastojanja prijemnih antena $\lambda_c/8$ i $\lambda_c/4$. Dodatno, u slučaju jednog parametra, tačnije po pitanju broja auto-korelisanih odbiraka, za rastojanje prijemnih antena $\lambda_c/4$, obe analizirane metode bile su istih performansi.

Imajući u vidu dobijene rezultate, može se zaključiti da se predložena ANN metoda može uspešno koristiti za simulaciju korelisanih signala kratkotrajnog fedinga. Pošto je zasnovana isključivo na mernim podacima, fleksibilnost predložene metode se ogleda u sposobnosti simuliranja fedinga u bilo kom odabranom mernom okruženju. Zapravo, pošto su merenja sprovedena u *indoor* okruženju koje je specifično po iregularnim propagacionim mehanizmima i različitim propagacionim efektima radio talasa, za očekivati je da će predloženo rešenje pokazati zadovoljavajuće rezultate i u *outdoor* okruženju. Međutim, adekvatni skup mernih podataka je neophodan za izvršavanje trening procedure primarnog i sekundarnog ANN-a. Štaviše, predloženo rešenje se potencijalno može koristiti za simulaciju frekvencijsko-selektivnih kanala, kao što su, na primer, signali nosioca u OFDMA sistemima koji podležu uticaju kros-korelisanih fedinga. Takođe, moguće je i proširenje predloženog simulatora u cilju simulacije većeg broja korelisanih feding sekvenci, kao na primer u WiMAX (*Worldwide Interoperability for Microwave Access*) i LTE-A (*Long Term Evolution - Advanced*) sistemima, jednostavnim dodavanjem paralelno povezanih neuralnih mreža (jedan ANN po izlaznom signalu), kao što je to prikazano na Sl. 6.10. Implementaciju simulatora je moguće paralelizovati jer svaki ANN nezavisno generiše sledeću vrednost fedinga, odnosno obradom samo prošlih vrednosti koje su prethodno generisane od strane drugog ANN-a. Jedna od prednosti ANN pristupa se ogleda u iterativnoj formi simulacione procedure pri kojoj se jedan feding odbirak generiše u okviru jedne iteracije. Stoga je moguće generisati izrazito duge sekvence fedinga primenom predloženog pristupa.



Sl. 6.10. Simulacija više korelisanih feding signala (r_i – generisana vrednost, R_i – auto-korelisane vrednosti i R_{ij} – kros-korelisane vrednosti feding signala i i j).

Tab. 6.5. Pregled najboljih poredbenih rezultata analiziranih simulacionih metoda (za rastojanje prijemnih antena $\lambda_c/8$ i $\lambda_c/4$).

Rastojanje antena	$\lambda_c/8$				$\lambda_c/4$			
Simulaciona metoda	ANN		Coloring matrica		ANN		Coloring matrica	
	Prim. feding	Sek. feding	Prim. feding	Sek. feding	Prim. feding	Sek. feding	Prim. feding	Sek. feding
PDF	✓	✓			✓	✓		
CDF	✓	✓			✓	✓		
LCR	✓	✓			✓	✓		
ADF	✓			✓	✓			✓
ACF	✓	✓			✓	✓		
$\mathcal{G}_{mean}$	✓	✓			✓			✓
$\mathcal{G}_{max}$	✓	✓			✓			✓
Γ	✓	✓			✓	✓		
Broj auto-koreliranih odbiraka	✓				✓		✓	
CCF	✓				✓			
Broj kros-koreliranih odbiraka			✓		✓			
Kros-korelacioni koeficijent			✓		✓			
Računska kompl.			✓				✓	
Rezultat	17		4		17		5	

7. SIMULACIJA DRUGIH STOHAISTIČKIH PROCESA


Rezime. U ovoj glavi je analizirana mogućnost primene predložene ANN metode radi simulacije drugih stohastičkih signala. Za potrebe verifikacije odabran je ljudski EEG signal kao jedan od kompleksnih stohastičkih procesa iz stvarnog sveta. Cilj je bio da se simulira spontana pozadinska aktivnost ljudskog EEG-a isključivo na osnovu eksperimentalno dobijenih EEG podataka. Stoga su sprovedena merenja EEG signala na zdravoj, budnoj, odrasloj osobi u cilju prikupljanja odgovarajućeg skupa ANN trening podataka. Zarad demonstracije performansi ANN pristupa, izvršena su poređenja naspram metode koja se zasniva na ARMA filtriranju. Kvantitativna i kvalitativna statistička analiza je pokazala da je EEG proces generisan predloženom metodom u zadovoljavajućem slaganju sa merenjima.

Na osnovu sprovedene analize i rezultata izloženih u Glavi 5, može se doneti zaključak da se predložena simulaciona metoda zasnovana na veštačkim neuralnim mrežama (ANN) može uspešno koristiti za potrebe simulacije kratkotrajnog fedinga. Imajući u vidu da je feding jedan od kompleksnih stohastičkih procesa, nameće se pitanje performansi predložene simulacione metode prilikom simuliranja drugih stohastičkih signala, kako veštačkih tako i "realnih" signala iz ljudskog okruženja, koji pokazuju slične autokorelacione karakteristike kao i kvazi-periodičnu prirodu oscilacija. Kao jedan od kompleksnih stohastičkih procesa sa stanovišta statističke analize, kao i mehanizama koji ga proizvode, je elektroencefalogram (EEG) koji opisuje fenomen iz stvarnog sveta i predstavlja meru električne aktivnosti ljudskog mozga [71]-[78]. Iz navedenog razloga je EEG proces odabran u cilju verifikacije performansi predložene simulacione metode i njene primene za potrebe simuliranja EEG-a što je i detaljnije analizirano u nastavku ove glave.

Pojam slučajnog procesa [79] u statistici i teoriji verovatnoće označava proces suprotan determinističkom procesu, čija se budućnost ne može odrediti sa sigurnošću, ali se može proceniti sa određenom verovatnoćom. Kao što je napomenuto, jedan takav proces je i EEG proces koji predstavlja meru električne aktivnosti ljudskog mozga. EEG se posebno koristi u medicini u svrsi analize funkcionisanja mozga. Zapravo, na osnovu abnormalnosti EEG-a može se postaviti pravovremena dijagnoza cerebralnih povreda i epileptičkih napada [80]-[88]. U poslednjih nekoliko godina, razvijeni su algoritmi bazirani na EEG procesu za automatsku dijagnozu različitih neuroloških poremećaja kao što je epilepsija [89]-[93],

autizam [94], hiperkinetički poremećaj (*Attention Deficit Hyperactivity Disorder* - ADHD) [95], [96], i Alchajmerova bolest [97]-[102]. EEG proces ljudskog mozga je kompleksan stohastički proces [103] koji zavisi od različitih parametara kao što su kognitivni napor, mentalno stanje subjekta, lokacije na lobanji sa koje se posmatra itd. EEG signali, snimljeni tokom različitih stanja ispitanika, od budnog stanja do dubokog sna, prikazani su na Sl. 7.1. Tipični EEG zdravog odraslog čoveka se može opisati u formi slučajne pozadinske aktivnosti (*background activity*) određenog poznatog ritma koji se može svrstati u frekvencijske opsege specificirane po nomenklaturi, kao što su alfa, beta ili teta talasi [104]-[106].

Simulacija EEG procesa je od velikog interesa već dugi niz godina. EEG simulacija, što je i tema ove glave, podrazumeva generisanje vrednosti koje su okarakterisane istim statističkim karakteristikama kao i realni EEG proces. Statistička karakterizacija EEG-a obuhvata veliki broj kvantitativnih i kvalitativnih parametara, u vremenskom i frekvencijskom domenu, kao što su parametri koji opisuju raspodelu verovatnoće, brojne metrike koje se odnose na korelacione osobine i spektralnu analizu.



Sl. 7.1. Izgled EEG signala tokom različitih stanja ispitanika: (a) uzbuđenje, (b) opuštenost, (c) pospanost, (d) san i (e) duboki san [107].

Simuliranje EEG procesa ima bitnu ulogu u domenu medicine i kliničkoj neuropsihologiji. Takođe, EEG simulacije igraju značajnu ulogu i u analizi fizičkih mehanizama koji generišu ovakve signale. Brojne metode za simulaciju veštačkih EEG vrednosti su predložene do danas [108]-[118]. Jedan od često citiranih pristupa EEG

simulaciji bazira se na WGN filtriranju [108]-[112]. Odabir optimalnih koeficijenata filtra i reda modela je od presudne važnosti za takve metode. Na primer, u [108] su za svaku simuliranu sekvencu EEG-a proračunati koeficijenti AR filtra na osnovu Burgovog (*Burg*) algoritma koji je primenjen na slučajno odabranom segmentu realnog EEG signala. U okviru [109] korišćena je autokorelaciona metoda da bi se došlo do koeficijenata AR filtra što je definisano Jul-Vokerovom jednačinom. Sa druge strane, u [110] je korišćen genetički algoritam (*Genetic Algorithm* - GA) [119] da bi se optimizovali koeficijenti ARMA filtra poređenjem frekvencijskog spektra originalnog i simuliranog EEG procesa. Izbor reda AR filtra radi simuliranja EEG procesa odrasle osobe je istražen u [120] za slučaj podešavanja modela pomoću kratkih segmenata EEG-a. Kriterijum za izbor reda multivarijantnih ARMA modela je analiziran i verifikovan za simulirane i realne EEG podatke u okviru [121]. Jedan od pristupa simulaciji EEG signala predloženih u [113] se bazira na Markovljevom procesu amplitude (*Markov Process Amplitude* - MPA) prvog reda izraženom pomoću sinusoidalnih talasa. Parametri ovog modela su dobijeni primenom frekvencijske analize da bi se minimizovala razlika između spektralne gustine snage originalnih i simuliranih EEG signala. Adaptivni model EEG signala koji se, takođe, bazira na MPA algoritmu je predložen u [114]. Parametri ovog modela su adaptivno određeni primenom algoritma najmanjeg srednjeg kvadrata (*least mean square*). Međutim, bitno je naglasiti da ekstrakcija dominantnih frekvencija koje doprinose međusobno združenim komponentama [113], kao i izbor optimalne stope adaptivnog učenja [114], zahtevaju dalje istraživanje. Još jedan modifikovani MPA pristup je predložen u okviru [118] koji koristi neuralnu mrežu radi identifikovanja nelinearnosti u fluktuacijama EEG signala. Sa druge strane, svi gore navedeni pristupi koji se baziraju na MPA algoritmu koriste trenutnu grešku, odnosno odstupanje simuliranog EEG signala od originalnog signala čiju je estimaciju potrebno izvršiti. Ovo dalje ukazuje na to da generisanje EEG signala nezavisno od originalnog signala nije moguće ostvariti primenom pomenutih pristupa, što, međutim, nije slučaj sa predloženom metodom.

U okviru ove glave analizirana je primena ANN metode, predložene u Glavi 5, za simulaciju EEG procesa. Cilj primene predložene metode bio je generisanje spontane pozadinske EEG aktivnosti koja je okarakterisana statističkim osobinama kao i EEG proces dobijen merenjima na zdravoj, budnoj osobi bez fizičkog i kognitivnog angažovanja. Pored brojnih mogućnosti primene, predloženi EEG simulator se može koristiti i za modelovanje *event related potential* (ERP) segmenata [108], [122]-[124] simuliranjem osnovne, pozadinske aktivnosti za superpoziciju sa odgovarajućim karakterističnim ERP komponentama. Za razliku od postojećih pristupa simulaciji EEG procesa, predložena metoda se bazira na eksperimentalno dobijenim podacima. U cilju snimanja spontanog EEG procesa ljudskog mozga [125], sprovedena je merna kampanja na zdravoj, odrasloj osobi u kontrolisanom okruženju. EEG podaci dobijeni u okviru merenja su zatim korišćeni za ANN trening i validacionu proceduru. Osnovna ideja primene predložene ANN metode je procena sledeće EEG vrednosti na osnovu sekvence prethodnih sukcesivnih EEG vrednosti koja se propagira kroz ANN. Kao što je već opisano u Glavi 5, predloženi simulator je inspirisan poznatim TDNN modelom neuralne mreže [4]. Dodatno, da bi se izbegao ulazak generisanog procesa u stacionarno stanje, poseban generator vodećeg signala (DS), optimizovan za slučaj simuliranja EEG procesa, je implementiran za grubu navigaciju ANN-a tokom simulacione procedure. Zarad verifikacije primene predložene metode, sprovedeno je poređenje performansi u odnosu na postojeću metodu koja se bazira na ARMA filtriranju WGN signala, koja je odabrana kao jedna od efikasnih i često primenjenih metoda [110]. Prilikom verifikacije rezultata oba pristupa EEG simulaciji, tačnije metode koja se bazira na ANN-u i metode ARMA filtriranja, analizirani su brojni kvantitativni i kvalitativni parametri u vremenskom i frekvencijskom domenu. Tačnije, pored PDF, CDF parametara i

autokorelacionih osobina koji su uobičajene metrike EEG statističke analize u vremenskom domenu, analizirani su takođe LCR i ADF parametri [2]. Sa druge strane, rezultati EEG simulacije su verifikovani i u frekvencijskom domenu analiziranjem spektralnih karakteristika.

