



UNIVERZITET U NIŠU
ELEKTRONSKI FAKULTET



Marija M. Stoilković

**NOVI PRISTUP U PROCENI PRAVCA
DOLAZEĆEG EM SIGNALA ZASNOVAN NA
PRIMENI VEŠTAČKIH NEURONSKIH MREŽA**

- doktorska disertacija -

Niš, 2014



UNIVERSITY OF NIŠ
FACULTY OF ELECTRONIC ENGINEERING



Marija M. Stoilković

**NEW APPROACH IN DIRECTION OF ARRIVAL
ESTIMATION OF EM SIGNALS USING
ARTIFICIAL NEURAL NETWORKS**

Doctoral Dissertation

Niš, 2014

Podaci o mentoru i članovima komisije

Mentor:

dr Bratislav Milovanović, redovni profesor

Univerzitet u Nišu, Elektronski fakultet

Predsednik komisije:

dr Nebojša Dončov, redovni profesor

Univerzitet u Nišu, Elektronski fakultet

Članovi komisije:

dr Vera Marković, redovni profesor

Univerzitet u Nišu, Elektronski fakultet

dr Branka Jokanović, naučni savetnik

Univerzitet u Beogradu, Institut za fiziku

dr Olivera Pronić-Rančić, redovni profesor

Univerzitet u Nišu, Elektronski fakultet

dr Nataša Maleš-Ilić, vanredni profesor

Univerzitet u Nišu, Elektronski fakultet

Datum odbrane:

Izrazi zahvalnosti

Profesoru Elektronskog fakulteta u penziji, dr Bratislavu Milovanović, izražavam zahvalnost na sveobuhvatnom angažovanju i stručnoj pomoći pruženoj tokom izrade ove disertacije.

Redovnom profesoru Elektronskog fakulteta u Nišu, dr Nebojši Dončovu, kao i asistentu dr Zoranu Stanković, najiskrenije se zahvaljujem na svestranoj stručnoj pomoći, korisnim sugestijama i podršci u toku izrade ovog rada.

Veliku zahvalnost na pomoći u izvođenju eksperimentalnog dela doktorske disertacije dugujem prof. dr Thomasu Zwick i istraživačima sa Instituta za visoke frekvencije i elektroniku (IHE, Institut für Hochfrequenztechnik und Elektronik), Univerziteta u Karlsruhe (KIT, Karlsruhe Institute of Technology).

Zahvaljujem se docentu dr Zlatici Marinković i prof. dr Veri Marković na značajnoj pomoći u razumevanju principa rada veštačkih neuronskih mreža kao i savetima za uspešno pisanje i prezentovanje naučnih radova.

Najveću zahvalnost dugujem mojoj porodici i suprugu Miodragu na pruženoj iskrenoj i nesebičnoj podršci i razumevanju tokom istraživačkog rada i izrade same disertacije.

dipl. inž. Marija Stoilković

Podaci o doktorskoj disertaciji

Naziv disertacije: NOVI PRISTUP U PROCENI PRAVCA DOLAZEĆEG EM SIGNALA ZASNOVAN NA PRIMENI VEŠTAČKIH NEURONSKIH MREŽA

Rezime

Procena pravaca dolaska elektromagnetskih (EM) signala u velikoj meri zavisi od karakteristika primljenih signala, konfiguracije i fizičke izrade prijemnog antenskog niza i uticaja okruženja. Algoritmi za procenu pravaca imaju veoma važnu ulogu kod adaptivnih antenskih sistema gde utiču na poboljšanje prijema željenih signala i potiskivanje interferencije. Do sada je razvijen veliki broj algoritama za različite konfiguracije antenskih nizova i karakteristike EM signala. Glavni problem koji se javlja pri određivanju pravaca njihovom primenom, predstavlja kompromis koji se mora napraviti između tačnosti rezultata i brzine izračunavanja. Iz navedenog razloga, u ovoj disertaciji je primenjen metod za određivanje pravaca EM signala zasnovan na veštačkim neuronskim mrežama.

Najznačajniji doprinos disertacije predstavlja razvoj neuronskih modela za efikasno i precizno određivanje pravaca iz kojih dolaze EM signali, u azimutu u elevaciji. Podrazumevajući pravougaoni antenski niz na prijemu, razvijeni su neuronski modeli za procenu pravaca nekorelisanih i korelisanih EM signala. Pokazano je da se formiranjem odgovarajućih hijerarhijskih neuronskih modela može u velikoj meri poboljšati tačnost procene pravaca u poređenju sa standardnim superrezolucijskim algoritmima. Kod neuronskih modela, celokupan posmatrani prostor podeljen je na sektore u azimutu i elevaciji pri čemu su neuronske mreže u prvom delu modela obučene za detekciju izvora signala, dok se neuronske mreže u drugom delu koriste za procenu pravca dolaznog EM signala. Odgovarajuće obučen hijerarhijski neuronski model, sačinjen od manjih neuronskih mreža, može se upotrebiti za preciznu procenu pravca dolaznog EM signala u azimutu i elevaciji. Na ovaj način je drastično smanjeno vreme za obuku pojedinačnih manjih mreža, pri čemu su za mreže u detekcionom i estimacionom delu upotrebljeni različiti skupovi za obuku. Predloženi modeli su veoma efikasni, obezbeđuju podatke o pravcima za nekoliko milisekundi i kao takvi, veoma su pogodni za primenu u realnom vremenu. Performanse navedenih modela su verifikovane eksperimentalnom metodom. Dobijeni rezultati su upoređeni sa rezultatima standardnog algoritma za procenu pravaca dolaznih signala. Prednost predloženih neuronskih

modela ogleda se pre svega, u tačnosti, a zatim i u brzini procene pravaca. Pored toga, neuronski modeli se mogu obučiti tako da uključe dodatne karakteristike signala (različit broj izvora signala, odnos signal/šum, stepen korelacije), fizičke karakteristike prijemnog antenskog niza i karakteristike okruženja.

Na primeru kružnog antenskog niza je razmatran uticaj odnosa signal/šum na performanse neuronskih modela. Pokazano je da odnos signal/šum ima značajan uticaj na tačnost procene pravaca EM signala i da ga je, kao takvog, potrebno uključiti među simulacione parametre u procesu obuke neuronskog modela. Nakon toga je istražena detekcija koreliranih signala, u zavisnosti od stepena korelacije. U ovom slučaju, razvijeni su neuronski modeli za slučaj više EM izvora.

U ovoj disertaciji je urađena analiza primene neuronskih mreža u procesu procene pravaca dolaska radarskih MIMO OFDM signala. Neuronski modeli su optimizovani i pokazano je da njihove performanse u velikoj meri nadmašuju standardni algoritam u pogledu tačnosti i brzine izračunavanja.

Ključne reči: antenski nizovi, MUSIC algoritam, procena pravca EM signala, prostorna kovarijansna matrica, prostorna obrada signala, veštačke neuronske mreže.

Naučna oblast: Telekomunikacije

Uža naučna oblast: Veštačke neuronske mreže

UDK broj:

Information regarding Doctoral Dissertation

Title: NEW APPROACH IN DIRECTION OF ARRIVAL ESTIMATION OF EM SIGNALS USING ARTIFICIAL NEURAL NETWORKS

Abstract

Direction of Arrival (DOA) estimation of electromagnetic (EM) signals strongly depends on characteristics of received signals, configuration and physical layout of a receiving antenna array and environmental conditions. DOA algorithms have crucial role in adaptive antenna systems where used to provide better reception of desired signals and to suppress interference. Consequently, they have significant impact on system capacity. So far, numerous DOA algorithms have been developed assuming different configurations of antenna arrays and characteristics of EM signals. The main problem that appears when these algorithms are applied in practice is that a compromise between accuracy of the results and speed of calculation must be made. For that reason, a method for DOA estimation based on Artificial Neural Networks (ANNs) is applied in this dissertation.

The main contribution of this work is development of neural models for the efficient and accurate DOA estimation of EM signals both in azimuth and elevation. Assuming rectangular antenna array geometry at the receiver, neural models for 2D DOA estimation of uncorrelated and coherent signals are developed. It is shown that applying a hierarchical neural model can greatly affect the accuracy of DOA estimates when compared to standard superresolution algorithms. To develop neural models, the observed space is divided into sectors in azimuth and elevation. The neural networks in the first stage of the model are trained to detect presence of electromagnetic sources, while the networks in the second stage are trained to provide precise DOA estimates. The appropriately trained hierarchical model, composed of smaller neural networks, can be used for accurate DOA estimation in azimuth and elevation. As follows, time to train separate networks is drastically reduced as different training sets are used for the networks in the detection and estimation stage. The proposed models are very efficient, able to provide DOA estimates in a matter of seconds and very suitable for real time application. Performances of the models are experimentally verified. Besides, the results are compared with the results of the standard algorithm for DOA estimation. Advantages of the proposed models are accuracy of DOA estimates and speed of

calculation. In addition, neural models can be trained to account for some other characteristics of EM signals (number of signals, signal to noise ratio, correlation between signals), physical characteristics of the receiving array and environmental conditions.