Struktura ove glave je organizovana tako što je najpre dat opis postojeće simulacione metode ARMA filtriranja WGN signala u Poglavlju 7.1. Zatim, u Poglavlju 7.2 su opisana merenja sprovedena nad ljudskim subjektom i obrada dobijenih EEG podataka. Potom je Poglavljem 7.3 dat uopšteni pregled predloženog ANN pristupa EEG simulaciji. Koncept DS-a, optimizovan za slučaj EEG simulacije, uveden je u Poglavlju 7.4 zajedno sa načinom na koji je ANN navođen kroz trening i simulaciju. Zatim, Poglavlje 7.5 opisuje arhitekturu ANN-a, kao i trening i validacionu proceduru. Poređenje performansi pristupa koji se bazira na neuralnoj mreži i pristupa ARMA filtriranja WGN signala je detaljno opisano u Poglavlju 7.6. Zaključci na osnovu dobijenih rezultata izvedeni su u Poglavlju 7.7.

7.1. EEG SIMULACIJA ARMA FILTRIRANJEM

Prema metodi koja je predložena u okviru [110], EEG signal se može simulirati filtriranjem WGN signala pomoću ARMA filtra. Osnovna ideja ove metode je predložena inicijalno u [126] i [127] radi simulacije nekih jednostavnih EEG segmenata. U [110] su koeficijenti filtra računati primenom GA i poređenjem frekvencijskog spektra izmerenog i simuliranog EEG procesa. Radi verifikacije performansi predložene ANN metode u okviru ove glave, ARMA filtriranje WGN signala je sprovedeno pomoću filtra osmog reda kao što je to i predloženo u okviru [110]. Varijansa ulaznog WGN signala je adekvatno korigovana da bi se varijanse izmerenog i generisanog EEG signala izjednačile.

Svi GA parametri su definisani prema [110]. Korišćena je dvanaestobitna predstava koeficijenta filtra, dok je svaki koeficijent biran iz opsega [-1, +1]. Da bi se odredilo odstupanje između originalnog i simuliranog EEG signala, fitnes funkcija f je implementirana kao:

$$f = \frac{100}{\left(100 + \sqrt{\sum error_i}\right)} . \quad (7.1)$$

Težinska suma greški (*Weighted Sum of Errors* - WSE), označena kao $\sum error_i$, je proračunata između spektralnih komponenti izmerenog i simuliranog EEG signala u opsegu od 0Hz do 50Hz. Drugim rečima, WSE je proračunat sumiranjem odgovarajućih greški dobijenih za svaku spektralnu komponentu ponaosob prema:

$$error_i = W_i (S_i - R_i)^2 , \quad (7.2)$$

gde S_i i R_i predstavljaju amplitude simulirane i izmerene spektralne komponente, respektivno [110]. Težinske vrednosti W_i , date u Tab. 7.1, dobijene su empirijski, analizom EEG signala u frekvencijskom domenu što je prikazano na Sl. 7.9. Na taj način je podstaknuta konvergencija spektralnih komponenti ka spektralnom obliku izmerenog signala.

GA algoritam je implementiran u formi turnir selekcije nad 10% populacije. Takođe, sprovedeno je ukrštanje (*double point crossover*) sa verovatnoćom od 95% i mutacija bita sa verovatnoćom od 10% po bitu. GA je sproveden nad 100 generacija, a korišćena je populacija od 200 individua. Takođe, GA je izvršen 10 puta sa istim parametrima ali različitim inicijalnim ulazom odabranim nasumično. Najbolja individua svih iteracija izabrana je kao rezultujući skup koeficijenata ARMA filtra. Dodatno, digitalni filter je korišćen nakon ARMA filtriranja da bi se odstranile suvišne komponente na visokim frekvencijama [110]. Tačnije, korišćen je Batervortov filter drugog reda, propusnik niskih učestanosti sa jediničnim dobitkom i graničnom frekvencijom 60 Hz.


Tab. 7.1. Težinski faktori W_i fitnes funkcije (F_i - frekvencija i S_i – amplitude simulirane spektralne komponente).

F_i [Hz]	S_i [μ V/Hz]	W_i vrednost
< 1.0	> 0.6	20-30
1.0-3.0	> 1.2	10-20
3.0-8.5	> 0.6	20-30
8.5-12	> 1.0	15-25
12-30	> 0.3	25-35
> 30	> 0.05	35-45
ništa od navedenog		1-7

7.2. PRIKUPLJANJE EEG PODATAKA

Radi merenja pozadinske aktivnosti ljudskog EEG procesa, sprovedena je merna kampanja u laboratoriji SIGMA Medizin-Technik GmbH, u Nemačkoj. Merna kampanja je sprovedena na budnoj, odrasloj osobi otvorenih očiju, bez fizičkog i kognitivnog angažmana. Osoba je relaksirano sedela u kontrolisanom okruženju, tačnije u zvučno izolovanoj sobi sa bešumnim ventilatorima i prigušenim svetlom. Konvencionalne pasivne elektrode su bile pozicionirane po lobanji subjekta prema internacionalnom 10-20 sistemu za pozicioniranje elektroda (prikazan na Sl. 7.2), a EEG signal, izmeren na centralnoj poziciji C3, je nasumično odabran za dalju analizu [128]. Referentna elektroda „uzemljenja” je postavljena na poziciji PO_Z. Signal indukovan u elektrodama je pojačan četrdesetokanalnim digitalnim EEG pojačavačem jednosmerne struje koji je izvršavao odabiranje vrednosti frekvencijom 1000Hz uz 22-bitnu A/D konverziju. Dodatno je signal propušten kroz filter propusnik niskih učestanosti sa graničnom frekvencijom 60Hz, dok je filter nepropusnik opsega učestanosti 50Hz korišćen u cilju eliminisanja interferirajućeg šuma prouzrokovanog od strane merne opreme i kablova elektroda. EEG signal je meren u trajanju od oko pola sata. Da bi se izvršila ekstrakcija “čiste” pozadinske EEG aktivnosti, tzv. *near-DC* (*Direct Current*) EEG aktivnosti [129], iz mernog EEG signala su odstranjene spore varijacije osnovne linije kao što je to opisano u okviru Sekcije 5.2.1. EEG vrednosti, ekstrahovane na taj način, su podeljene u tri

skupa, podjednake veličine, koja su korišćena za ANN treniranje, ANN validacionu proceduru i kao referenca za verifikaciju predloženog pristupa, respektivno. Merni EEG proces nije pokazao abnormalnosti i klasifikovan je od strane doktora specijaliste kao pozadinska EEG aktivnost sa prisustvom alfa talasa koji su uobičajeni za odrasle osobe, a pojavljuju se sa zatvaranjem očiju i u relaksiranom stanju [130].



Sl. 7.2. Lokacija EEG elektroda (internacionalni 10-20 sistem) [131].

7.2.1. EKSTRAKCIJA EEG POZADINSKE AKTIVNOSTI

Varijacije osnovne linije EEG procesa predstavljaju komponentu najnižeg frekvencijskog opsega koja se često naziva i kao *near-DC* komponenta. Pošto je ova sporo promenljiva EEG komponenta izrazito osetljiva na brojne artefakte, ona se obično ne uzima u obzir u kliničke svrhe. U cilju određivanja varijacija osnovne EEG linije, merni EEG signal je usrednjen pomoću adekvatno odabranog pokretnog vremenskog intervala, odnosno prozora [132]. Proces usrednjavanja je sproveden na osnovu:

$$u(t_i) = \frac{1}{T} \sum_{k=i-\frac{T}{2}}^{i+\frac{T}{2}} r(t_k), \quad (7.3)$$

gde $u(t)$ označava spore varijacije osnovne EEG linije, T označava dužinu vremenskog prozora, a $r(t)$ predstavlja vrednost izmerenog EEG signala u vremenskom trenutku $t_i = it_s$, pri čemu t_s predstavlja periodu odabiranja.

Određivanje optimalne dužine prozora T je od velike važnosti. Na sličan način kao što je opisano u Sekciji 5.2.1, u slučaju da je interval za usrednjavanje predugačak, gubi se informacija o varijacijama osnovne linije EEG procesa. Sa druge strane, ako je interval za usrednjavanje prekratak onda se karakteristike pozadinske EEG aktivnosti ne mogu sagledati u potpunosti. Imajući navedeno na umu, vremenski interval prozora je odabran da iznosi 0.5s, odnosno 500 EEG odbiraka, kao što je to i predloženo u [132]. Odvajanjem proračunatih varijacija osnovne EEG linije iz mernog EEG signala dobijena je “čista” pozadinska EEG aktivnost:

$$x(t) = r(t) - u(t). \quad (7.4)$$

U ostatku ove glave je pojam vrednosti pozadinske EEG aktivnosti naznačen jednostavnije kao EEG vrednost.

7.2.2. KORELACIONE KARAKTERISTIKE SNIMLJENOG EEG PROCESA

Pošto je estimacija sledeće EEG vrednosti vršena na osnovu sekvence prethodnih EEG vrednosti, neophodno je bilo uzeti u obzir korelacione karakteristike ekstrahovanog EEG procesa. Zbog toga je posebna pažnja posvećena analizi ACF-a dobijenih EEG vrednosti. Zapravo, ACF je proračunat u formi autokorelacionih koeficijenata prema (5.16). Broj korelisanih EEG odbiraka je određen brojem EEG odbiraka za koji je potrebno pomeriti referentnu sekvencu da bi vrednost ACF-a pala po prvi put ispod odabranog korelacionog praga. Kao što je to predloženo u [5], za prag je uzeta vrednost ACF-a 0.2. Na taj način je određeno da je broj korelisanih EEG odbiraka bio 43. Drugim rečima, određeni EEG odbirak je korelisan sa prethodnim odbircima koji se nalaze unutar vremenskog prozora od 43ms.

7.3. ANN PRISTUP EEG SIMULACIJI

Predmet ove glave je primena simulacione metode, predložene u Glavi 5, u cilju simuliranja EEG procesa zdrave, odrasle osobe. Cilj je bio konstruisanje EEG simulatora i njegova optimizacija nad izmerenim EEG procesom. Predloženi EEG simulator je baziran na ANN-u koji je treniran nad eksperimentalno dobijenim podacima. Prednost takvog pristupa je, zapravo, što se oslanja na realni EEG proces, a ne na teorijski definisane EEG parametre koji često ne pružaju zadovoljavajuće rezultate.

Kao što je i napomenuto, osnovna ideja predloženog pristupa je estimacija naredne EEG vrednosti na osnovu sukcesivnih EEG vrednosti koje joj prethode i njihovih korelacionih

karakteristika. Zbog toga je neuralna mreža, trenirana nad mernim EEG podacima, korišćena kao što je to prikazano na Sl. 5.5, gde u ovom slučaju $x(t_i)$ predstavlja i -tu EEG vrednost. Tačnije, zadatak ANN-a je estimacija naredne EEG vrednosti na osnovu ulaznog vektora od L prethodnih EEG odbiraka. Pošto je cilj generisati stohastički proces, primenjen je i koncept DS signala, predložen u Poglavlju 5.4, koji je optimizovan za slučaj stohastičke navigacije ANN-a kroz EEG simulaciju. Iz tog razloga je, pored sekvence od L susednih EEG odbiraka, uzet i DS kao poslednji element ulaznog ANN vektora koji je označavao smer u kom je bilo potrebno generisati narednu EEG vrednost. U skladu sa navedenim, poslednji element ulaznog ANN vektora, odnosno i -ta DS vrednost je označena na Sl. 5.5 sa $d(t_i)$. Odgovarajući DS generator je konstruisan u cilju generisanja DS vrednosti tokom simulacije. DS generator je navodio ANN mrežu na osnovu statističkih karakteristika izmerenog EEG signala i generatora slučajnih brojeva. Poglavlje 7.4 detaljnije opisuje DS generator koji je primenjen za potrebe EEG simulacije.

Na sličan način kao što je opisano u Poglavlju 5.3, sprovedena je inicijalizacija ulaznog ANN vektora na početku simulacionog postupka. Segment ulaznog vektora koji predstavlja ulaznu EEG sekvencu je inicijalizovan nasumično odabranim brojevima. Sa druge strane, kao poslednji element ulaznog vektora uzeta je DS vrednost generisana DS generatorom. Zatim je celokupni ulazni ANN vektor propagiran kroz ANN i generisana je naredna EEG vrednost. U okviru sledeće iteracije, najpre je izvršeno pomeranje vrednosti prethodno propagiranog ulaznog ANN vektora. Pomeranje vrednosti ulaznog ANN vektora je sprovedeno na takav način da je generisana vrednost zauzela mesto odgovarajućeg elementa EEG segmenta, dok je poslednja vrednost EEG segmenta izostavljena. Uspostavljanjem modela zatvorene povratne sprege koji se zasniva na poznatom modelu TDNN-a [4], cilj je bio da se korelacione karakteristike originalnih EEG podataka prenesu generisanom EEG procesu. U isto vreme je generisana DS vrednost zauzela mesto poslednjeg elementa ulaznog ANN vektora. Ponavljanjem opisane procedure generisan je odgovarajući niz EEG vrednosti.

7.4. KONCEPT VODEĆEG SIGNALA U EEG SIMULACIJI

Kao što je i pretpostavljeno na osnovu izloženog u Poglavlju 5.4, kada su trening i simulacione procedure sprovedene nad ulaznim ANN vektorima koji se sastoje samo od EEG vrednosti, odnosno izostavljanjem DS elementa ulaznog vektora iz modela prikazanog na Sl. 5.5, nisu dobijeni zadovoljavajući rezultati. Zapravo, izlaz ANN-a je i u tom slučaju pokazao karakteristike prigušenih oscilacija. Time je potvrđen zaključak izložen u Poglavlju 5.4 da je neophodno uvesti stohastičku komponentu u model da bi se izbegao ulazak ANN-a u stacionarno stanje. Zbog toga je odgovarajući DS element, optimizovan nad mernim EEG procesom, dodat ulaznom ANN vektoru. Uloga DS elementa bila je stohastičko naznačavanje smera u kom je potrebno generisati sledeću EEG vrednost.

DS element je mogao uzeti jednu od dve moguće vrednosti -1 ili +1. Negativna DS vrednost označava da se EEG vrednost koju treba generisati nalazi na opadajućoj strani EEG krive. Sa druge strane, pozitivna DS vrednost označava uzlaznu stranu EEG krive. Drugim rečima, ako je DS vrednost -1, onda je sledeću EEG vrednost potrebno generisati kao manju vrednost u poređenju sa prethodnom. Sa druge strane, ako je DS vrednost +1, onda je potrebno da sledeća EEG vrednost bude generisana kao veća vrednost u poređenju sa EEG vrednošću koja joj prethodi.

U skladu sa zaključcima izvedenim u Poglavlju 5.4, a koji su, takođe, potvrđeni i u slučaju EEG-a, konstruisan je odgovarajući DS ekstraktor koji proračunava DS vrednosti na osnovu originalnih EEG odbiraka i na taj način navodi ANN kroz trening proceduru. Sa druge strane, u cilju navođenja simulacione procedure implementiran je DS generator koji generiše nove DS vrednosti na osnovu DS sekvence koja joj prethodi.

7.4.1. EKSTRAKCIJA VODEĆEG SIGNALA

Da bi se izvršila ekstrakcija DS vrednosti iz izmerenog EEG procesa, a po ugledu na opis iz Sekcije 5.4.1, konstruisan je DS ekstraktor prikazan na Sl. 5.6, gde $x(t_n)$ predstavlja EEG vrednost, a $d(t_n)$ DS vrednost u trenutku t_n . Kao što je i predloženo, DS ekstraktor se sastojao iz dve jedinice. Prva jedinica je korišćena za određivanje razlike između dve susedne EEG vrednosti prema jednačini (5.17). Dobijena razlika $\Delta x(t_n)$ je uzeta kao ulaz druge jedinice. Zadatak druge jedinice je određivanje znaka ulazne vrednosti koja predstavlja razliku dve susedne EEG vrednosti. Stoga je druga jedinica DS ekstraktora implementirana sa signum funkcijom prenosa (5.18).

Odgovarajuća DS vrednost je generisana propuštanjem dve uzastopne ulazne EEG vrednosti kroz DS ekstraktor. Obradom celokupnog EEG signala, odnosno propuštanjem po dva sukcesivna EEG odbirka kroz DS ekstraktor, generisana je odgovarajuća sekvenca DS vrednosti. DS ekstraktor je na opisani način korišćen za navođenje ANN-a kroz trening proceduru, odnosno radi obučavanja neuralne mreže kako da pravilno interpretira ulazni DS element.

7.4.2. GENERATOR VODEĆEG SIGNALA

DS generator, prikazan na Sl. 5.8, je korišćen za generisanje DS vrednosti koje su navodile simulacionu proceduru. Cilj je bio da se generiše nova DS vrednost na osnovu prethodnih DS vrednosti. Po ugledu na opis DS generatora iz Sekcije 5.4.2, najpre su analizirane statističke osobine DS sekvence ekstrahovane iz izmerenog EEG signala. Zapravo, određene su uslovne verovatnoće P_d da će DS vrednost $d(t_n)$ biti generisana na izlazu DS generatora nakon određene sekvence od S uzastopnih DS vrednosti prema (5.19). Od velike važnosti bilo je odrediti optimalnu dužinu, odnosno najveći broj S , takav da se svaka od 2^S mogućih DS sekvenci može locirati u ekstrahovanom DS signalu. Imajući ovo u vidu, analiziranjem izmerenog EEG procesa zaključeno je da optimalna dužina DS sekvence za procenu naredne DS vrednosti iznosi $S = 5$. Zatim je, u cilju proračuna odgovarajuće uslovne verovatnoće, broj pojavljivanja određene DS sekvence nakon koje sledi odgovarajuća DS vrednost $d(t_n)$ podeljen ukupnim brojem pojavljivanja te DS sekvence. Na taj način su proračunate uslovne verovatnoće za svaku od 2^5 mogućih DS sekvenci i sačuvane unutar *lookup* tabele DS generatora (primer *lookup* tabele je prikazan u Tab. 5.1).

DS generator je implementiran sa memorijom koja je držala u svakom momentu tačno pet sukcesivnih DS vrednosti. U skladu sa predloženom procedurom u Sekciji 5.4.2, memorija DS generatora je na početku simulacione procedure inicijalizovana nasumično odabranim DS vrednostima. U cilju procene naredne DS vrednosti u skladu sa proračunatim uslovnim verovatnoćama, implementiran je i generator slučajnih brojeva unutar DS generatora. Zavisno od rezultata poređenja vrednosti na izlazu generatora slučajnih brojeva i uslovne verovatnoće za DS sekvencu u memoriji, generisana je odgovarajuća DS vrednost na izlazu DS generatora.

DS vrednosti su pomerane unutar memorije na početku svake sledeće iteracije. Pomeranje je vršeno na takav način da generisana DS vrednost ulazi u memoriju, dok poslednja DS vrednost u nizu izlazi iz nje. Naredna DS vrednost je generisana u saglasnosti sa novom DS sekvencom koja se nalazi u memoriji. DS vrednosti su generisane ponavljanjem opisanog postupka tokom celokupne EEG simulacione procedure.

7.5. OPTIMIZACIJA ANN SIMULATORA EEG PROCESA

Na osnovu zaključaka iznetih u Poglavlju 5.5, MFNN je odabran za EEG simulaciju kao jedan od najčešće korišćenih pristupa modelovanju, estimaciji i predikciji stohastičkih procesa [4], [133]-[135]. U cilju dizajniranja simulatora EEG procesa, neophodno je bilo izvršiti optimizaciju težinskih koeficijenata neuralne mreže. Kao što je to i predloženo u Sekciji 5.5.3, optimalni skup ANN težinskih koeficijenata je određen tokom trening procedure koja je sprovedena korišćenjem EBP pravila učenja [4], kao jednog od najčešće primenjenih pravila učenja [136], [137].

7.5.1. ARHITEKTURA NEURALNE MREŽE

Najpre, neophodno je bilo odrediti arhitekturu i tip neuralne mreže. Između ostalog, ovo je podrazumevalo određivanje broja ANN ulaza i izlaza. Kao što je i predloženo u Sekciji 5.5.1, da bi se optimizovao broj ulaznih EEG vrednosti, uzeta je u obzir analiza korelacionih karakteristika izmerenog EEG signala, opisana u Sekciji 7.2.2. Stoga je zaključeno da optimalni broj sukcesivnih EEG odbiraka pomoću kojih se vrši estimacija iznosi $L = 43$, pošto je to broj korelisanih EEG odbiraka. Pored sekvence sukcesivnih EEG vrednosti, DS vrednost je uzela mesto poslednjeg elementa ulaznog ANN vektora. Sa druge strane, broj ANN izlaza je direktno uslovljen činjenicom da je potrebno generisati jednu EEG vrednost po simulacionoj iteraciji. Zbog toga je korišćena neuralna mreža imala samo jedan izlaz.

MFNN podrazumeva mogućnost postojanja jednog ili više skrivenih slojeva ispred izlaznog sloja. Odabir unutrašnje strukture ANN-a podrazumeva određivanje broja skrivenih slojeva, kao i broj neuronskih jedinica unutar ovih slojeva. U skladu sa Sekcijom 5.5.2, prihvaćeno je dobro poznato stanovište da se broj neurona u svakom sledećem skrivenom sloju smanjuje i konvergira ka broju neurona u izlaznom sloju. Štaviše, usvojeno je da broj neurona u prvom skrivenom sloju bude značajno veći u poređenju sa brojem elemenata ANN ulaznog vektora. Na ovaj način, omogućeno je da ANN lakše kvantifikuje i grupiše ulaznu informaciju na manje porcije što potpomaže proceduru učenja [57], [138].

Optimalna unutrašnja ANN struktura je određena empirijski [139]. Kao i u Sekciji 5.5.2, sproveden je i analiziran veći broj trening/simulacionih procedura korišćenjem jednog, dva, tri i četiri skrivena sloja. U isto vreme, variran je i broj neuronskih jedinica u svakom sloju. Simulacije su sprovedene primenom modela zatvorene povratne sprege i DS generatora, kao što je prikazano na Sl.5.5. Generisane EEG sekvence su upoređene sa izmerenom EEG sekvencom analiziranjem kvalitativnih metrika detaljnije opisanih u narednom Poglavlju 7.6. Analizom dobijenih rezultata zaključeno je da je neuralna mreža koja se sastoji od dva skrivena sloja pokazala nabolje rezultate. Tačnije, u pitanju je mreža koja se sastoji od 160 neurona u prvom skrivenom sloju, 80 u drugom i od jednog izlaznog

neurona. Veći broj neurona, odnosno težinskih koeficijenata, proizvodi više lokalnih minimuma bliskih globalnom na površini kriterijumske funkcije što je dodatno potpomoglo pretragu za globalnim minimumom od strane minimizacionog algoritma [57]. Imajući u vidu zadatak koji ANN treba da izvrši, svi neuroni su implementirani sa sigmoidalnom funkcijom izuzev izlaznog koji je implementiran sa linearnom aktivacionom funkcijom.

7.5.2. TRENING i VALIDACIJA NEURALNE MREŽE

U cilju optimizacije ANN težinskih koeficijenata za simulaciju EEG procesa sprovedena je ANN trening procedura. Za potrebe treniranja je povratna sprega modela prikazanog na Sl.5.5 prekinuta, odnosno izostavljena je veza između ANN izlaza i odgovarajućeg elementa ulaznog vektora. Za ANN treniranje je korišćen prvi skup izmerenih EEG vrednosti, sa tačno $4.0 \cdot 10^5$ EEG odbiraka. Ulazno/izlazni parovi su nasumično birani iz datog skupa EEG vrednosti. U skladu sa predloženim trening postupkom u Sekciji 5.5.3, ulazni ANN vektori su se sastojali od 43 sukcesivna EEG odbirka, dok su za ciljne vrednosti uzeti EEG odbirci koji slede odgovarajuću ulaznu sekvencu. EEG vrednosti trening skupa su normalizovane na interval vrednosti $[-1, +1]$ prema konvencionalnoj trening proceduri [4]. Ekstrahovana DS vrednost je uzeta kao poslednji element ulaznog ANN vektora. Poslednja EEG vrednost ulazne sekvence i ciljna vrednost su propagirane kroz DS ekstraktor pre obrade svakog ulazno/izlaznog para radi ekstrakcije odgovarajuće DS vrednosti. Za inicijalizaciju ANN težinskih koeficijenata i kontrolnih (*bias*) vrednosti, korišćen je Engagen-Vidrov inicijalizacioni algoritam [58]. Kao što je i predloženo u Sekciji 5.5.3, EBP algoritam je odabran kao trening metoda. MSE je korišćen kao kriterijumska funkcija računata između generisanih i ciljnih EEG vrednosti. Trening procedura je sprovedena inkrementalno, odnosno ANN težinskih koeficijenti su korigovani nakon obrade svakog nasumično odabranog ulazno/izlaznog para. Stopa učenja je, kao i u Sekciji 5.5.3, držana konstantnom 0.01 tokom celokupne trening procedure. Trening je zaustavljen nakon 1000 krugova, pri čemu je svaki krug podrazumevao obradu svih ulazno/izlaznih parova trening skupa.


Uz trening, sprovedena je i validaciona procedura da bi se izbegli potencijalni problemi preteranog treniranja ANN-a. Zapravo, prema validacionom postupku predloženom u Sekciji 5.5.3, nakon svakog trening kruga je generisana EEG sekvenca primenom modela prikazanog na Sl. 5.5. Pošto je inicijalno skup trening podataka normalizovan, sprovedena je odgovarajuća denormalizacija ANN izlaznih vrednosti. Generisane EEG sekvence su zatim upoređene sa izmerenom sekvencom od $4.0 \cdot 10^4$ sukcesivnih odbiraka, nasumično odabranih iz validacionog skupa podataka. Poređenje EEG sekvenci je sprovedeno analizom niza kvantitativnih i kvalitativnih parametara koji su pobrojani u Poglavlju 7.6. Poređenje je sprovedeno primenom klasične metode bodovanja. Tačnije, poređeni su parovi EEG sekvenci, pri čemu je bod dat onoj sekvenci koja je za određeni poredbeni parametar pokazala bolje rezultate, a sekvenca sa više sakupljenih bodova je uzeta u obzir za dalje poređenje. Na taj način je identifikovana optimalna EEG sekvenca, odnosno određen je optimalni skup ANN težinskih koeficijenata. Na osnovu sprovedene validacione procedure zaključeno je da su optimalni ANN koeficijenti dobijeni nakon 225. trening kruga i da dalje treniranje nije pokazalo poboljšanje.