Influence of signal to noise ratio (SNR) on the performance of neural models, aimed for DOA estimation of signals in azimuth plane, is also investigated. It is shown that SNR strongly affects the accuracy of DOA estimates, and as such should be involved as an additional parameter in the process of training of a neural network. Further, detection of correlated signals is investigated assuming circular antenna array geometry. In this case, neural models are developed for different number of signals and correlation between them.

In this dissertation, application of artificial neural networks in DOA estimation of radar MIMO (*Multiple Input Multiple Output*) – OFDM (*Orthogonal Frequency Division Multiplexing*) signals is presented. A neural model is optimized and its performance is compared to conventional algorithm regarding accuracy and time consumption.

Key words: antenna arrays, artificial neural networks, DOA estimation, MUSIC algorithm, spatial covariance matrix, spatial signal processing.

Scientific research area: Telecommunications

Specific scientific research area: Artificial neural networks

UDK number:

Sadržaj

1	Uvod.....	1
2	Primena antenskih nizova kod inteligentnih antenskih sistema	7
2.1	Prednosti upotrebe inteligentnih antenskih sistema	7
2.2	Vrste inteligentnih antenskih sistema.....	8
2.3	Osnove antenskih nizova.....	10
2.3.1	Linearni antenski niz.....	10
2.3.2	Kružni antenski niz	21
2.3.3	Pravougaoni antenski niz	23
2.4	Modeli signala	31
3	Veštačke neuronske mreže.....	35
3.1	Biološki nervni sistem.....	35
3.2	Neuroni i aktivacione funkcije	36
3.3	Višeslojna neuronska mreža – MLP.....	39
3.3.1	Pravila učenja MLP neuronskih mreža	40
3.3.2	Sposobnost generalizacije MLP neuronskih mreža	45
3.4	Radijalna bazisna neuronska mreža – RBF	47
3.4.1	Model neurona	47
3.4.2	Struktura RBF neuronske mreže	49
3.4.3	Pravila učenja RBF neuronskih mreža.....	50
3.5	Testiranje neuronskih modela	59
3.6	Poređenje karakteristika MLP i RBF neuronskih mreža.....	60
4	Procena pravaca dolaska EM signala.....	62
4.1	Prostorna kovarijansna matrica	62
4.2	Primena MUSIC algoritma.....	64
4.3	MUSIC algoritam sa SSP metodom.....	65
4.4	Primena veštačkih neuronskih mreža	66
4.4.1	Preprocesiranje podataka	67
5	Sektorizacioni model za precizno određivanje pravca EM signala	70
5.1	Osnovni koncept.....	71
5.2	Numerički rezultati.....	72

6	Empirijski neuronski model za precizno određivanje pravca EM signala	78
6.1	Osnovni koncept.....	79
6.2	Postavka mernog sistema	80
6.3	Rezultati	87
7	Kaskadni neuronski model za određivanje pravca EM signala.....	93
7.1	Osnovni koncept.....	94
7.2	Rezultati	94
8	Neuronski modeli za procenu pravaca koherentnih signala	101
8.1	Razvoj neuronskog modela.....	102
8.1.1	Osnovni koncept	102
8.1.2	Numerički rezultati	103
8.2	Razvoj sektorizacionog modela	107
8.2.1	Osnovni koncept	107
8.2.2	Razvoj sektorizacionog modela	108
8.2.3	Postavka mernog sistema.....	111
8.2.4	Eksperimentalna verifikacija sektorizacionog modela	113
9	Procena pravaca EM signala različitih karakteristika	118
9.1	Uticaj odnosa signal/šum na performanse neuronskih modela	118
9.1.1	Osnovni koncept	119
9.1.2	Numerički rezultati	119
9.1.3	Zaključak.....	123
9.2	Uticaj korelacije signala na performanse neuronskih modela.....	123
9.2.1	Osnovni koncept	123
9.2.2	Numerički rezultati	124
9.2.3	Zaključak.....	128
9.3	Neuronski model za detekciju MIMO OFDM radarskih signala.....	128
9.3.1	Osnovni koncept	128
9.3.2	Numerički rezultati	129
9.3.3	Zaključak.....	132
10	Zaključak	133
10.1	Pravci budućih istraživanja.....	134
Literatura.....		136
Biografija autora.....		145

Reference autora	146
Izjave autora.....	151

Spisak slika

- Slika 2.1 *Switched-beam antena*
- Slika 2.2 *Adaptivni antenski niz*
- Slika 2.3 *Uniformni linearni antenski niz*
- Slika 2.4 *Faktor niza u zavisnosti od broja antenskih elemenata i rastojanja između susednih elemenata (a) $N=2$, $d=\lambda/2$, (b) $N=4$, $d=\lambda/2$, (c) $N=8$, $d=\lambda/2$, (d) $N=16$, $d=\lambda/2$, (e) $N=2$, $d=\lambda$, (f) $N=4$, $d=\lambda$, (g) $N=8$, $d=\lambda$, (h) $N=16$, $d=\lambda$*
- Slika 2.5 *Faktor linearne niza od osam elemenata u zavisnosti od prozorske funkcije (a) pravougaona, (b) Bartlettova, (c) Blackmanova, (d) Hammingova, (e) Kaiserova, (h) Dolph-Chebyshevljeva*
- Slika 2.6 *Usmeravanje glavnog lista zračenja u pravcu $\theta=35^\circ$*
- Slika 2.7 *Usmeravanje glavnog lista i nula u karakteristici zračenja antenskog niza od (a) dva elementa, (b) četiri elementa*
- Slika 2.8 *Uniformni kružni antenski niz*
- Slika 2.9 *Pravougaoni antenski niz*
- Slika 2.10 *Preslikavanje između prostora (φ, θ) i prostora $(\sin\alpha, \sin\beta)$*
- Slika 2.11 *Maksimumi u karakteristici zračenja pravougaonog antenskog niza*
- Slika 2.12 *Karakteristika zračenja 11×11 pravougaonog antenskog niza u linearnoj skali (a) bez primjenjene prozorske funkcije, (b) sa Hammingovom prozorskom funkcijom*
- Slika 2.13 *Karakteristika zračenja 11×11 pravougaonog antenskog niza u decibelskoj skali (a) bez primjenjene prozorske funkcije, (b) sa Hammingovom prozorskom funkcijom*
- Slika 2.14 *Struktura pravougaonog antenskog niza*
- Slika 2.15 *Usmeravanje glavnog lista zračenja antenskog niza u prostoru $(\sin\alpha, \sin\beta)$ za $\varphi_1=40^\circ$ i $\theta_1=60^\circ$, (a) u linearnoj skali, (b) u dB skali*
- Slika 3.1 *Prikaz bioloških neurona*
- Slika 3.2 *Matematički model neurona sa jednim ulazom*
- Slika 3.3 *Linearna aktivaciona funkcija*
- Slika 3.4 *Odskočna aktivaciona funkcija*
- Slika 3.5 *Sigmoidne aktivacione funkcije (a) log-sigmoidna, (b) tan-sigmoidna*
- Slika 3.6 *Višeslojna neuronska mreža, MLP*
- Slika 3.7 *Primer (a) dobre generalizacije i (b) loše generalizacije neuronske mreže*
- Slika 3.8 *Matematički model RBF neurona*
- Slika 3.9 *Radijalna bazisna funkcija*
- Slika 3.10 *Struktura RBF neuronske mreže*