7.6. PERFORMANSE I EVALUACIJA EEG SIMULATORA


Predložena metoda je verifikovana naspram performansi postojećeg pristupa koji se bazira na ARMA filtriranju, a koji je odabran kao jedna od efikasnih metoda simulacije EEG procesa [110]. Poređenje performansi je sprovedeno analizom različitih kvantitativnih i kvalitativnih parametara u vremenskom i frekvencijskom domenu. Sekvenca od $4.0 \cdot 10^4$ sukcesivnih EEG odbiraka, nasumično odabranih iz verifikacionog skupa, uzeta je kao referenca za poređenje. Radi boljeg uvida u razlike simuliranog i izmerenog EEG procesa, rezultati poređenja predstavljeni u ovom poglavlju su dobijeni usrednjavanjem ansambla pojedinačnih rezultata poređenja koji se sastojao od 10 nasumično odabranih simulacionih procedura. Sekvenca od $4.0 \cdot 10^4$ EEG odbiraka je generisana u okviru svake simulacione procedure.

7.6.1. POREĐENJE PDF I CDF PARAMETARA EEG PROCESA

Jedna od uobičajenih poredbenih mera u vremenskom domenu se zasniva na analizi verovatnoće pojave određene EEG vrednosti na izlazu simulatora [140]. Proračunati PDF i CDF analiziranih simulacionih metoda prikazani su na Sl. 7.3 i Sl. 7.4, respektivno. Dodatno, MSE vrednosti proračunatih PDF i CDF parametara su uzete kao kvantitativna mera razlike generisanog i referentnog EEG signala dobijenog merenjima. Proračunate MSE vrednosti su prikazane u Tab. 7.2. U Tab. 7.2, kao i u nastavku ovog poglavlja, crvenom bojom su naznačeni najbolji rezultati, dok su teorijski definisani parametri naznačeni sivom bojom. Na osnovu dobijenih rezultata može se primetiti da je predložena metoda u dobrom slaganju sa merenjima i da je dala rezultate za red veličine bolje u poređenju sa metodom koja se bazira na ARMA filtriranju.




Sl. 7.3. Funkcija gustine verovatnoće EEG procesa.




Sl. 7.4. Kumulativna funkcija raspodele EEG procesa.

7.6.2. POREĐENJE LCR I ADF PARAMETARA EEG PROCESA

Analizirani zajedno, LCR i ADF parametri pružaju jedan od načina za karakterizaciju intenziteta varijacija EEG signala tokom vremena [2]. LCR predstavlja očekivanu učestanost kojom EEG signal prelazi određeni nivo signala u pozitivnom smeru, od niže ka višoj EEG vrednosti. Sa druge strane, ADF označava srednje vreme koje EEG signal provede ispod određenog praga. Proračunati LCR i ADF parametri analiziranih simulacionih metoda prikazani su na Sl. 7.5 i Sl. 7.6, respektivno. Dodatno, MSE vrednosti dobijenih LCR i ADF parametara su uzete kao kvantitativna mera razlike generisanog i referentnog EEG signala koji je dobijen merenjima. Proračunate MSE vrednosti su prikazane u Tab. 7.2. Sa Sl. 7.6 se može primetiti da postoje neznatne devijacije ADF parametara analiziranih simulacionih metoda za EEG vrednosti ispod $-10\mu\text{V}$. Međutim, pošto su ADF vrednosti predstavljene na logaritamskoj skali, ove devijacije ne doprinose znatnije ukupnoj MSE vrednosti. Analiziranjem rezultata prikazanih u Tab. 7.2, može se primetiti da je predloženi ANN simulator pokazao bolje rezultate u poređenju sa pristupom koji se bazira na ARMA filtriranju u slučaju LCR, kao i u slučaju ADF parametra.




Sl. 7.5. LCR parametar EEG procesa.



Sl. 7.6. ADF parametar EEG procesa.

7.6.3. POREĐENJE KORELACIONIH KARAKTERISTIKA

Radi poređenja korelacionih osobina generisanih i izmerenog EEG procesa, sprovedena je analiza ACF-a kvadrata EEG signala [141]. ACF kvadrata generisanih EEG signala prikazan je na Sl.7.7. Takođe, MSE dobijenih vrednosti ACF-a je uzet kao kvantitativna mera razlike generisanih i izmerenog EEG signala. Proračunate MSE vrednosti su prikazane u Tab.7.2. Na osnovu dobijenih rezultata može se zaključiti da je ANN simulator generisao zadovoljavajuće korelacione osobine EEG procesa koje su u boljem slaganju sa merenjima u poređenju sa pristupom koji se bazira na ARMA filtriranju.



Sl. 7.7. Autokorelacija kvadrata EEG signala.

Tab. 7.2. MSE vrednosti PDF, CDF, LCR, ADF parametara i ACF-a kvadrata EEG signala.

	ANN	ARMA filtriranje
MSE(PDF)	$1.51 \cdot 10^{-6}$	$1.34 \cdot 10^{-5}$
MSE(CDF)	$2.92 \cdot 10^{-5}$	$2.40 \cdot 10^{-4}$
MSE(LCR)[prelaza ² /s ²]	$2.94 \cdot 10^{-1}$	1.30
MSE(ADF) [s ²]	$2.76 \cdot 10^{-3}$	$9.38 \cdot 10^{-3}$
MSE(SqACF)	$9.19 \cdot 10^{-4}$	$1.46 \cdot 10^{-2}$

7.6.4. POREĐENJE MARGINE SNAGE

Odstupanje generisanog od izmerenog EEG procesa se može proceniti kvalitativnim merama predloženim u [59]. Prva mera, koja se naziva *mean basis* margina snage, data je jednačinom (5.20), dok je druga, *maximum basis* margina snage, definisana jednačinom (5.21). Na osnovu ACF-a kvadrata EEG signala prikazanih na Sl.7.7 dobijene su odgovarajuće matrice kovarijanse koje ulaze u proračun margine snage. Autokorelaciona sekvenca dužine $l = 200$ je korišćena za proračun (5.20) i (5.21). Za referencu je uzet ACF kvadrata izmerenog EEG signala. Dobijene vrednosti margine snage su prikazane u Tab. 7.3

(označene kao $\mathcal{G}_{mean}$ i $\mathcal{G}_{max}$). Idealno generisanom EEG procesu odgovara vrednost 0dB za obe margine snage. Imajući ovo u vidu, prema prikazanim rezultatima predložena ANN metoda je u boljem slaganju sa merenjima nego metoda ARMA filtriranja.

7.6.5. POREĐENJE WMSAE PARAMETRA


Za procenu kvaliteta generisanog slučajnog procesa u [60] korišćen je WMSAE parametar kao poredbena metrika. Ova poredbena metrika je definisana jednačinom (5.22). Proračunate WMSAE vrednosti obe analizirane metode su prikazane u Tab.7.3. Bitno je napomenuti da je aproksimacija bolja što je parameter $\Gamma(p)$ manji. Imajući ovo u vidu, može se primetiti da su rezultati dobijeni predloženim ANN simulatorom u boljem slaganju sa merenjima u poređenju sa metodom ARMA filtriranja.

Tab. 7.3. Margina snage i WMSAE.

	$\mathcal{G}_{mean}$ [dB]	$\mathcal{G}_{max}$ [dB]	Γ [dB]
ANN	0.27	0.29	-18.25
ARMA filtriranje	0.70	0.75	-7.77

7.6.6. EEG SIGNAL U VREMENSKOM DOMENU

U cilju kvalitativne vizuelne inspekcije EEG procesa u vremenskom domenu, nasumično odabrani segmenti generisanih EEG sekvenci su prikazani na Sl.7.8. Analiziranjem prezentovanih EEG signala može se zaključiti da su obe simulacione metode generisale sekvence prilično slične izmerenoj.




Sl. 7.8. EEG signal u vremenskom domenu: (a) merenja, (b) ANN metoda i (c) metoda ARMA filtriranja.

7.6.7. EEG SIGNAL U FREKVENCIJSKOM DOMENU

Radi analize generisanih EEG signala u frekvencijskom domenu, proračunati su jednostrani EEG spektri [142] pomoću Furijeove transformacije. Analizirane su anvelope jednostranog EEG spektra, proračunate nad ansamblom od 10 nasumično odabranih sekvenci. Proračunate anvelope EEG spektra su prikazane na Sl. 7.9. Kao referenca je prikazana i anvelopa jednostranog EEG spektra izmerenog EEG procesa. Poređenjem u odnosu na izmereni EEG proces, predloženi ANN pristup je pokazao približno sličnu raspodelu energije u svim frekvencijskim opsezima, osim u opsegu delta i delimično beta talasa [104], gde su spektralne komponente generisane sa neznatno manjom energijom. Međutim, na osnovu Sl. 7.9, može se primetiti da je frekvencijski spektar proizveden primenom ANN simulatora bliži merenjima u poređenju sa metodom ARMA filtriranja. Takođe, može se primetiti da je predložena metoda znatno bolje rekonstruisala alfa pik snimljenog EEG signala.

Ujedno je proračunata i totalna energija spektralnih komponenti u opsegu 0-50Hz kao kvantitativna mera razlike spektra generisanih i izmerenog EEG signala. Dobijeni rezultati koji ilustruju totalnu energiju frekvencijskog spektra izmerenog EEG signala i prosečnu totalnu energiju spektra generisanog analiziranim simulacionim metodama su predstavljeni u Tab. 7.4. Na isti način, proračunate su i WSE vrednosti prema (7.2), a odgovarajući rezultati su dati u Tab. 7.4. Na osnovu izvršene analize može se zaključiti da je ANN simulator pokazao bolje celokupne spektralne osobine u poređenju sa metodom ARMA filtriranja.



Sl. 7.9. Jednostrani spektar izmerenog EEG signala i odgovarajuće anvelope spektra dobijenog ANN metodom i ARMA filtriranjem.

Tab. 7.4. Totalna energija i WSE.

	Totalna energija	WSE
Merenja	127.60	-
ANN	110.15	311.93
ARMA filtriranje	104.50	363.10

7.6.8. RAČUNSKA KOMPLEKSNOŠT

Analiza vremena potrebnog za izvršavanje simulacije EEG signala je sprovedena radi procene računске kompleksnosti predložene i postojeće simulacione metode. Primenom analiziranih metoda generisane su sekvence od 10^6 EEG odbiraka u Matlab-u na računaru sa Intel Core i7 CPU-om (Q 820 @ 1.73GHz). Vreme potrebno za generisanje jedne EEG vrednosti u slučaju ANN metode, pri čemu je ANN model implementiran u paraleli sa DS generatorom, bilo je 3.6189ms. Ujedno je DS generatoru bilo potrebno 0.0229ms da generiše jednu DS vrednost. Sa druge strane, 0.6976μs je bilo potrebno metodi zasnovanoj na *coloring* matrici da generiše jedan EEG odbirak. Dobijeni rezultati ukazuju da je postojeća metoda pokazala bolje performanse u poređenju sa predloženom metodom po pitanju vremena

izvršavanja simulacionog procesa. Pošto su merni podaci dobijeni periodom odabiranja od 1ms, zaključeno je da se predložena ANN metoda u ovom konkretnom slučaju (za datu periodu odabiranja i broj korelisanih EEG vrednosti) može koristiti za potrebe tzv. *offline* simulacije. Imajući u vidu svakodnevno tehnološko unapređenje računarskih resursa i performansi, za očekivati je da će predložena metoda zadovoljiti i zahteve u realnom vremenu u skorijoj budućnosti. Takođe, treba uzeti u obzir da će moguća implementacija ANN metode na posebno dizajniranom hardveru dodatno poboljšati performanse ANN metode.

Dodatno, u cilju poređenja modela ANN simulatora i ARMA filtra istog reda (sa stanovišta dimenzija ulaznog ANN vektora i reda ARMA filtra), sprovedene su i GA optimizacione procedure nad koeficijentima filtra 43. reda. Ove optimizacione procedure nisu konvergirale ka stabilnom skupu koeficijenata filtra i zbog toga nisu uzete u dalje razmatranje. Takođe, oba modela su verifikovana i nad EEG signalom dobijenim frekvencijom odabiranja 200Hz, kao što je to i originalno urađeno radi validacije modela ARMA filtra u okviru [110]. Zbog niže frekvencije odabiranja, ANN model je pojednostavljen, odnosno ulazni vektor je sadržao manje korelisanih EEG odbiraka. Međutim, u ovom slučaju nije došlo do značajnijeg poboljšanja. Tačnije, za pojedine poredbene mere dobijeni su i lošiji rezultati u poređenju sa rezultatima koji su prethodno prezentovani u ovom poglavlju. Pristup baziran na ARMA filtriranju je pokazao neznatna poboljšanja u frekvencijskom domenu (alfa pik je rekonstruisan bolje), ali rezultati ostalih poredbenih mera nisu bili zadovoljavajući.

Premda je cilj bio da se simulira EEG signal jednog subjekta, ANN pristup je, takođe, verifikovan nad EEG signalima druge dve zdrave odrasle osobe, izmerenim pod istim uslovima. Bez novog ili dodatnog treniranja, ANN model analiziran u ovom poglavlju je pokazao slične rezultate i u poređenju sa druga dva EEG signala koja su dodatno merena, ali neznatne devijacije su postojale zbog statističkih specifičnosti svakog EEG procesa. Na osnovu dobijenih rezultata može se zaključiti da se zadovoljavajući stepen generalizacije može postići jednom optimizacionom procedurom ANN-a.

7.7. ZAKLJUČNI KOMENTARI

Simulaciona metoda koja se bazira na principima ANN-a, predložena u Glavi 5, dodatno je verifikovana za potrebe simuliranja EEG signala kao jednog od kompleksnih stohastičkih procesa. Cilj je bio simulacija spontane pozadinske EEG aktivnosti. Drugim rečima, potrebno je bilo konstruisati simulator EEG procesa sa statističkim osobinama EEG procesa koji je dobijen merenjima. Optimizacija predloženog ANN simulatora je zasnovana isključivo na eksperimentalno dobijenim EEG podacima. Da bi se snimila pozadinska EEG aktivnost ljudskog mozga, sprovedena je EEG merna kampanja na zdravoj odrasloj osobi. Merenja su izvršena u kontrolisanom okruženju nad budnim subjektom koji je sedeo u relaksiranom stanju, bez kognitivnog angažmana. Izmereni EEG podaci su korišćeni potom za potrebe ANN treniranja i validacione procedure.

Radi verifikacije performansi ANN pristupa EEG simulaciji, sprovedena su poređenja u odnosu na postojeći pristup ARMA filtriranja [110] koji je odabran kao jedna od efikasnih simulacionih metoda. Niz kvantitativnih i kvalitativnih poredbenih metrika u vremenskom i frekvencijskom domenu je analiziran radi potpunijeg uvida u performanse simulacionih metoda. Ovo je podrazumevalo, pored proračuna PDF i CDF parametara koji su standardno

deo EEG statističke analize u vremenskom domenu, i analiziranje LCR i ADF parametara generisanih EEG procesa. Dodatno su autokorelacione osobine, margine snage i WMSAE uzeti u obzir. Sa druge strane, dobijeni simulacioni rezultati su verifikovani u frekvencijskom domenu analiziranjem EEG spektralnih karakteristika. Takođe je i računska kompleksnost analiziranih simulacionih metoda uzeta u razmatranje. Na osnovu dobijenih rezultata, može se zaključiti da je EEG signal generisan primenom predložene ANN metode u zadovoljavajućem slaganju sa izmerenim EEG signalom. Štaviše, može se primetiti da je predložena ANN metoda pokazala bolje performanse u poređenju sa postojećom metodom ARMA filtriranja. Radi uvida u perdnosti i mane analiziranih simulacionih metoda, pregled rezultata poređenja kvantitativnih parametara dat je u Tab. 7.5 (štiklirani su najbolji rezultati). Na osnovu Tab. 7.5 može se zaključiti da je ANN metoda pokazala bolje rezultate za 10 od ukupno 11 poredbenih parametara. Dodatno je ANN model pokazao bolju stabilnost u poređenju sa modelom ARMA filtra. Pošto je validacija nad EEG signalima druga dva subjekta dala slične rezultate, zaključeno je da se zadovoljavajući stepen generalizacije može postići jednom optimizacionom procedurom ANN modela. Uprkos činjenici da su ANN trening i validacioni procesi računski zahtevni, predloženi simulator je nakon optimizacije ANN težinskih koeficijenata pokazao zadovoljavajuće performanse i u realnom vremenu. Na osnovu celokupnih poredbenih rezultata, može se zaključiti da se predložena ANN metoda može uspešno koristiti za simulaciju ljudske pozadinske EEG aktivnosti.

Tab. 7.5. Pregled najboljih poredbenih rezultata analiziranih simulacionih metoda.

Simulaciona metoda	ANN	ARMA filtriranje
PDF	✓	
CDF	✓	
LCR	✓	
ADF	✓	
SqACF	✓	
$\mathcal{G}_{mean}$	✓	
$\mathcal{G}_{max}$	✓	
Γ	✓	
Totalna energija	✓	
WSE	✓	
Računska kompl.		✓
Rezultat	10	1

8. ZAKLJUČAK

Rezime. U okviru ove glave izvedena su zaključna razmatranja i analiza istraživanja sprovedenog u okviru doktorske disertacije. Takođe, razmatrane su i smernice za dalja istraživanja u cilju unapređenja predloženih simulacionih metoda.

Pojam radio kanala opisuje medijum za prenos informacija u zemaljskim mobilnim radio sistemima. Zapravo, radio kanal u kontekstu mobilnih komunikacionih sistema podrazumeva niže slojeve atmosfere, u blizini Zemljine površine. Usled kompleksnosti karakteristika radio kanala, složene zakonitosti propagacije radio talasa, kao i promene uslova propagacije u vremenu, intenzitet električnog polja na prijemu varira. Nezavisno od toga da li između predajne i prijemne antene postoji direktna optička vidljivost, u tipičnim propagacionim uslovima do prijemnika stiže veći broj replika izvornog signala. Kao posledica navedenog, prijemni signal gubi svoje determinističke karakteristike i postaje slučajan u vremenu i prostoru, što se opisuje pojmom fedinga. Oslanjajući se samo na fizičke zakone propagacije, odnosno na deterministički pristup, nije moguće proceniti spomenute varijacije prijemnog signala. Praktično, jedino je moguće govoriti o verovatnoći određenog nivoa polja na prijemu na osnovu velikog broja merenja i odgovarajuće statističke analize izmerenih vrednosti.

Kao posledica spomenute stohastičke prirode signala može doći do pada nivoa prijemnog polja i do narušavanja kvaliteta veze. Dodatno, usled različitog kašnjenja replika izvornog signala, dolazi do širenja emitovanog impulsa, tj. do disperzije koja može prouzrokovati intersimbolsku interferenciju. Sa druge strane, korelisani procesi kratkotrajnog fedinga utiču na performanse različitih tehnika prenosa signala, kao što su npr. *diversity* i MQAM tehnike prenosa sa više nosioca. Usled navedenog, feding simulatori su od značaja u procesu razvoja i testiranja komunikacionih uređaja i sistema, kao i prilikom procene performansi bežičnih komunikacionih sistema. Simulacija, kako pojedinačnih, tako i korelisanih feding procesa, već dugi niz godina je od teorijskog i praktičnog interesa. Iako to nije slučaj u praksi, u cilju modelovanja radio kanala se najčešće pretpostavlja da feding podleže "čistoj" Rejlijevoj statističkoj raspodeli. Sa druge strane, kada je reč o komunikacionim sistemima koji primenjuju *diversity* i OFDMA metode, često se podrazumevaju nekorelisane anvelope fedinga na prijemu. Stoga se ovakvim pristupom analizi komunikacionog sistema ne dobija realna slika o performansama sistema. Do danas je u literaturi predložen veći broj različitih tehnika simuliranja feding procesa. Postojeće metode

su najčešće optimizovane i verifikovane u odnosu na teorijske karakteristike fedinga. Merni rezultati konkretnih komunikacionih sistema nisu uzimani u obzir.

Predmet istraživanja doktorske disertacije je simulacija pojedinačnih i korelisanih feding procesa, koja se bazira na principima veštačkih neuralnih mreža (ANN). Cilj predložene simulacione metode je generisanje kratkotrajnog fedinga sa statističkim i korelacionim karakteristikama fedinga izmerenog u konkretnom komunikacionom sistemu. Osnovna ideja predložene metode je optimizacija nad mernim podacima što nije slučaj sa postojećim metodama koje su optimizovane nad teorijskim karakteristikama fedinga. U cilju određivanja modela simulatora i pogodne arhitekture neuralne mreže sproveden je niz simulacionih i validacionih procedura. Takođe, izvršena je i procena optimalnih vrednosti parametara simulacije kao što je broj elemenata ulaznog ANN vektora, dimenzije ANN-a itd.

U okviru doktorske disertacije je, najpre, predložena nova metoda simulacije pojedinačnog procesa kratkotrajnog fedinga koja se zasniva na veštačkim neuralnim mrežama. Simulacione metode kratkotrajnog fedinga, predložene u literaturi, baziraju se ili na SoS metodi, na IDFT algoritmu, ili na WGN filtriranju. Postojeće metode su najčešće optimizovane nad teorijskim karakteristikama fedinga, dok podaci iz realnog komunikacionog sistema nisu analizirani. Sa druge strane, predložena metoda simulacije fedinga je isključivo bazirana na mernim podacima. Cilj predložene metode je simulacija pojedinačnog procesa kratkotrajnog fedinga, tačnije generisanje signala sa statističkim karakteristikama anvelope fedinga iz realnog komunikacionog sistema. Radi prikupljanja mernih podataka, sprovedena su merenja jačine električnog polja u odabranom *indoor* okruženju, u NLoS scenariju. Odbirci fedinga, ekstrahovani iz jačine prijemnog električnog polja, korišćeni su za optimizaciju neuralne mreže. Koncept vodećeg signala (DS) je uveden da bi se izbegao ulazak ANN izlaznog signala u stacionarno stanje. Tačnije, konstruisan je tzv. DS generator u vidu diskretnog Markovljevog lanca koji je određivao smer simulirane vrednosti na osnovu statističkih karakteristika izmerenog feding procesa. Predložena metoda je u cilju verifikacije upoređena sa postojećim simulatorima Rejljevog fedinga. U okviru verifikacije su, takođe, uzete u obzir i teorijske karakteristike Rejljevog fedinga. U cilju poređenja simulacionih metoda analizirano je nekoliko kvalitativnih i kvantitativnih mera. Najpre, upoređeni su PDF, CDF, LCR i ADF parametri generisanih feding procesa. Zatim, analizirane su korelacione karakteristike, margine snage i WMSAE. Slaganjem mernih rezultata sa teorijskim karakteristikama Rejljevog fedinga je potvrđeno da prijemni signal u odabranom okruženju podleže Rejljevom fedingu. Na osnovu dobijenih rezultata, zaključeno je da je predložena metoda generisala bolje rezultate u poređenju sa postojećim simulatorima. Neznatne razlike u performansama predložene i drugih analiziranih metoda dobijene su samo za manji broj poredbenih parametara. Tačnije, od ukupno 8 kvantitativnih parametara, ANN metoda je pokazala najbolje rezultate za pet parametara. Dodatno, poređenjem sa svakom od postojećih simulacionih metoda ponaosob, ANN pristup pokazao je bolje celokupne rezultate uzimajući sve analizirane parametre u obzir.

Predložena je zatim metoda za simulaciju korelisanih procesa kratkotrajnog fedinga zasnovana, takođe, na principima ANN-a. Postojeće metode simulacije korelisanih procesa Rejljevog fedinga su u najvećoj meri optimizovane nad teorijskim karakteristikama Rejljevog fedinga. Optimizaciona procedura predloženog simulatora se sprovodi isključivo nad mernim podacima, odnosno vrednostima korelisanih feding procesa izmerenim u realnom komunikacionom sistemu. Cilj predložene metode je simulacija dva korelisana feding procesa sa statističkim i korelacionim karakteristikama feding procesa izdvojenih iz izmerenih prijemnih signala. Model predloženog simulatora se sastoji od dve neuralne mreže, primarne i sekundarne. Svaka neuralna mreža ponaosob je zadužena za generisanje jednog od dva

korelisana feding procesa. Primarna neuralna mreža je vodeća na osnovu koje sekundarna generiše odgovarajuće vrednosti korelisanog feding procesa. Za optimizaciju neuralnih mreža korišćene su vrednosti fedinga ekstrahovane iz jačine prijemnog električnog polja u odabranom *indoor* okruženju, u NLoS scenariju. Merenja jačine električnog polja su sprovedena za rastojanja prijemnih antena od $\lambda_c/8$ i $\lambda_c/4$. Radi navođenja primarne i sekundarne neuralne mreže kroz simulacioni proces korišćeni su odgovarajući DS generatori. Zarad verifikacije, predložena metoda je upoređena sa postojećom metodom koja se zasniva na *coloring* matrici [63] kao jednoj od često korišćenih metoda za generisanje korelisanih feding procesa. Radi potpunije verifikacije uzete su u obzir i teorijske karakteristike Rejljevog fedinga. Analizom prethodno nabrojanih kvalitativnih i kvantitativnih metrika, zaključeno je da je predložena ANN metoda generisala bolje rezultate u poređenju sa postojećom metodom koja se zasniva na *coloring* matrici. Od ukupno 20 kvantitativnih poredbenih parametara, postojeća metoda je pokazala bolje rezultate samo za tri parametra u oba slučaja rastojanja prijemnih antena $\lambda_c/8$ i $\lambda_c/4$. Dodatno, u slučaju jednog parametra (tačnije po pitanju broja auto-korelisanih odbiraka), za rastojanje prijemnih antena $\lambda_c/4$, obe analizirane metode su pokazale iste performanse.