- Slika 3.11 *Primer k-means clustering algoritma gde podatak d_1 prelazi iz klastera 1 u klaster 2 posle ažuriranja centara*
- Slika 4.1 *Primer jednog $M \times N$ pravougaonog antenskog niza podeljenog na određeni broj međusobno preklapajućih $P \times Q$ podnizova*
- Slika 4.2 *Procena pravca EM signala pomoći neuronske mreže*
- Slika 4.3 *Neuronska mreža za procenu pravaca EM signala u azimutu i elevaciji*
- Slika 5.1 *Koncept sektorizacionog modela za procenu pravca EM signala*
- Slika 5.2 *Odziv MLP neuronske mreže u (a) elevacionom sektoru, (b) azimutnom sektoru*
- Slika 5.3 *Rezultati sektorizacionog modela za test podatke (\times – odziv sektorizacionog modela, $\textcolor{green}{\times}$ – referentne pozicije izvora)*
- Slika 5.4 *Korelacioni dijagram sektorizacionog modela i 2D MUSIC algoritma za uglove u (a) azimutu, (b) elevaciji*
- Slika 6.1 *Koncept empirijskog neuronskog modela*
- Slika 6.2 *Ilustracija strukture podataka za obuku neuronskog modela*
- Slika 6.3 *Ilustracija mernog sistema u anehoičnoj komori*
- Slika 6.4 *Fotografija i blok-šema sistema za merenja u anehoičnoj komori*
- Slika 6.5 *Predajna levak antena*
- Slika 6.6 *Pravougaoni antenski niz na antenskom tornju*
- Slika 6.7 *Dijagram toka merenja*
- Slika 6.8 *Dijagrami rasejanja MLP neuronskog modela i 2D MUSIC algoritma na test frekvenciji $f=2.4220 \text{ GHz}$*
- Slika 6.9 *Dijagrami rasejanja MLP neuronskog modela i 2D MUSIC algoritma na test frekvenciji $f=2.4400 \text{ GHz}$*
- Slika 6.10 *Dijagrami rasejanja MLP neuronskog modela i 2D MUSIC algoritma na test frekvenciji $f=2.4700 \text{ GHz}$*
- Slika 6.11 *Koren srednje kvadratne greške (RMSE) neuronskog modela za (a) $f=2.4100 \text{ GHz}$, (b) $f=2.4400 \text{ GHz}$ i (c) $f=2.4700 \text{ GHz}$*
- Slika 6.12 *Frekvencijska zavisnost RMSE procenjenih uglova u azimutu i elevaciji za više pozicija predajne antene (a) $\varphi=-45^\circ$, (b) $\varphi=0^\circ$, (c) $\varphi=45^\circ$*
- Slika 7.1 *Neuronski model za poboljšanje tačnosti procene pravca EM signala*
- Slika 7.2 *Razvoj neuronske mreže zasnovane na simuliranom EM izvoru*
- Slika 7.3 *Dijagrami rasejanja simulacione neuronske mreže za merene rezultate na ulazu (a) procenjeni pravci u azimutu, (b) procenjeni pravci u elevaciji*
- Slika 7.4 *Dijagrami rasejanja kaskadnog neuronskog modela za merene rezultate na ulazu (a) procenjeni pravci u azimutu, (b) procenjeni pravci u elevaciji*
- Slika 7.5 *RMSE greška kaskadnog neuronskog modela za različite uglove u azimutu i elevaciji*

- Slika 7.6 *Dijagrami rasejanja predloženog neuronskog modela za različite vrednosti uglova u azimutu i 4 fiksna ugla u elevaciji (a) $\theta=-7.81^\circ$, (b) $\theta=7.81^\circ$, (c) $\theta=-2.25^\circ$, (d) $\theta=2.25^\circ$*
- Slika 7.7 *Dijagrami rasejanja predloženog neuronskog modela za različite vrednosti uglova u elevaciji i 4 fiksna ugla u azimutu (a) $\varphi=-33^\circ$, (b) $\varphi=33^\circ$, (c) $\varphi=-9^\circ$, (d) $\varphi=9^\circ$*
- Slika 8.1 *RBF neuronska mreža za procenu pravaca koherentnih signala u azimutu i elevaciji*
- Slika 8.2 *RMSE greška procene pravca prvog koherentnog izvora za rastojanje između dva izvora od 35°*
- Slika 8.3 *RMSE greška procene pravca drugog koherentnog izvora za rastojanje između dva izvora od 35°*
- Slika 8.4 *Spektar MUSIC algoritma sa SSP metodom za dva koherentna izvora pozicionirana na $(-10^\circ, 10^\circ)$ i $(10^\circ, 10^\circ)$*
- Slika 8.5 *Spektar MUSIC algoritma sa SSP metodom za dva koherentna izvora pozicionirana na $(-14^\circ, -17^\circ)$ i $(14^\circ, -17^\circ)$*
- Slika 8.6 *Spektar MUSIC algoritma sa SSP metodom za dva koherentna izvora pozicionirana na $(-21^\circ, 26^\circ)$ i $(21^\circ, 26^\circ)$*
- Slika 8.7 *Šema neuronskog modela za procenu pravaca dva koherentna EM signala*
- Slika 8.8 *Odziv mreže RBFNN_2_det (sive linije) i RBFNN_4_det (crne linije) u funkciji ugla u elevaciji*
- Slika 8.9 *Ilustracija mernog sistema u anehoičnoj komori*
- Slika 8.10 *Dve predajne levak antene u anehoičnoj komori*
- Slika 8.11 *Prijemni antenski niz na antenskom tornju*
- Slika 8.12 *Spektar MUSIC algoritma za dva koherentna izvora čije su ugaone koordinate $(\varphi_1, \theta_1)=(-12.6^\circ, 0^\circ)$, $(\varphi_2, \theta_2)=(10^\circ, 0^\circ)$*
- Slika 8.13 *Spektar MUSIC algoritma za dva koherentna izvora čije su ugaone koordinate $(\varphi_1, \theta_1)=(21^\circ, 0^\circ)$, $(\varphi_2, \theta_2)=(38^\circ, 0^\circ)$*
- Slika 8.14 *Spektar MUSIC algoritma za dva koherentna izvora čije su ugaone koordinate $(\varphi_1, \theta_1)=(33.6^\circ, -1.7^\circ)$, $(\varphi_2, \theta_2)=(45^\circ, -1.7^\circ)$*
- Slika 8.15 *Spektar MUSIC algoritma za dva koherentna izvora čije su ugaone koordinate $(\varphi_1, \theta_1)=(-35^\circ, -3.4^\circ)$, $(\varphi_2, \theta_2)=(-23.6^\circ, -3.4^\circ)$*
- Slika 8.16 *RMSE greška procene pravaca koherentnih EM signala u funkciji rastojanja između dve predajne antene*
- Slika 9.1 *Koncept neuronskog modela*
- Slika 9.2 *Rezultati simulacije RBF neuronske mreže za dva korisnika međusobno razdvojena 17° , 23° i 32° , $SNR=15\text{ dB}$*
- Slika 9.3 *Performanse RBF neuronske mreže i MUSIC algoritma u zavisnosti od odnosa signal/šum, u slučaju praćenja dva korisnika*

- Slika 9.4 *Rezultati simulacije RBF neuronske mreže za tri korisnika međusobno razdvojena 17° , 23° i 32° , SNR=15 dB*
- Slika 9.5 *Performanse RBF neuronske mreže i MUSIC algoritma u zavisnosti od odnosa signal/šum, u slučaju praćenja tri korisnika*
- Slika 9.6 *Neuronska mreža za detekciju korelisanih signala*
- Slika 9.7 *Rezultati RBF-NN modela za detekciju dva izvora signala (-- izvor 1, - izvor 2), $\rho=1$*
- Slika 9.8 *RMSE greška u zavisnosti od stepena korelacije*
- Slika 9.9 *Rezultati RBF-NN mreže za detekciju tri izvora signala (-- izvor 1, - izvor 2, - izvor 3), $\rho=1$*
- Slika 9.10 *RMSE greška u zavisnosti od stepena korelacije*
- Slika 9.11 *Neuronski model za određivanje pozicija objekata u azimutu*
- Slika 9.12 *Dijagram rasejanja MLP mreže za prvi objekat*
- Slika 9.13 *Dijagram rasejanja MLP mreže za drugi objekat*

Spisak tabela

- Tabela 5.1 *Test statistika MLP neuronske mreže za elevacioni (E) sektor [-15°, 15°]*
- Tabela 5.2 *Test statistika MLP neuronske mreže za azimutni (A) sektor [-20°, 20°]*
- Tabela 5.3 *Test statistika RBF neuronske mreže*
- Tabela 6.1 *Test statistika MLP neuronskih mreža za procenu pravaca u azimutu i elevaciji*
- Tabela 6.2 *Prosečna greška u određivanju pravca signala predajne antene korišćenjem MLP neuronskog modela i 2D MUSIC algoritma*
- Tabela 7.1 *Parametri simulacija za razvoj simulacione neuronske mreže*
- Tabela 8.1 *Rezultati RBF mreže*
- Tabela 8.2 *Rezultati MUSIC algoritma sa SSP metodom*
- Tabela 8.3 *Statistika testiranja neuronskih mreža u delu za detekciju signala*
- Tabela 8.4 *Statistika testiranja neuronskih mreža u delu za procenu pravaca EM signala*
- Tabela 8.5 *Prosečna greška u proceni pravaca pojedinih neuronskih mreža*
- Tabela 8.6 *Procenjeni uglovi u azimutu i elevaciji za četiri merna scenarija u anehoičnoj komori*
- Tabela 9.1 *Rezultati RBF neuronskih mreža za test pozicije izvora signala*
- Tabela 9.2 *Referentni i procenjeni uglovi u azimutu*