Imajući u vidu zadovoljavajuće rezultate simulacije kratkotrajnog fedinga, analizirana je i moguća primena predložene metode za potrebe simulacije drugih stohastičkih signala, kako “veštačkih” tako i “realnih” signala iz ljudskog okruženja, koji pokazuju odgovarajuće autokorelacione karakteristike kao i kvazi-periodičnu prirodu oscilacija. Kao jedan od kompleksnih stohastičkih signala sa stanovišta analize, kao i mehanizama koji ga prouzrokuju, jeste EEG signal, fenomen iz stvarnog sveta koji predstavlja meru električne aktivnosti ljudskog mozga. Zapravo, EEG signal kao takav je odabran u cilju verifikacije primene predložene simulacione metode za potrebe simuliranja EEG-a. Tačnije, zadatak je bio da se simulira spontana pozadinska EEG aktivnost, odnosno da se generiše signal sa statističkim karakteristikama izmerenog ljudskog EEG procesa. Stoga je predloženi simulator optimizovan nad eksperimentalno dobijenim EEG podacima. Da bi se prikupile vrednosti pozadinske EEG aktivnosti ljudskog mozga, sprovedeno je merenje EEG-a zdrave odrasle osobe u laboratoriji SIGMA Medizin-Technik GmbH, u Nemačkoj. Subjekt nad kojim su sprovedena merenja je sedeo budan, u kontrolisanom okruženju, bez kognitivnog angažmana. Prikupljeni EEG podaci su zatim korišćeni za ANN trening i validacionu proceduru. Performanse ANN pristupa EEG simulaciji su upoređene sa postojećim pristupom ARMA filtriranja [110] koji je odabran kao jedna od efikasnih i prihvaćenih metoda. Da bi se predloženi pristup verifikovao, analiziran je veći broj kvantitativnih i kvalitativnih poredbenih mera u vremenskom i frekvencijskom domenu. Pored prethodno nabrojanih poredbenih mera, analizirane su i spektralne karakteristike generisanih EEG signala. Na osnovu rezultata verifikacije, može se doneti zaključak da je primenom predložene ANN metode generisan signal koji je u boljem slaganju sa merenjima u poređenju sa postojećom metodom ARMA filtriranja. Tačnije, ANN metoda je pokazala bolje rezultate po svim od ukupno 10 analiziranih kvantitativnih parametara. Takođe, predloženi pristup je pokazao bolje karakteristike po pitanju stabilnosti simulacione metode. Imajući u vidu da je validacija predložene ANN metode u slučaju druga dva subjekta dala zadovoljavajuće rezultate, zaključeno je da se određeni stepen generalizicaije može obezbediti jednom optimizacionom procedurom ANN-a.

Na osnovu rezultata sprovedenih simulacionih procedura, može se doneti zaključak da se predložena metoda zasnovana na veštačkim neuralnim mrežama može koristiti za potrebe simulacije stohastičkih signala koji pokazuju određene autokorelacione karakteristike kao i kvazi-periodičnu prirodu oscilacija. Najpre, može se zaključiti da je primena predložene

metode za simuliranje pojedinačnih i korelisanih signala Rejljevog kratkotrajnog fedinga pokazala zadovoljavajuće rezultate. Pošto su merenja jačine električnog polja sprovedena u *indoor* okruženju koje je okarakterisano nepravilnim mehanizmima propagacije i različitim propagacionim efektima radio talasa, može se očekivati da će predloženo rešenje, nakon odgovarajuće optimizacije neuralnih mreža, pokazati slične performanse i u *outdoor* okruženju. Ujedno, jedna od prednosti predložene metode je i mogućnost simulacije izrazito dugačkih feding sekvenci u formi iterativnog procesa pri čemu se generiše jedna feding vrednost po iteraciji. Takođe, predloženi ANN pristup potencijalno pruža i mogućnost kontinualnog prelaza simulacije sa jednog na drugi tip okruženja, odnosno komunikacionog kanala. U ovom slučaju, jednostavna zamena skupa težinskih koeficijenata mreže kao i statističkih parametara DS generatora koji karakterišu tip željenog komunikacionog kanala omogućava promenu karakteristika izlaznog feding signala u realnom vremenu. Sa druge strane, mogu se konstatovati zadovoljavajući rezultati dobijeni primenom predložene metode za potrebe simuliranja ljudske pozadinske EEG aktivnosti. Imajući prethodno pomenuto u vidu, zadovoljavajuće performanse predložene ANN simulacione metode mogle bi se, takođe, očekivati pri simulaciji drugih stohastičkih signala koji pokazuju slične karakteristike kao i feding proces (po pitanju autokorelacije i kvazi-periodične prirode oscilacija). Navedeni zaključci su uslovljeni pretpostavkom da je odgovarajući skup mernih vrednosti dostupan radi treniranja veštačke neuralne mreže. Iako su ANN trening i validacioni procesi računski zahtevni, na osnovu analize računске kompleksnosti i vremena potrebnog za izvršavanje simulacije, zaključeno je da ANN metoda, nakon sprovedene optimizacije ANN težinskih koeficijenata, zadovoljava zahteve simulacije fedinga u realnom vremenu. Sa druge strane, u slučaju analiziranog EEG procesa je zaključeno da se predložena ANN metoda može koristiti samo za tzv. *offline* simulacije. Štaviše, treba imati na umu da će moguća implementacija predloženog pristupa na mikrokontroleru ili posebno dizajniranom hardveru (kao što je na primer FPGA) dodatno redukovati vreme simulacije.

Mogućnosti za dalje istraživanje i unapređenje predloženih simulacionih metoda su višestruke. Kao jedna od smernica za unapređenje simulatora korelisanih feding procesa je i razvoj simulatora opštije namene uvođenjem posebnog ulaznog parametra sekundarne neuralne mreže koji bi označavao rastojanje prijemnih antena. Time bi se korelacione osobine generisanih signala mogle korigovati u realnom vremenu odgovarajućom promenom dodatog ulaznog parametra. Takođe, jedno od mogućih proširenja predložene metode u cilju simulacije većeg broja korelisanih signala (kao što je to slučaj, na primer, u WiMAX i LTE-A sistemima) je dodavanje novih paralelno povezanih neuralnih mreža (jedan ANN po izlaznom signalu). U pogledu potrebnih resursa za implementaciju na hardveru, spomenuti pristup se može paralelizovati pošto svaki dodati ANN generiše sledeću feding vrednost nezavisno od ostalih neuralnih mreža, odnosno, vrši jedino obradu prošlih vrednosti generisanih od strane drugih mreža. Sa aspekta simulacije EEG signala, jedna od mogućnosti daljeg istraživanja je i simulacija različitih neuroloških EEG aktivnosti koje su predstavljene odgovarajućim ERP komponentama. Ovo podrazumeva simulaciju tranzicije stanja subjekta, abnormalnog EEG procesa, i primenu u dijagnostičkoj i kliničkoj medicini. Takođe, jedan od mogućih istraživačkih zadataka jeste i simulacija istovremenih EEG signala sa različitih elektroda, odgovarajućih korelacionih osobina, uvođenjem dodatnih ANN izlaza u predloženi model.

REFERENCE

- [1] Bertoni H. L., Radio propagation for modern wireless systems, Prentice Hall, 2000.
- [2] Goldsmith A., Wireless communications, Cambridge University Press, 2005.
- [3] Garg V. K., Wireless communications and networking, Elsevier Inc., 2007.
- [4] Hassoun M. H., Fundamentals of artificial neural networks, MIT Press, 1995.
- [5] Lee W. C. Y., Mobile communications design fundamentals, John Wiley & Sons, 1993.
- [6] Godse A. P., Bakshi U. A., Analog communication, Second revision edition, Technical Publications Pune, 2007.
- [7] Veerarajan T., Probability, Statistics And Random Processes, Second edition, Tata McGraw Hill, 2007.
- [8] Rahnema M., UMTS network planning, optimization, and inter-operation with GSM, John Wiley & Sons, 2008.
- [9] Jakes W. C., Microwave mobile communications, John Wiley & Sons, 1974.
- [10] Stüber G. L., Principles of mobile communication, Second edition, Springer, 2001.
- [11] Ramachandran K. M., Tsokos C. P., Mathematical Statistics with Applications, Elsevier Inc., 2009.
- [12] Sijbers J., den Dekker A. J., Scheunders P., Van Dyck D., "Maximum Likelihood estimation of Rician distribution parameters," IEEE Transactions on Medical Imaging, vol. 17, no. 3, pp. 357–361, 1998.
- [13] Jung P., Baier P. W., Steil A., "Advantages of CDMA and spread spectrum techniques over FDMA and TDMA in cellular mobile radio applications," IEEE Transactions on Vehicular Technology, pp. 357-364, 1993.
- [14] Gudmundson M., "Generalized frequency hopping in mobile radio systems," Proceedings of IEEE Vehicular Technology Conference, pp. 788-91, 1993.

- [15] Simon M. K., Alouini M.-S., Digital communication over fading channels, Second edition, John Wiley & Sons, Inc., New Jersey, 2005.
- [16] Clarke R. H., "A statistical theory of mobile-radio reception," Bell System Technical Journal, vol. 47, pp. 957–1000, 1968.
- [17] McCulloch J. L., Pitts W., "A logical calculus of the ideas immanent in nervous activity," Bulletin of Mathematical Biophysics, vol. 5, no. 4, pp. 115-133, 1943.
- [18] Widrow B., Hoff M. E., "Adaptive switching circuits," IRE WESCON Convention Record, vol. 4, pp. 96-104, 1960.
- [19] Amari S.-I., "A theory of adaptive pattern classifiers," IEEE Transactions on Electronic Computers, EC-16, no. 3, pp. 299-307, 1967.
- [20] Amari S.-I., Geometrical theory of information, Kyoritsu-Shuppan, Tokyo, 1968.
- [21] Bryson, A. E., Ho, Y.-C., Applied optimal control, Blaisdell, New York, 1969.
- [22] Werbos P., Beyond regression: new tools for prediction and analysis in the behavioral sciences, Ph.D. dissertation, Committee on Applied Mathematics, Harvard University, Cambridge, MA, 1974.
- [23] Parker D. B., Learning Logic, Technical Report TR-47, Center for Computational Research in Economics and Management Science, Massachusetts Institute of Technology, Cambridge, MA, 1985.
- [24] Finnoff W., "Diffusion approximations for the constant learning rate backpropagation algorithm and resistance to local minima," Neural Computation, vol 6., no. 2, pp. 285-295, 1994.
- [25] Pop M. F., Beaulieu N. C., "Limitations of sum-of-sinusoids fading channel simulators," IEEE Transactions on Communications, vol. 49, pp. 699–708, 2001.
- [26] Li Y., Huang X., "The simulation of independent Rayleigh faders," IEEE Transactions on Communications, vol. 50, no. 9, pp. 1503–1514, 2002.
- [27] Xiao C., Zheng Y. R., Beaulieu N. C., "Second-order statistical properties of the WSS Jakes' fading channel simulator," IEEE Transactions on Communications, vol.50, pp. 888–891, 2002.
- [28] Zheng Y. R., Xiao C., "Improved models for the generation of multiple uncorrelated Rayleigh fading waveforms," IEEE Communications Letters, vol. 6, pp. 256–258, 2002.
- [29] Zheng Y. R., Xiao C., "Simulation models with correct statistical properties for Rayleigh fading channels," IEEE Transactions on Communications, vol. 51, no. 6, pp. 920–928, 2003.
- [30] Patel C. S., Stuber G. L., Pratt T. G., "Comparative analysis of statistical models for the simulation of Rayleigh faded cellular channels," IEEE Transactions on Communications, vol. 53, pp. 1017–1026, 2005.

- [31] Xiao C., Yahong Y. R., Beaulieu N. C., "Novel sum-of-sinusoids simulation models for Rayleigh and Rician fading channels," IEEE Transactions on Wireless Communications, vol. 5, no. 12, pp. 3667–3679, 2006.
- [32] Smith J. I., "A computer generated multipath fading simulation for mobile radio," IEEE Transactions on Vehicular Technology, vol. VT-24, pp. 39–40, 1975.
- [33] Young D. J., Beaulieu N. C., "The generation of correlated Rayleigh random variates by inverse discrete Fourier transform," IEEE Transactions on Communications, vol. 48, no. 7, pp. 1114–1127, 2000.
- [34] Loo C., Secord N., "Computer models for fading channels with applications to digital transmission," IEEE Transactions on Vehicular Technology, vol. 40, no. 4, pp. 700–707, 1991.
- [35] Verdin D., Tozer T., "Generating a fading process for the simulation of land-mobile radio communications," Electronics Letters, vol. 29, no. 23, pp. 2011–2012, 1993.
- [36] McLane P., "Two-stage doppler-phasor-corrected TCM/DMPK for shadowed mobile satellite channels," IEEE Transactions on Communications, vol. 41, pp. 1137–1141, 1993.
- [37] Komninakis C., Kirshman J. F., "Fast Rayleigh fading simulation with an IIR filter and polyphase interpolation," RF Design, pp. 24–34, 2004.
- [38] Zhang Q. T., "A decomposition technique for efficient generation of correlated Nakagami fading channels," IEEE Journal on Selected Areas in Communications, vol. 18, no. 11, pp. 2385–2392, 2000.
- [39] Wu H., Duel-Hallen A., "Multiuser detectors with disjoint Kalman channel estimators for synchronous CDMA mobile radio channels," IEEE Transactions on Communications, vol. 48, no. 5, pp. 752–756, 2000.
- [40] Baddour K. E., Beaulieu N. C., "Autoregressive modeling for fading channel simulation," IEEE Transactions on Wireless Communications, vol. 4, no. 4, pp. 1650–1662, 2005.
- [41] Colman G. W. K., Blostein S. D., Beaulieu N. C., "An ARMA multipath fading simulator," Chapter 4 in Wireless personal communications, eds. Rappaport T. S. et al., pp. 37–48, New York: Kluwer, 1997.
- [42] Mehrpouyan H., Blostein S. D., "ARMA synthesis of fading channels," IEEE Transactions on Wireless Communications, vol. 7, pp. 2846–2850, 2008.
- [43] Baddour K. E., Simulation, estimation and prediction of flat fading wireless channels, Ph.D. dissertation, Department of Electrical and Computer Engineering, Queens University, Kingston, ON, Canada, 2006.
- [44] Papoulis A. Probability, random variable, and stochastic processes, Third edition, McGraw-Hill, 1991.