1 Uvod

U toku poslednjih nekoliko decenija komunikacione tehnologije su zabeležile ubrzani razvoj i postale ključan faktor modernog društva. Sa pojavom novih generacija bežičnih komunikacionih sistema, težište je sa prenosa govornog signala prebačeno na prenos podataka. Pored zahteva za poboljšanjem kvaliteta servisa (QoS, *Quality of Service*) stalno raste i potreba za uvođenjem novih širokopojasnih servisa, što nije moguće ostvariti bez dodele novih frekvencijskih opsega ili dodatnog povećanja kapaciteta sistema. Sa druge strane, frekvencijski spektar je ograničen resurs i njegovo korišćenje mora biti efikasno. Za raspodelu raspoloživog spektra u bežičnim komunikacionim sistemima primenjuju se tehnike višestrukog pristupa kao što su FDMA (*Frequency Division Multiple Access*), TDMA (*Time Division Multiple Access*) i CDMA (*Code Division Multiple Access*). U kombinaciji sa njima, može se iskoristiti koncept zasnovan na prostornom filtriranju signala, SDMA (*Space Division Multiple Access*). Upotreboom tehnologija kao što su inteligentni antenski sistemi, SDMA omogućava ponovno korišćenje frekvencija (*frequency reuse*) u okviru iste ćelije, čime se u značajnoj meri povećava odnos signal/interferencija, a time i ukupni kapacitet sistema [1].

Kod tradicionalnih mobilnih sistema, bazna stanica je obično opremljena omnidirekcionim ili trosektorskim antenama čiji su dijagrami zračenja veoma široki u azimutu kako bi prihvatali signale velikog broja korisnika. Ona ne raspolaže podacima o lokacijama mobilnih korisnika i samim tim emituje radio signale u svim pravcima u okviru ćelije. Iz tog razloga, u sistemu dolazi do međukanalne interferencije. Kroz upotrebu intelligentnih antenskih sistema, SDMA koncept omogućava usmeravanje radio signala u zavisnosti od lokacije mobilnog korisnika. Intelligentni antenski sistemi koriste antenske nizove i algoritme za procenu pravaca (DOAs, *Directions of Arrival*) iz kojih dolaze korisnički signali, kako bi u zavisnosti od uslova okruženja dinamički oblikovali karakteristiku zračenja antenskog niza. Kontrola karakteristike zračenja se u ovom slučaju vrši promenom amplituda i faza struja napajanja antenskih elemenata.

Algoritmi za procenu pravaca se mogu primeniti za oblikovanje karakteristike zračenja antenskog niza i u *uplink* i u *downlink* pravcu. Čak i u prisustvu komponenti signala usled višestrukog prostiranja antenski niz usmerava glavni list zračenja prema željenom korisniku a nule u karakteristici prema interferentnim signalima, što dovodi do značajnog poboljšanja odnosa SINR (*Signal to Interference and Noise Ratio*). Na ovaj način, ne dolazi

do međukanalne interferencije jer se elektromagnetna energija emituje samo u pravcu određenog korisnika i praktično nema slanja energije u ostalim pravcima. SDMA koncept omogućava baznim stanicama da ostvare veliku pokrivenost uz manju efektivnu snagu zračenja antenskog sistema. Takođe, SDMA vrši značajnu uštedu mrežnih resursa jer sprečava emitovanje radio signala u oblastima gde su korisnici trenutno neaktivni [2]. Na osnovu navedenog, može se zaključiti da performanse inteligentnog antenskog sistema u velikoj meri zavise od efikasnosti algoritama za procenu pravaca iz kojih dolaze EM signali.

Do sada je razvijen veliki broj algoritama za procenu pravaca EM signala. Svi ovi algoritmi mogu biti klasifikovani u tri osnovne kategorije: klasični algoritmi, algoritmi maksimalne verovatnoće (ML - *Maximum Likelihood*) i algoritmi zasnovani na određivanju podprostora [3].

Na početku, najznačajnija primena algoritama za procenu pravaca dolaznih signala bila je za potrebe lokalizacije izvora kod radara i sonara [2]. Ove dve aplikacije primarno su vodile razvoj algoritama za procenu pravaca, još od pojave prvih pristupa o prostornom filtriranju i beamformingu. Konvencionalni beamformer, koji pripada grupi klasičnih algoritama, nastao je još u vreme Drugog svetskog rata i predstavlja primenu *Fourierove spektralne analize* na podacima uzorkovanim u prostorno-vremenskom domenu [4]. Nešto kasnije, razvijene su naprednije tehnike, *delay-and-sum* i MVDR (*Minimum Variance Distortionless Response*), radi poboljšanja detekcije bliskih izvora. Osnovna ideja kod klasičnih algoritama je da se posmatrani prostor skenira u svim pravcima i izmeri snaga primljenih signala iz svakog od njih. Pravci iz kojih dolaze najjači signali smatraju se pravcima u kojima su pozicionirani EM izvori. Uprkos jednostavnosti, nedostatak klasičnih metoda predstavlja jaka zavisnost njihovih performansi od aperture antenskog niza, što ih čini nepogodnim za dobijanje rezultata visoke rezolucije. Ograničenja beamforming metoda bila su povod za razvoj drugih algoritama, koji bi ih prevazišli.

Na razvoju algoritama, zasnovanih na parametarskom metodu, intenzivno se radilo poslednje tri decenije. Boljim razumevanjem i eksploracijom fizičkih modela komunikacionog kanala, ostvarene su bolje performanse od klasičnih algoritama. S obzirom da se procena pravaca signala za komunikacione scenarije suštinski razlikuje od tipične radarske primene, pri opisu modela signala su uključene i karakteristike bežičnog kanala. ML algoritmi su jako moćni i mogu se primeniti za određivanje pravaca i nekih koreliranih signala. Ovi algoritmi ostvaruju optimalnu procenu pravaca po cenu jako kompleksnih proračuna [5].

Najveću pažnju istraživača su privukli algoritmi zasnovani na određivanju podprostora. Dva algoritma iz ove grupe, MUSIC (*MULTiple SIgnal Classification*) [6] i ESPRIT (*Estimation of Signal Parameters via Rotational Invariance Techniques*), izdvajaju se po svojoj preciznosti [7]. MUSIC algoritam određuje pravce na osnovu pretrage spektra primljenih signala i smatra se najpouzdanim algoritmom za procenu pravaca. Međutim, nedostatak ovog algoritma predstavlja njegova vremenska neefikasnost. Usled kompleksnih matričnih operacija nad prostornom kovarijansnom matricom, MUSIC algoritam nije pogodan za upotrebu u realnom vremenu. Brojne modifikacije ovog algoritma doprinele su poboljšanju njegovih nedostataka u pogledu efikasnosti i detekcije koreliranih signala [8]-[9]. ESPRIT algoritam ima prednost u odnosu na MUSIC kada je potrebno odrediti višedimenzionalne parametre primljenih signala na antenskom nizu [7], [10]. S obzirom da se procena pravaca EM signala kod ESPRIT algoritma ne zasniva na pretrazi spektra, kompleksnost izračunavanja raste linearno sa povećanjem dimenzija antenskog niza, dok je kod MUSIC algoritma ova zavisnost eksponencijalna.

U slučaju procene pravaca u azimutu i elevaciji (dvodimenzionalni slučaj, 2D), 2D MUSIC vrši pretragu spektra po svim uglovima u azimutu i elevaciji što predstavlja jako dugotrajan i zahtevan proces. U cilju prevazilaženja ovog problema, razvijena je modifikacija 2D ESPRIT algoritma [11]. S obzirom da ovaj metod ne zahteva kompleksne procedure pretrage spektra i inicijalizaciju, njegova je kompleksnost udvostručena u odnosu na 1D ESPRIT algoritam. Radi poboljšanja procene pravaca predloženi su novi algoritmi razvijeni na osnovu generalizovane *Rayleigheve* teorije [12]-[13]. Faktorizacijom *steering* vektora u odnosu na pravce dolaska ili druge parametre (npr. šum), uglovi u azimutu i elevaciji se određuju jednostavnom jednodimenzionalnom optimizacionom procedurom. Pokazano je da se performanse ovog metoda mogu porediti sa performansama MUSIC algoritma za vrednosti odnosa signal/šum veće od 20 dB [13]. Propagatorski model, koji koristi L-konfiguraciju antenskog niza za preciznu procenu pravaca dolaska EM signala, predložen je u [14]. Ovaj model ne vrši dekompoziciju prostorne kovarijanske matrice ali podrazumeva antenske elemente idealnih karakteristika i zanemaruje postojanje elektromagnetskih sprega između njih. Pristup zasnovan na singularnoj dekompoziciji kros-korelacionih matrica primljenih signala prikazan je u [15]. Algoritam je razvijen podrazumevajući L-geometriju antenskog niza, i najpre vrši procenu pravaca u elevaciji a potom u azimutu, u potpuno odvojenim procedurama. Modifikacije MUSIC i ESPRIT algoritama zasnovane na virtuelnim antenskim nizovima mogu doprineti efikasnijoj proceni pravaca EM signala, u poređenju sa MUSIC algoritmom [16]-[19]. Primena SVM (*Support Vector Machine*) metode u oblasti procene

pravaca analizirana je u [20], i verifikovana simulacijama. Algoritam za detekciju nekorelisanih i koherentnih signala opisan je u [21], i predstavlja modifikaciju ESPRIT algoritma. Procena pravaca koherentnih signala u azimutu i elevaciji, primenom 2D *Unitary* ESPRIT metoda, prikazana je u [22]. Performanse ovog modela su takođe verifikovane za nekoliko pozicija EM izvora u procesu simulacija.

Međutim, iako pomenuti algoritmi imaju manju kompleksnost izračunavanja u odnosu na 2D MUSIC algoritam, oni nisu dovoljno efikasni za procenu pravaca EM signala u realnom vremenu. Pored toga, performanse najpreciznijih algoritama za procenu pravaca mogu biti u velikoj meri degradirane usled grešaka u procesu kalibracije antenskog niza, perturbacija amplituda i faza, grešaka usled elektromagnetne sprege između antenskih elemenata, grešaka u izradi antenskog niza i pozicioniranju pojedinih antenskih elemenata. Netačan model šuma takođe može drastično da pogorša performanse algoritama za procenu pravaca. Pored toga, najveći broj algoritama podrazumeva da je broj dolaznih EM signala unapred poznat. Problem procene broja signala je poznat kao problem detekcije i najčešće se rešava odvojeno od procene pravaca EM signala.

Poslednjih par decenija, razmatran je pristup za određivanje pravaca EM signala zasnovan na primeni veštačkih neuronskih mreža (ANNs, *Artificial Neural Networks*). Neuronske mreže predstavljaju veoma pogodan alat za modelovanje, pre svega, zahvaljujući sposobnosti da uče na osnovu prikazanih primera [23]. U poređenju sa konvencionalnim algoritmima za procenu pravaca koji su zasnovani na linearnim modelima, neuronske mreže posmatraju problem procene pravaca kao aproksimaciju jako nelinearne višedimenzionalne funkcije, ili drugim rečima, kao preslikavanje između prostorne kovarijansne matrice primljenih signala na antenskim elementima i pravaca njihovog dolaska.

Postoje brojne publikacije o primeni neuronskih mreža u oblasti procene pravaca različitih EM signala (uskopojasnih, širokopojasnih), [24]-[36]. Upotreba neuronskih mreža radijalnih bazisnih funkcija (RBF-NNs, *Radial Basis Function Neural Networks*) za određivanje uglova u azimutu, najčešća je u ovim radovima. Takođe, objavljen je manji broj radova koji se odnose na 2D procenu pravaca [33]-[36]. Pristup zasnovan na primeni višeslojnih perceptronskih neuronskih mreža (MLP-NNs, *Multilayer Perceptron Neural Networks*) predložen je u [33]. Za procenu pravaca dolaska signala su korišćeni samo podaci o amplitudama signala sa antenskog niza L-konfiguracije. U radu [34], razmatrana je 2D procena pravaca u polusfernem prostoru pomoću RBF neuronske mreže i kružno polarizovanih *patch* antena. Eksperimentalna verifikacija RBF neuronskog modela za određivanje ugaonih pozicija EM izvora pomoću kružnog antenskog niza, data je u [35].

U ovoj disertaciji je prikazan novi metod za precizno određivanje pravaca dolaska EM signala, zasnovan na primeni veštačkih neuronskih mreža. Razmatrane su tri konfiguracije antenskih nizova i različiti tipovi dolaznih signala, uključujući nekorelisane, korelisane i radarske signale. Akcenat je stavljen na pravougaoni antenski niz i procenu pravaca u azimutu i elevaciji. Najveći doprinos disertacije predstavlja razvoj neuronskog modela za veoma preciznu procenu pravaca dolaska EM signala u azimutu i elevaciji, kao i razvoj modela za detekciju koherentnih EM signala. Razvijeni su simulacioni, empirijski kao i kaskadni neuronski modeli. U disertaciji je opisana procedura za dobijanje merenih rezultata u ovoj oblasti. Veliki broj modela je verifikovan eksperimentalnim rezultatima. Performanse razvijenih modela su upoređene sa standardnim algoritmima u ovoj oblasti. Neuronski modeli su se pokazali veoma pogodnim za precizno određivanje pravaca dolaska EM signala jer se prilikom njihove obuke mogu uključiti brojni faktori koje je nemoguće opisati preciznim matematičkim modelima. Sam izbor podataka za obuku, njihovo prezentovanje neuronskoj mreži, kao i organizovanje mreža u složenije hijerarhijske neuronske modele predstavlja značajan doprinos ove disertacije. Takođe, u jednom poglavlju je urađena kraća analiza primene neuronskih modela za detekciju pravaca radarskih MIMO OFDM signala.

Disertacija je organizovana na sledeći način: u Poglavlju 2 je dat pregled standardnih konfiguracija antenskih nizova za procenu pravaca dolaznih EM signala. U Poglavlju 3, opisana je struktura MLP i RBF neuronskih mreža kao i odgovarajući algoritmi za obuku. U Poglavlju 4, ukratko je dat postupak za određivanje prostorne kovarijansne matrice. Opisan je princip rada MUSIC algoritma i veštačkih neuronskih mreža. U ovom poglavlju je data i procedura za preprocesiranje podataka za obuku neuronskih mreža u slučaju nekorelisanih i korelisanih signala. Poglavlja 2-4 uglavnom sadrže rad drugih autora.

Poglavlja 5-9 predstavljaju originalni naučni doprinos autora ove disertacije. U Poglavlju 5, data je primena sektorizacionog neuronskog modela u proceni pravaca EM signala u azimutu i elevaciji. Opisana je procedura izbora podataka za obuku neuronskih mreža kao i način njihove obuke. Data je diskusija o dobijenim rezultatima simulacija i poređenje sa 2D MUSIC algoritmom. U Poglavlju 6, prikazana je merna procedura za dobijanje eksperimentalnih rezultata u oblasti antenskih nizova i procene pravaca EM signala. Verifikacija metoda je urađena primenom MUSIC algoritma, nakon čega su prikupljeni podaci iskorišćeni za obuku neuronskih modela. U ovom poglavlju je opisan razvoj i verifikacija empirijskog modela za procenu pravaca EM signala. Kaskadni neuronski model koji kombinuje neuronske modele zasnovane na simulacionim i merenim podacima, prikazan je u Poglavlju 7. Pokazano je da ovakav model može da poboljša tačnost simulacionog

neuronskog modela u realnim aplikacijama, uključivanjem male količine merenih podataka u razvoj modela. Poglavlje 8 se bavi 2D detekcijom koherentnih signala. Najpre je prikazan razvoj i testiranje jedne neuronske mreže za procenu pravaca dva koherentna signala. Performanse mreže su ocenjene u procesu simulacija. U drugom delu poglavlja je razvijen složeniji neuronski model zasnovan na simulacionim podacima, nakon čega je data merna procedura i opisana verifikacija modela za slučaj dva koherentna izvora. U Poglavlju 9, dati su rezultati istraživanja uticaja odnosa signal/šum i korelacije signala na performanse neuronskih modela. Takođe je opisana detekcija radarskih MIMO OFDM signala.

Poslednje poglavlje u disertaciji sadrži zaključke o najvažnijim rezultatima. Ujedno su definisane i smernice za dalja istraživanja u ovoj oblasti. Na kraju disertacije, dat je pregled literature koja je korišćena za naučno-istraživački rad i pisanje same disertacije.

2 Primena antenskih nizova kod intelligentnih antenskih sistema

Intelligentni antenski sistem se sastoji od antenskog niza i koherentnih primopredajnika sa naprednim algoritmima za digitalnu obradu signala [37]-[39]. Kada antenski niz radi u prijemnom režimu, signali sa različitih antenskih elemenata se kombinuju pomoću adaptivnog algoritma, dok se kod predajnog antenskog niza signali na antenskim elementima formiraju pomoću algoritma. Može se zaključiti da “inteligencija” nije u samim antenama već u algoritmima za obradu signala koji omogućavaju dinamičko oblikovanje karakteristike zračenja antenskog niza radi ostvarivanja optimalnog prijema signala i smanjenja interferencije.