- [45] Sathini Ramaswamy V. R., A comparative study of Rayleigh fading wireless channel simulators, M.S. thesis, Department of Electrical and Computer Engineering, Texas A&M University, TX, United States, 2005.
- [46] Haykin S., Adaptive filter theory, Third edition, Englewood Cliffs, NJ: Prentice-Hall, 1996.
- [47] Kay S. M., Modern spectral estimation: theory and application, Englewood Cliffs, NJ: Prentice-Hall, 1988.
- [48] Glisic S. G., Advanced wireless communications: 4G technologies, John Wiley & Sons, 2004.
- [49] Steele R., Hanzó L., Mobile radio communications: second and third generation cellular and WATM systems, Second edition, John Wiley & Sons, 1999.
- [50] Valenzuela R. A., Landron O., Jacobs D. L., "Estimating local mean signal strength of indoor multipath propagation," IEEE Transactions on Vehicular Technology, vol. 46, pp. 203–212, 1997.
- [51] Abdi A., Tepedelenlioglu C., Kaveh M., Giannakis G., "On the estimation of the K parameter for the Rice fading distribution," IEEE Communications Letters, vol. 5, no. 3, pp. 92–94, 2001.
- [52] Prasad R., OFDM for wireless communications systems, Artech House, 2004.
- [53] Chatfield C., The analysis of time series: an introduction, Sixth edition, CRC Press, 2004.
- [54] Frank H., Althoen S. C., Statistics: concepts and applications, Cambridge University Press, 1994.
- [55] Gentle J. E., Härdle W., Mori Y., Handbook of computational statistics: concepts and methods, Springer-Verlag Berlin Heidelberg, 2004.
- [56] Grimmett G., Stirzaker D., Probability and random processes, Third edition, Oxford University Press, 2001.
- [57] Shang Y., Wah W. B., "Global optimization for neural network training," Computer, vol. 29, no. 3, pp. 45–56, 1996.
- [58] Nguyen D., Widrow B., "Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights," IEEE First International Joint Conference on Neural Networks, vol. 3, pp. 21–26, Jun 1990.
- [59] Young D. J., Beaulieu N. C., "Power margin quality measures for correlated random variates derived from the normal distribution," IEEE Transactions on Information Theory, vol. 49, no. 1, pp. 241–252, 2003.
- [60] Crespo P. M., Jiménez J., "Computer simulation of radio channels using a harmonic decomposition technique," IEEE Transactions on Vehicular Technology, vol. 44, no. 3, pp. 414–419, 1995.

- [61] Sundararajan D., Digital signal processing: theory and practice, World Scientific Publishing, Co. Pte. Ltd., 2003.
- [62] Golub G. H., Van Loan C. F., Matrix computations, Third edition, Johns Hopkins University Press, 1996.
- [63] Ertel R. B., Reed J. H., "Generation of two equal power correlated Rayleigh fading envelopes," IEEE Communications Letters, vol. 2, no. 10, pp. 276-278, October 1998.
- [64] Beaulieu N. C., "Generation of correlated Rayleigh fading envelopes," IEEE Communications Letters, vol. 3, no. 6, pp. 172-174, 1999.
- [65] Natarajan B., Nassar C. R., Chandrasekhar V., "Generation of correlated Rayleigh fading envelopes for spread spectrum applications," IEEE Communications Letters, vol. 4, issue 1, pp. 9-11, 2000.
- [66] Beaulieu N. C., Merani M. L., "Efficient simulation of correlated diversity channels," IEEE Wireless Communications and Networking Conference, 2000 WCNC, vol. 1, pp. 207-210, 2000.
- [67] Sorooshyari S., Daut D. G., "On the generation of correlated Rayleigh fading envelopes for accurate simulation of diversity channels," IEEE Transactions on Communications, vol. 54, no. 8, pp. 1381-1386, 2006.
- [68] Beaulieu N. C., Merani M. L., "Generation of multiple Rayleigh fading sequences with specified cross-correlations," European Transactions on Telecommunications, vol. 15, pp. 471-476, 2004.
- [69] Watkins D. S., Fundamentals of matrix computations, Second edition, John Wiley & Sons, Inc., New York, 2002.
- [70] Cormen T. H., Leiserson C. E., Rivest R. L., Stein C., Introduction to algorithms, Third edition, Massachusetts Institute of Technology, 2009.
- [71] Barlow J. S., The electroencephalogram: its patterns and origins, MIT Press, Cambridge MA, 1993.
- [72] Osorio I., Frei M. G., "Seizure abatement with single DC pulses: is phase resetting at play?," International Journal of Neural Systems, vol. 19, no. 3, pp. 149-156, 2009.
- [73] Shoeb A., Guttag J., Pang T., Schachter S., "Non-invasive computerized system for automatically initiating vagus nerve stimulation following patient-specific detection of seizures or epileptiform discharges," International Journal of Neural Systems, vol. 19, no. 3, pp. 157-172, 2009.
- [74] Good L. B., Sabesan S., Marsh S. T., Tsakalis, K. S., Iasemidis L. D., "Control of synchronization of brain dynamics leads to control of epileptic seizures in rodents," International Journal of Neural Systems, vol. 19, no. 3, pp. 173-196, 2009.
- [75] Hsu W. Y., "Continuous EEG signal analysis for asynchronous BCI application," International Journal of Neural Systems, vol. 21, no. 4, pp. 335-350, 2011.

- [76] Medvedev A. V., Murro A. M., Meador K. J., "Abnormal interictal gamma activity may manifest a seizure onset zone in temporal lobe epilepsy," *International Journal of Neural Systems*, vol. 21, no. 2, pp. 103-114, 2011.
- [77] Jahangiri A. F., Durand D. M., "Phase resetting of spiking epileptiform activity by electrical stimulation in the CA3 region of the rat hippocampus," *International Journal of Neural Systems*, vol. 21, no. 2, pp. 127-138, 2011.
- [78] Rajdev P., Ward M., Irazoqui P., "Effect of stimulus parameters in the treatment of seizures by electrical stimulation in the kainate animal model," *International Journal of Neural Systems*, vol. 21, no. 2, pp. 151-162, 2011.
- [79] Ibe O. C., *Fundamentals of applied probability and random processes*, Elsevier Inc. 2005.
- [80] Adeli H., Ghosh-Dastidar S., (in corroboration with Dadmehr N.), *Automated EEG-based diagnosis of neurological disorders - inventing the future of neurology*, CRC Press, Taylor & Francis, Boca Raton, Florida, 2010.
- [81] Kramer M. A., Chang F.-L., Cohen M. E., Hudson D., Szeri A. J., "Synchronization measures of the scalp electroencephalogram can discriminate healthy from Alzheimer's subjects," *International Journal of Neural Systems*, vol. 17, no. 2, pp. 61-69, 2007.
- [82] Adeli H., Ghosh-Dastidar S., Dadmehr N. "A spatio-temporal wavelet-chaos methodology for EEG-based diagnosis of alzheimer's disease," *Neuroscience Letters*, vol. 444, no. 2, pp. 190-194, 2008.
- [83] Adeli H., Zhou Z., Dadmehr N., "Analysis of EEG records in an epileptic patient using wavelet transform," *Journal of Neuroscience Methods*, vol. 123, no. 1, pp. 69-87, 2003.
- [84] Acharya U. R., Sree S. V., Chattopadhyay S., Yu W., Alvin Ang P. C., "Application of recurrence quantification analysis for the automated identification of epileptic EEG signals," *International Journal of Neural Systems*, vol. 21, no. 3, pp. 199-211, 2011.
- [85] Sherman D., Zhang N., Anderson M., Garg S., Hinich M. J., Thakor N. V., and Mirski M. A., "Detection of nonlinear interactions of EEG alpha waves in the brain by a new coherence measure and its application to epilepsy and anti-epileptic drug therapy," *International Journal of Neural Systems*, vol. 21, no. 2, pp. 115-126, 2011.
- [86] Adeli H., Ghosh-Dastidar S., Dadmehr N., "A wavelet-chaos methodology for analysis of EEGs and EEG Sub-bands to detect seizure and epilepsy," *IEEE Transactions on Biomedical Engineering*, vol. 54, no. 2, pp. 205-211, 2007.
- [87] Faust O., Acharya U. R., Min L. C., Sputh B. H. C., "Automatic identification of epileptic and background EEG signals using frequency domain parameters," *International Journal of Neural Systems*, vol. 20, no. 2, pp. 159-176, 2010.
- [88] Colici S., Zalay O. C., Bardakjian B. L., "Response neuromodulators based on artificial neural networks used to control seizure-like events in a computational model of epilepsy," *International Journal of Neural Systems*, vol. 21, no. 5, pp. 367-383, 2011.

- [89] Ghosh-Dastidar S., Adeli H., "Improved spiking neural networks for EEG classification and epilepsy and seizure detection," *Integrated Computer-Aided Engineering*, vol. 14, no. 3, pp. 187-212, 2007.
- [90] Ghosh-Dastidar S., Adeli H., "A new supervised learning algorithm for multiple spiking neural networks with application in epilepsy and seizure detection," *Neural Networks*, vol. 22, pp. 1419-1431, 2009.
- [91] Ghosh-Dastidar S., Adeli H., Dadmehr N., "Mixed-band wavelet-chaos-neural network methodology for epilepsy and epileptic seizure detection," *IEEE Transactions on Biomedical Engineering*, vol. 54, no. 9, pp. 1545-1551, 2007.
- [92] Ghosh-Dastidar S., Adeli H., Dadmehr N., "Principal component analysis-enhanced cosine radial basis function neural network for robust epilepsy and seizure detection," *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 2, pp. 512-518, 2008.
- [93] Adeli H., Ghosh-Dastidar S., Dadmehr N., Ghosh-Dastidar S., Adeli H., "Spiking neural networks," *International Journal of Neural Systems*, vol. 19, no. 4, pp. 295-308, 2009.
- [94] Ahmadlou M., Adeli H., Adeli A. "Fractality and a wavelet-chaos-neural network methodology for EEG-based diagnosis of autistic spectrum disorder," *Journal of Clinical Neurophysiology*, vol. 27, no. 5, pp. 328-333, 2010.
- [95] Ahmadlou M., Adeli H., "Wavelet-synchronization methodology: a new approach for EEG-based diagnosis of ADHD," *Clinical EEG and Neuroscience*, vol. 41, no. 1, pp. 1-10, 2010.
- [96] Ahmadlou M., Adeli H., "Fuzzy synchronization likelihood with application to attention-deficit/hyperactivity disorder," *Clinical EEG and Neuroscience*, vol. 42, no. 1, pp. 6-13, 2011.
- [97] Adeli H., Ghosh-Dastidar S., Dadmehr N., "Alzheimer's disease and models of computation: imaging, classification, and neural models," *Journal of Alzheimer's Disease*, vol. 7, no. 3, pp. 187-199, 2005.
- [98] Adeli H., Ghosh-Dastidar S., Dadmehr N., "Alzheimer's disease: models of computation and analysis of EEGs," *Clinical EEG and Neuroscience*, vol. 36, no. 3, pp. 131-140, 2005.
- [99] Ahmadlou M., Adeli H., Adeli A., "New diagnostic EEG markers of the Alzheimer's disease using visibility graph," *Journal of Neural Transmission*, vol. 117, no. 9, pp. 1099-1109, 2010.
- [100] Ahmadlou A., Adeli H., Adeli A., "Fractality and a wavelet-chaos methodology for EEG-based diagnosis of Alzheimer's disease," *Alzheimer Disease and Associated Disorders*, vol. 25, no. 1, pp. 85-92, 2011.
- [101] Sankari Z., Adeli H., "Probabilistic neural networks for EEG-based diagnosis of Alzheimer's disease using conventional and wavelet coherence," *Journal of Neuroscience Methods*, vol. 197, no. 1, pp. 165-170, 2011.