2.1 Prednosti upotrebe intelligentnih antenskih sistema

Primenom intelligentnih antena kod bežičnih komunikacionih sistema ostvaruju se sledeća poboljšanja:

- Povećanje pokrivenosti – u ovom slučaju se podrazumeva da intelligentna antena radi u prijemnom režimu. Ukoliko je poznata pozicija predajnika tada antenski niz na prijemu može da formira karakteristiku zračenja u pravcu predajnika što rezultuje većom primljenom snagom. Poboljšanje odnosa signal/šum (SNR, *Signal to Noise Ratio*) utiče na povećanje površine oblasti koju može da pokrije jedna bazna stanica. Ili obratno, oblast pokrivenosti može ostati ista uz smanjenu snagu predajnika [1].
- Povećanje kapaciteta sistema – kroz optimalno kombinovanje signala intelligentne antene mogu da poboljšaju odnos signal/interferencija (SIR, *Signal to Interference Ratio*), što dovodi do povećanog broja korisnika.
- Poboljšanje kvaliteta linka – povećanjem snage signala i/ili smanjenjem snage interferencije može se poboljšati kvalitet predaje na svakom zasebnom linku.
- Smanjenje disperzije kašnjenja signala – potiskivanjem komponenti signala nastalih usled prostiranja po višestrukim putanjama postiže se smanjenje disperzije kašnjenja što je posebno korisno u sistemima sa velikom brzinom prenosa podataka.
- Poboljšanje procene pravca korisničkog signala – poznavanje pravca dolaska signala poboljšava geolokaciju korisnika.

- Potiskivanje interferencije – komunikacioni sistemi su veoma osetljivi na interferentne signale primljene od strane antenskih nizova preko bočnih listova zračenja. Potiskivanje interferencije se obično vrši propuštanjem signala kroz neku vrstu digitalnog filtra, koji otklanja smetnje i propušta željeni signal relativno nepromenjen. Jako je važna upotreba antenskih sistema u potiskivanju jakih interferentnih signala (npr. namerno ometanje), gde konvencionalni filtri prijemnika imaju slabe performanse. Samim tim, antenski sistem može biti posmatran kao prostorni filter sa karakteristikom zračenja koja je ekvivalentna odzivu FIR (*Finite Impulse Response*) digitalnog filtra.

Upotrebom inteligentnih antenskih sistema nije moguće istovremeno, i u potpunosti, ostvariti sva navedena poboljšanja. U najvećem broju slučajeva, potrebno je postići izvesne kompromise u zavisnosti od prioritetnih ciljeva [1].

2.2 Vrste intelligentnih antenskih sistema

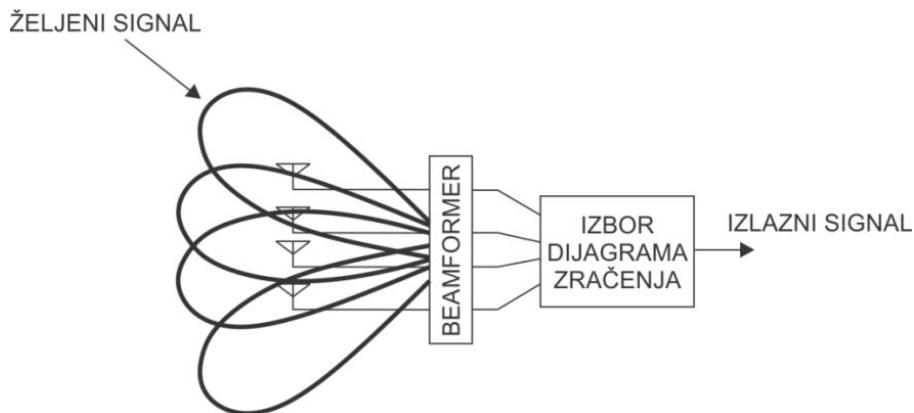
Razlikuju se tri osnovna tipa intelligentnih antenskih sistema (*SA – Smart Antenna*): *switched-beam* antena, sistemi sa faziranim antenskim nizovima i adaptivni antenski sistemi [38]-[42].

Na Slici 2.1, prikazana je *switched-beam* antena. Ovakva antena može da formira određeni broj fiksnih dijagrama zračenja usmerenih u određenom pravcu. U zavisnosti od lokacije korisnika *switch* vrši izbor dijagrama zračenja koji daje najbolji odnos SNR ili SINR. Zbog veće usmerenosti u odnosu na konvencionalnu antenu ostvaruje se određeno pojačanje, osim u slučaju bliskih korisnika. Upotreba *switched-beam* antene u velikoj meri pojednostavljuje dizajn prijemnika.

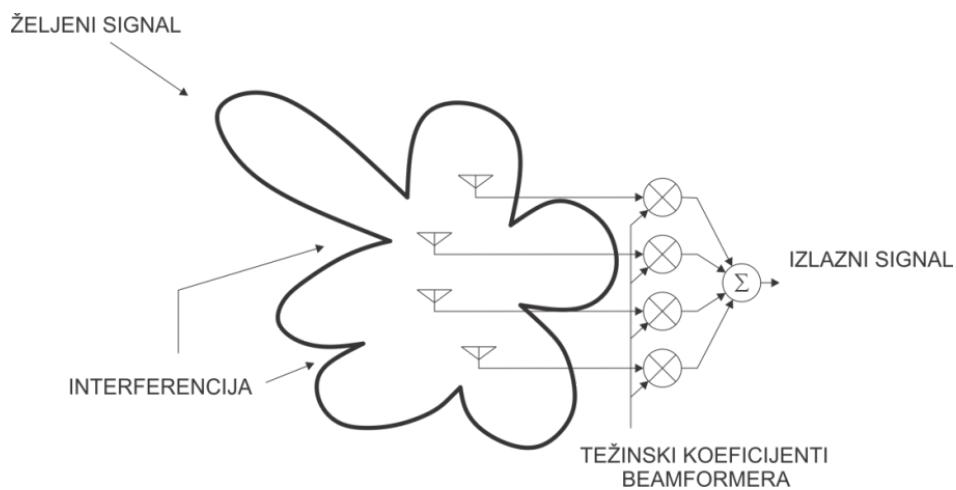
Fazirani antenski niz takođe koristi algoritme za određivanje pravaca dolaznih signala kako bi se dijagram zračenja usmerio u pravcu korisnog signala. Faze antenskih elemenata se kontrolišu pomeračima faze tako da je upotrebom ovih antenskih nizova moguće kontinualno praćenje signala.

Na Slici 2.2, prikazan je treći tip intelligentnih antena, odnosno, adaptivni antenski niz. Kod adaptivnih antenskih nizova se primljeni signali množe težinskim koeficijentima i kombinuju kako bi se postigla maksimalna vrednost SINR. Ovakvi nizovi predstavljaju najsloženiju varijantu intelligentnih antenskih sistema s obzirom da se kod njih koriste algoritmi za određivanje pravaca signala, kako korisnih tako i interferentnih. Na osnovu poznavanja pravaca dolaska signala vrši se izbor dijagrama zračenja koji će dati maksimalni

odnos SINR. Generisanje nula u dijagramu zračenja u pravcu interferentnih signala moguće je u slučaju kada je broj interferentnih korisnika manji od broja antenskih elemenata. Problemi se mogu javiti u okruženjima sa jako izraženim efektima prostiranja signala po višestrukim putanjama i u situacijama kada ne postoji direktna linija vidljivosti (LOS, *Line of Sight*). U slučaju generisanja glavnog lista zračenja, postiže se maksimalno pojačanje kako u uslovima postojanja LOS tako i u uslovima odsustva LOS i jako izražene višestruke propagacije.