- [102] Sankari Z., Adeli H., Adeli A., "Intrahemispheric, interhemispheric and distal EEG coherence in Alzheimer's disease," *Clinical Neurophysiology*, vol. 122, no. 5, pp. 897-906, 2011.
- [103] Ahmadlou M., Adeli H., "Visibility graph similarity: a new measure of generalized synchronization in coupled dynamic systems," *Physica D: Nonlinear Phenomena*, vol. 241, no. 4, pp. 326-332, 2012.
- [104] Sanei S., Chambers J., *EEG signal processing*, John Wiley & Sons, 2007.
- [105] Ayala M., Cabrerizo M., Jayakar P., Adjouadi M., "Subdural EEG classification into seizure and non-seizure files using neural networks in the gamma frequency band," *Journal of Clinical Neurophysiology*, vol. 28, no. 1, pp. 20-29, 2011.
- [106] Tito M., Cabrerizo M., Ayala M., Jayakar P., Adjouadi M., "Seizure detection: an assessment of time- and frequency-based features in a unified 2-D decisional space using nonlinear decision functions", *Journal of Clinical Neurophysiology*, vol. 26, no. 6, pp. 381-391, 2009.
- [107] Jasper H. H., *Electroencephalography, in epilepsy and cerebral localization*, eds. Penfield W. G., Erickson T. C., Springfield I. L., Thomas C. C., 1941.
- [108] Britton J., Jervis B. W., Grunewald R. A., "Extracting single trial event related potentials," *IEE Proceedings - Science, Measurement and Technology*, vol. 147, no. 6, 2000.
- [109] Doležal J., Štastný J., Sovka P., "Modeling and recognition of movement related EEG signal," *International Conference on Applied Electronics*, pp. 27-30, 2006.
- [110] Janeczko C., Lopes H. S., "A genetic approach to ARMA filter synthesis for EEG signal simulation," *Proceedings of the 2000 Congress on Evolutionary Computation*, vol. 1, pp. 373-378, La Jolla, California, USA, 2000.
- [111] Palaniappan R., Raveendran P., Nishida S., Saiwaki N., "Autoregressive spectral analysis and model order selection criteria for EEG signals," *Proceedings of the TENCON 2000*, vol. 2, pp. 126-129, Kuala Lumpur, Malaysia, 2000.
- [112] Steinberg H.-W., Gasser T., Franke J., "Fitting autoregressive models to EEG time series: an empirical comparison of estimates of the order," *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. 33, no. 1, pp. 143-150, 1985.
- [113] Bai O., Nakamura M., Ikeda A., Shibasaki H., "Nonlinear Markov process amplitude EEG model for nonlinear coupling interaction of spontaneous EEG," *IEEE Transactions on Biomedical Engineering*, vol. 47, no. 9, pp. 1141-1146, 2000.
- [114] Al-Nashash H., Al-Assaf Y., Paul J., Thakor N., "EEG signal modeling using adaptive Markov process amplitude," *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 5, pp. 744-751, 2004.
- [115] Celka P., Colditz P., "Nonlinear nonstationary Wiener model of infant EEG seizures," *IEEE Transactions on Biomedical Engineering*, vol. 49, no. 6, pp. 556-564, 2002.

- [116] Roessgen M., Zoubir A., Boashash B., "Seizure detection of newborn EEG using a model-based approach," IEEE Transactions on Biomedical Engineering, vol. 45, no. 6, pp. 673-685, 1998.
- [117] Rankine L., Stevenson N., Mesbah M., Boashash B., "A nonstationary model of newborn EEG," IEEE Transactions on Biomedical Engineering, vol. 54, no. 1, pp. 19-28, 2007.
- [118] Al-Nashash H. A., Zalzal A. M. S., Thakor N. V., "A neural networks approach to EEG signals modeling," Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, vol. 3, pp. 2451-2454, Cancun, 2003.
- [119] Adeli H., Hung S. L., Machine learning - neural networks, genetic algorithms, and fuzzy systems, John Wiley & Sons, New York, 1995.
- [120] Jansen B. H., Bourne J. R., Ward J. W., "Autoregressive estimation of short segment spectra for computerized EEG analysis," IEEE Transactions on Biomedical Engineering, vol. BME-28, no. 9, pp. 630-638, 1981.
- [121] Cassar T., Camilleri K. P., Fabri S. G., "Order estimation of multivariate ARMA models," IEEE Journal of Selected Topics in Signal Processing, vol. 4, no. 3, pp. 494-503, 2010.
- [122] Rugg M., Coles M., Electrophysiology of mind: event related brain potentials and cognition, Oxford University Press, 1985.
- [123] Acharya R., Chua E. C. P., Chua K. C., Min L. C., Tamura T., "Analysis and automatic identification of sleep stages using higher order spectra," International Journal of Neural Systems, vol. 20, no. 6, pp. 509-521, 2010.
- [124] Lee H., Cichocki A., Choi S., "Nonnegative matrix factorization for motor imagery EEG classification," International Journal of Neural Systems, vol. 17, no. 4, pp. 305-317, 2007.
- [125] Sörnmo L., Laguna P., Bioelectrical signal processing in cardiac and neurological applications, Elsevier Inc., 2005.
- [126] Zetterberg L. H., "Experience with analysis and simulation of EEG signals with parametric description of spectra," in: Kellaway P., Petersén I., Automation of clinical electroencephalography, pp. 161-201, Raven Press, New York, 1973.
- [127] Zetterberg L. H., Ahlin K., "Analogue simulator of EEG signals based on spectral components," Medical and Biological Engineering and Computing, vol. 13, no. 2, pp. 272-278, 1975.
- [128] Binnie C., Cooper R., Mauguière F., Osselton J., Prior P., Tedman B., Clinical neurophysiology: EEG paediatric neurophysiology, special techniques and applications, vol. 2, Elsevier Science B.V., 2003.
- [129] Vanhatalo S., Voipio J., Kaila K., "Infraslow EEG activity," in: Niedermeyer E., Lopes Da Silva F., Electroencephalography: basic principles, clinical applications, and related fields, Fifth edition, pp. 489-494, Lippincott Williams & Wilkins, 2005.

- [130] Stern J. M., Engel J., Atlas of EEG patterns, Lippincott Williams & Wilkins, 2004.
- [131] Reilly E. L., "EEG recording and operation of the apparatus," in: Niedermeyer E., Lopes Da Silva F., Electroencephalography: basic principles, clinical applications, and related fields, Fifth edition, pp. 139-161, Lippincott Williams & Wilkins, 2005.
- [132] Schell A. M., Dawson M. E., Oray S., Lu Z.-L., "Prepulse inhibition of event-related brain potentials and startle eyeblink," in: Shohov S. P., Advances in psychology research, vol. 29, pp. 57-70, Nova Science Publishers, 2004.
- [133] Széliga M. I., Verdes P. F., Granitto P. M., Ceccatto H. A., "Artificial neural network learning of nonstationary behavior in time series," International Journal of Neural Systems, vol. 13, no. 2, pp. 103-109, 2003.
- [134] Adeli H., Jiang X., "Neuro-fuzzy logic model for freeway work zone capacity estimation," Journal of Transportation Engineering, vol. 129, no. 5, pp. 484-493, 2003.
- [135] Ghosh-Dastidar S., Adeli H., "Neural network-wavelet micro-simulation model for delay and queue length estimation at freeway work zones," Journal of Transportation Engineering, ASCE, vol. 132, no. 4, pp. 331-341, 2006.
- [136] Hung S. L., Adeli H., "Parallel backpropagation learning algorithms on Cray Y-MP8/864 supercomputer," Neurocomputing, vol. 5, no. 6, pp. 287-302, 1993.
- [137] Hung S. L., Adeli H., "Object-oriented back propagation and its application to structural design," Neurocomputing, vol. 6, no. 1, pp. 45-55, 1994.
- [138] Adeli H., Hung S. L., "An adaptive conjugate gradient learning algorithm for effective training of multilayer neural networks," Applied Mathematics and Computation, vol. 62, no. 1, pp. 81-102, 1994.
- [139] Bishop C.M., Neural networks for pattern recognition, Oxford, UK: Oxford University Press, 1995.
- [140] Leon-Garcia A., Probability, statistics, and random processes for electrical engineering, Third edition, Pearson Education, Inc., 2008.
- [141] Bendat J. S., Piersol A. G., Random data: analysis and measurement procedures, fourth edition, John Wiley & Sons, Inc., 2010.
- [142] Salivahanan S., Vallavaraj A., Gnanapriya C., Digital signal processing, Tata McGraw-Hill Publishing Company Limited, 2000.

BIOGRAFIJA AUTORA

Nikola M. Tomašević rođen je 04.12.1983. godine u Beogradu. Osnovnu školu „Braća Jerković” u Beogradu završio je 1998. godine sa maksimalnom prosečnom ocenom (5.0) i dobitnik je Vukove diplome. U periodu od 1998. do 2002. godine, bio je učenik XIII beogradske gimnazije, koju je završio, takođe, sa maksimalnom prosečnom ocenom. Od 1997. do 2001. godine učestvovao je na mnogobrojnim takmičenjima i dobitnik je nagrada iz matematike, hemije i fizike na regionalnom i republičkom nivou. U periodu od 2002. do 2007. godine studirao je na Elektrotehničkom fakultetu u Beogradu, smer Telekomunikacije. 2006. godine, u okviru stručne prakse u oblasti telekomunikacija, radio je kao deo tima kompanije *General Telecom Services* u Tunisu na projektovanju i implementaciji *broadcast* sistema za prenos podataka u HF, VHF i UHF opsegu. Tokom osnovnih studija bio je stipendista Ministarstva prosvete i sporta Republike Srbije (2003-2007), Gradske uprave grada Beograda (2006-2007) i dobitnik nagrade Eurobanke EFG za najbolje studente Republike Srbije (2007). Studije je završio jula 2007. godine sa prosečnom ocenom 9.67. Rezultati diplomskog rada pod nazivom “Simulacija *short-term fading*-a pomoću veštačkih neuralnih mreža”, pod mentorstvom prof. dr Nataše Nešković, objavljeni su na 15. telekomunikacionom forumu TELFOR 2007 i nagrađeni na konkursu ETF BAFA USA za najbolji projekat studenata redovnih studija na Elektrotehničkom fakultetu.

Početkom 2008. godine upisao je doktorske studije na Elektrotehničkom fakultetu u Beogradu, smer Telekomunikacije i informacione tehnologije, pod mentorstvom prof. dr Aleksandra Neškovića. U periodu od 2008. do 2009. godine bio je stipendista Ministarstva za telekomunikacije i informatičko društvo Republike Srbije. Ispite na doktorskim studijama položio je prosečnom ocenom 10.00. Od 2007. godine do danas zaposlen je kao naučni istraživač u Institutu Mihajlo Pupin u Beogradu, u odeljenju *Fraunhofer – Pupin Joint Project Office* pod vođstvom naučnog direktora instituta prof. dr Sanje Vraneš. Na poziciji naučnog istraživača u institutu stekao je značajno radno iskustvo radeći na većem broju nacionalnih i evropskih istraživačkih projekata Sedmog okvirnog programa u oblastima kao što su inteligentno i adaptivno upravljanje kompleksnim infrastrukturama, razvoj inteligentnih sistema za povećanje energetske efikasnosti kompleksnih objekata poput aerodroma, pervazivno-adaptivne infrastrukture za kontekstno osetljiv sistem čovek-okruženje itd. Rezultate proistekle iz njegovog istraživačkog rada objavio je u vodećim međunarodnim časopisima i prezentovao stručnoj javnosti na konferencijama od međunarodnog i nacionalnog značaja. Ujedno, učestvovao je i u procesu recenzije radova u renomiranim međunarodnim časopisima poput *IEEE Transactions on Wireless Communications*, *AEU - International Journal of Electronics and Communications* itd.

Прилог 1.

Изјава о ауторству

Потписани-а **Никола Томашевић**

број индекса **5015/07**

Изјављујем

да је докторска дисертација под насловом

**СИМУЛАЦИЈА КРАТКОТРАЈНОГ ФЕДИНГА МОБИЛНОГ ПРОПАГАЦИОНОГ
КАНАЛА ЗАСНОВАНА НА ВЕШТАЧКИМ НЕУРАЛНИМ МРЕЖАМА**

- резултат сопственог истраживачког рада,
- да предложена дисертација у целини ни у деловима није била предложена за добијање било које дипломе према студијским програмима других високошколских установа,
- да су резултати коректно наведени и
- да нисам кршио/ла ауторска права и користио интелектуалну својину других лица.

Потпис докторанда

У Београду, децембар 2013. године

Никола Томашевић

Прилог 2.

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора **Никола Томашевић**

Број индекса **5015/07**

Студијски програм **Електротехника и рачунарство – Телекомуникације и информационе технологије**

Наслов рада **СИМУЛАЦИЈА КРАТКОТРАЈНОГ ФЕДИНГА МОБИЛНОГ ПРОПАГАЦИОНОГ КАНАЛА ЗАСНОВАНА НА ВЕШТАЧКИМ НЕУРАЛНИМ МРЕЖАМА**

Ментор **Проф. др Александар Нешковић**

Потписани/а **Никола Томашевић**

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла за објављивање на порталу **Дигиталног репозиторијума Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског звања доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис докторанда

У Београду, децембар 2013. године

Никола Томашевић

Прилог 3.

Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

СИМУЛАЦИЈА КРАТКОТРАЈНОГ ФЕДИНГА МОБИЛНОГ ПРОПАГАЦИОНОГ КАНАЛА ЗАСНОВАНА НА ВЕШТАЧКИМ НЕУРАЛНИМ МРЕЖАМА

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигитални репозиторијум Универзитета у Београду могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио/ла.

1. Ауторство

2. Ауторство - некомерцијално

3. Ауторство – некомерцијално – без прераде

4. Ауторство – некомерцијално – делити под истим условима

5. Ауторство – без прераде

6. Ауторство – делити под истим условима

(Молимо да заокружите само једну од шест понуђених лиценци, кратак опис лиценци дат је на полеђини листа).

Потпис докторанда

У Београду, децембар 2013. године

Никола Томановић

1. Ауторство - Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.
2. Ауторство – некомерцијално. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.
3. Ауторство - некомерцијално – без прераде. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.
4. Ауторство - некомерцијално – делити под истим условима. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.
5. Ауторство – без прераде. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.
6. Ауторство - делити под истим условима. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.