Slika 2.1 *Switched-beam antenna*



Slika 2.2 *Adaptivni antenski niz*

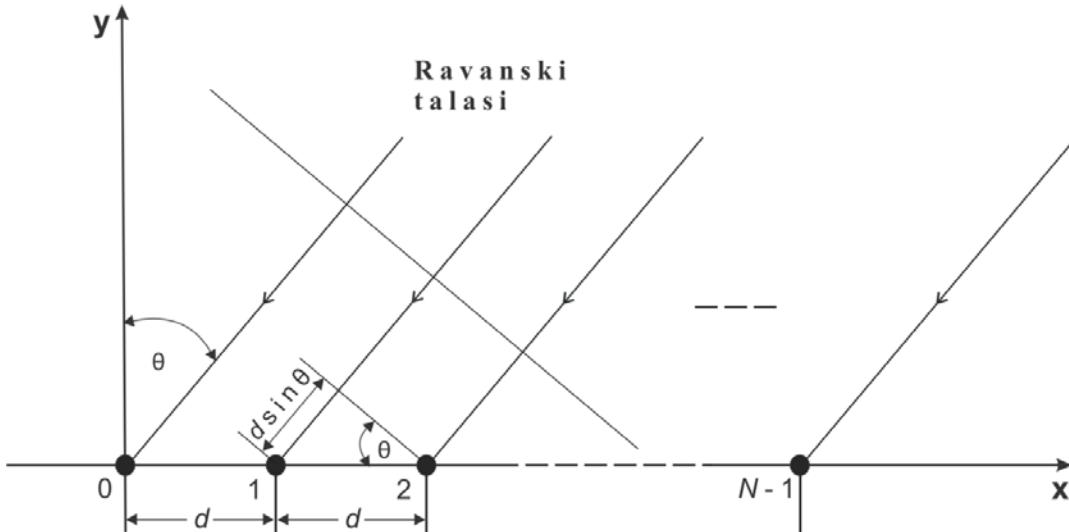
2.3 Antenski nizovi

Antenski niz predstavlja skup od N prostorno razdvojenih antenskih elemenata. U poređenju sa performansama jedne antene, antenski niz je daleko superiorniji u predaji i prijemu signala. Karakteristika zračenja antenskog niza je određena brojem antenskih elemenata, vrstom elemenata koji se koriste, njihovim prostornim rasporedom kao i amplitudama i fazama struja koje ih napajaju. Sa povećanjem broja elemenata u nizu dolazi do poboljšanja njegovih karakteristika, tako da antenski nizovi namenjeni za vojne primene mogu imati i po nekoliko hiljada antenskih elemenata. Postoji više vrsta antena koje se mogu koristiti kao antenski elementi u nizu: monopoli, dipoli, *patch* antene, levak antene, spiralne i druge. Konstelacija antenskih elemenata može biti linearna, kružna, planarna ili trodimenzionalna. Najčešće su u upotrebi uniformni antenski nizovi sa konstantnim rastojanjem između antenskih elemenata. Linearni i kružni antenski nizovi se koriste za kontrolu dijagrama zračenja u azimutu, dok se planarni i trodimenzionalni nizovi mogu koristiti za upravljanje dijagramom zračenja kako po azimutu, tako i po elevaciji [42]-[44].

Za primenu u mobilnim sistemima do sada su najčešće razmatrani linearne i kružne antenske nizove. Glavna razlika između ove dve konfiguracije ogleda se u tome što kružni nizovi omogućavaju potpuno pokrivanje po azimutu, dok linearne konfiguracije imaju veći broj ograničenja. Linearni nizovi se uglavnom koriste u opsegu azimuta od 120° . Antenski nizovi se ne mogu učiniti proizvoljno malim jer se usled malih rastojanja između antenskih elemenata pojavljuje elektromagnetska sprega između njih. Iz tog razloga, poželjno je da rastojanje između elemenata bude jednak polovini talasne dužine elektromagnetskih talasa, $\lambda/2$. Sa druge strane, direaktivnost antene je proporcionalna relativnom odnosu ukupne dužine antenskog niza i λ , pa je istovremeno cilj da ukupna dužina niza bude što veća. Iz navedenog razloga, potrebno je napraviti kompromis između direaktivnosti i nivoa bočnih listova zračenja.

2.3.1 Linearni antenski niz

Posmatraćemo linearne antenske nizove sastavljen od N identičnih izotropnih antenskih elemenata, raspoređenih na jednakim međusobnim rastojanjima označenim sa d . Antenski elementi su postavljeni duž x -ose koordinatnog sistema, Slika 2.3.



Slika 2.3 Uniformni linearni antenski niz

Faktor niza se može napisati u funkciji sfernih koordinata φ i θ na sledeći način:

$$AF_{linear} (\theta, \varphi) = \sum_{n=0}^{N-1} I_n e^{j\left(\frac{2\pi}{\lambda}dnsin\theta + \delta_n\right)}, \quad (2.1)$$

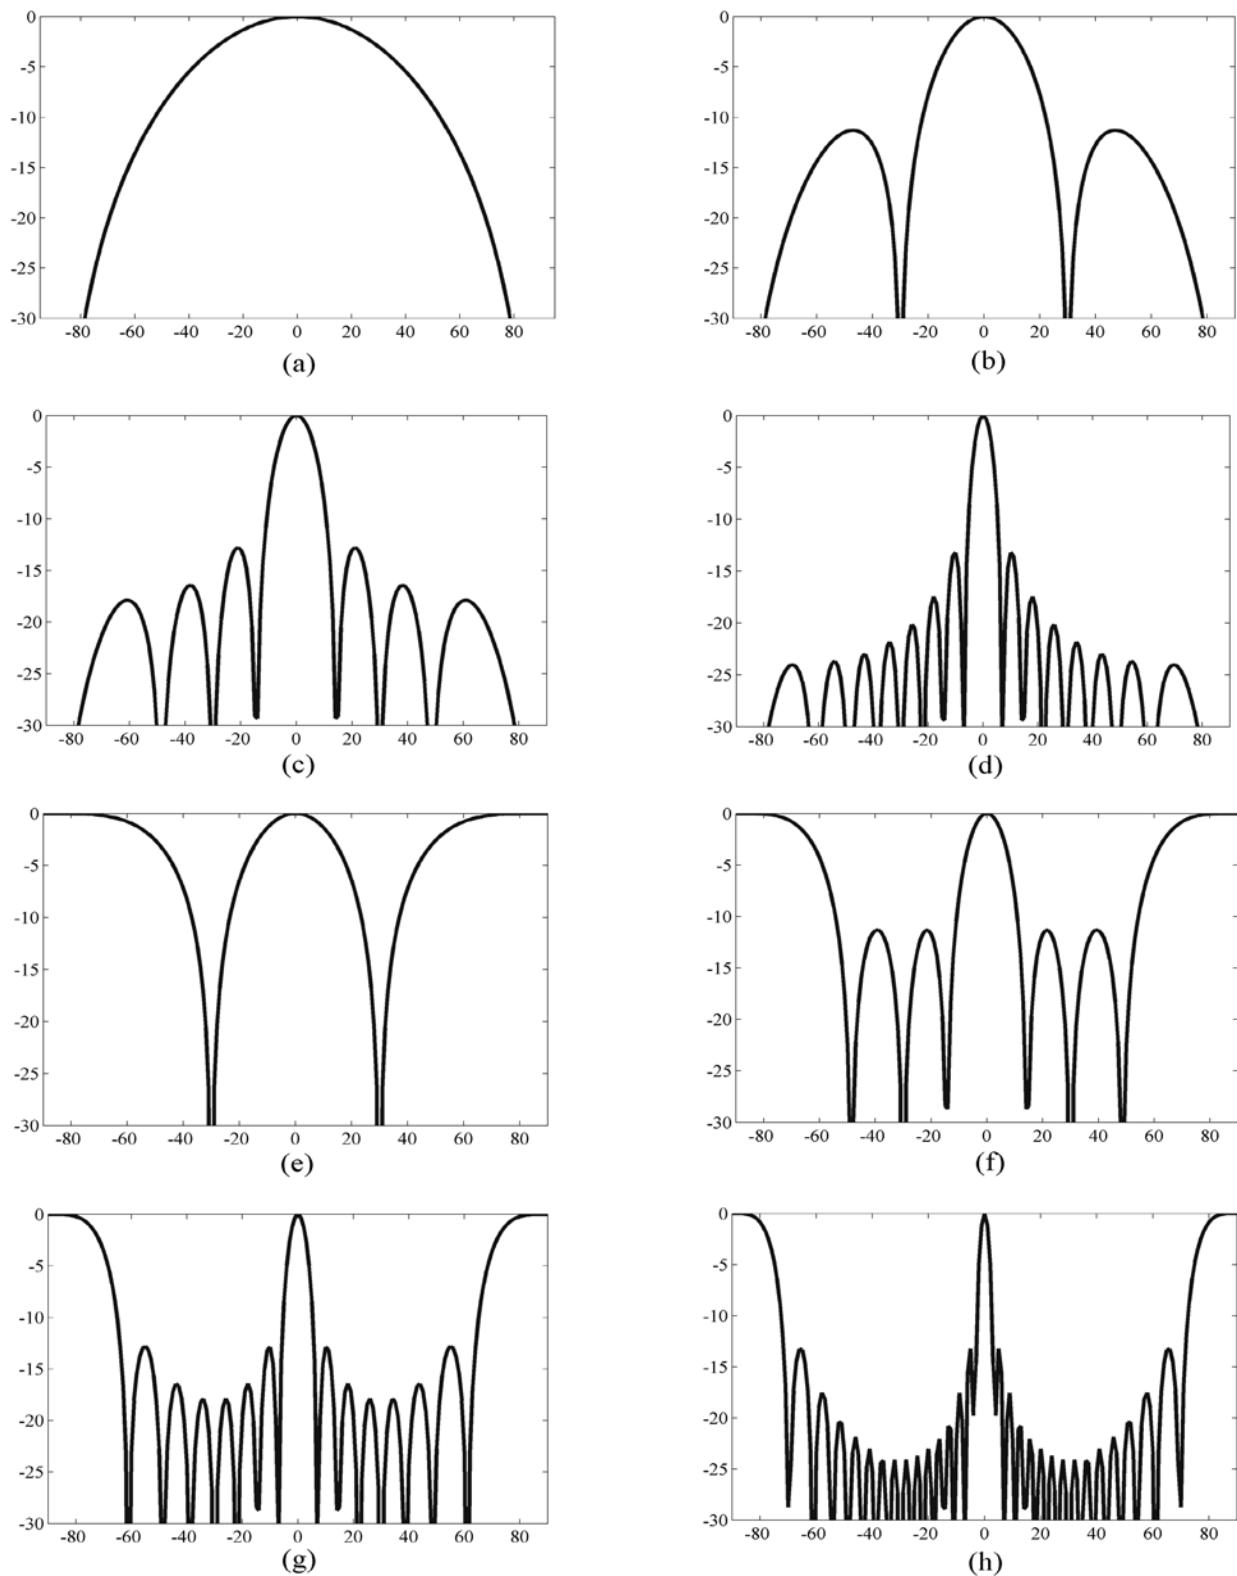
gde su I_n i δ_n ($n=0, 1, 2, \dots, N-1$) amplituda i faza eksitacije n -tog elementa niza, dok je sa d označeno rastojanje između dva susedna elementa. Vrednosti I_n i δ_n su određene specifičnim dizajnom mreže za napajanje antenskog niza [44]. Faktor niza se obično izražava kao apsolutna vrednost izraza (2.1), normalizovana u odnosu na maksimalnu vrednost i prikazana u dB skali:

$$|AF_{linear}^{norm} (\theta, \varphi)| = \frac{|AF_{linear} (\theta, \varphi)|}{\max \{|AF_{linear} (\theta, \varphi)|\}}. \quad (2.2)$$

U slučaju uniformnog napajanja antenskog niza ($I_n=I$ i $\delta_n=0$, $n=0, 1, 2, \dots, N-1$), normalizovani faktor niza se može napisati u sledećem obliku:

$$|AF_{linear}^{norm} (\theta, \varphi)| = \frac{1}{N} \left| \frac{\sin \left(\frac{N2\pi}{\lambda} ds \sin \theta \right)}{\sin \left(\frac{2\pi}{\lambda} ds \sin \theta \right)} \right|. \quad (2.3)$$

Na osnovu prethodnog izraza se može zaključiti da faktor niza ne zavisi od φ i da ima maksimalnu vrednost jednaku jedinici za $\theta=0$ [44].



Slika 2.4 Faktor niza u zavisnosti od broja antenskih elemenata i rastojanja između susednih elemenata (a) $N=2$, $d=\lambda/2$, (b) $N=4$, $d=\lambda/2$, (c) $N=8$, $d=\lambda/2$, (d) $N=16$, $d=\lambda/2$, (e) $N=2$, $d=\lambda$, (f) $N=4$, $d=\lambda$, (g) $N=8$, $d=\lambda$, (h) $N=16$, $d=\lambda$ [2]

Funkcija data u (2.3) ima maksimume za vrednosti θ date sledećim izrazom:

$$\theta = \pm \arcsin\left(\frac{\lambda a}{d}\right). \quad a=1, 2, \dots \quad (2.4)$$

Ukoliko je rastojanje između susednih elemenata jednako ili manje od talasne dužine λ , tada antenski niz ima samo jedan maksimum u karakteristici zračenja. Ovaj maksimum odgovara glavnom listu zračenja u opsegu uglova u azimutu od -90° do 90° . Za rastojanja $d > \lambda$ javljaju se neželjeni listovi zračenja (*grating lobes*) u opsegu uglova od -90° do 90° . Na osnovu izraza (2.3) sledi da je vrednost najvećeg bočnog lista u karakteristici zračenja (u odnosu na glavni list), jednaka -13.1 dB. Ugaona pozicija glavnog lista zračenja se može odrediti na osnovu sledećeg izraza:

$$\theta_{max\ lobe} = \pm \arcsin\left(\frac{3}{2} \frac{1}{N} \frac{\lambda}{d}\right). \quad (2.5)$$

Na Slici 2.4, prikazani su rezultati simulacija normalizovanog faktora niza u zavisnosti od broja antenskih elemenata i rastojanja između njih. Rezultati svih simulacija dobijeni su za uniformnu raspodelu amplituda i normalizovani su u odnosu na nivo glavnog lista zračenja. Slike 2.4 (a)-(d), prikazuju rezultate za rastojanje između antenskih elemenata jednako $\lambda/2$, dok Slike 2.4 (e)-(h) ilustruju faktor niza za $d=\lambda$. Kao što se može videti, veće rastojanje između antenskih elemenata generiše neželjene listove u karakteristici zračenja sa amplitudama jednakim amplitudi glavnog lista. Vrednost bočnih listova zračenja iznosi -13 dB, što se poklapa sa rezultatima jednačine (2.3). Širina glavnog lista zračenja između dve nule može se približno izračunati na osnovu izraza:

$$\Delta\theta_{main} \approx \frac{2}{d} \frac{\lambda}{N}. \quad (2.6)$$

Direktivnost linearног antenskog niza, koji zraчи u pravcu koji je ortogonalan u odnosu na osu niza, data je izrazom:

$$D_{linear} = \frac{N^2}{N+2 \sum_{n=1}^{N-1} \frac{(N-n)\sin\left(\frac{n}{\lambda}2\pi d\right)}{n\frac{2\pi}{\lambda}d}}. \quad (2.7)$$

Za rastojanje između antenskih elemenata od $\lambda/2$, direktivnost je jednaka broju antenskih elemenata N . Direktivnost antenskog niza raste sa povećanjem rastojanja između antenskih elemenata sve do pojave prvog neželjenog lista zračenja, kada počinje da opada.

Kontrola nivoa bočnih listova zračenja

Primarna funkcija adaptivnog antenskog sistema je kontrola karakteristike zračenja antenskog niza sa ciljem da se glavni list zračenja usmeri prema željenom korisniku, a nule prema interferentnim signalima. Pored toga, potrebno je kontrolisati i nivo bočnih listova zračenja što se postiže podešavanjem kompleksnih težinskih koeficijenata koji su pridruženi svakom pojedinačnom antenskom elementu. Kompleksne težine se sastoje od amplitudske i fazne komponente, $A_n = \alpha_n e^{j\beta_n}$, gde je A_n kompleksna težina n -tог elementa, α_n je amplitudski težinski koeficijent, dok je β_n fazni težinski koeficijent n -tог elementa. Amplitudska komponenta kontroliše nivo bočnih listova zračenja kao i širinu glavnog lista, dok fazna komponenta utiče na pravce u kojima su usmereni glavni list i nule u karakteristici zračenja.

Nivo bočnih listova u karakteristici zračenja linearog antenskog niza može se u određenoj meri kontrolisati pomoću prozorskih funkcija. Na ovaj način se vrši podešavanje amplitudskih težina antenskih elemenata. Standardne prozorske funkcije kao što su pravougaona, *Hammingova*, *Hanningova*, *Bartlettova*, *Kaiserova*, triangularna i *Dolph-Chebyshevleva*, imaju brojne primene u obradi signala i beamformingu. Svaka od njih predstavlja kompromis između širine glavnog lista zračenja (HPBW, *Half-Power Beam Width*) i nivoa bočnih listova zračenja (SLL, *Sidelobe Level*). Odnos između amplitudskih težina i karakteristike zračenja definisan je *Fourierovom* transformacijom na isti način na koji su povezani vremenski i frekvencijski domen u oblasti obrade signala.

Pravougaona prozorska funkcija daje uniformne amplitudske težinske koeficijente za sve elemente antenskog niza. Kao posledica toga, karakteristika zračenja antenskog niza je identična karakteristici bez primenjene prozorske funkcije. Širina glavnog lista zračenja je minimalna ali je zato nivo bočnih listova zračenja relativno visok. Težinski koeficijenti amplituda se izračunavaju pomoću izraza:

$$\mathbf{w}(n)=1, \quad (2.8)$$

gde je n redni broj antenskog elementa ($n=0, 1, \dots, N-1$). Na Slici 2.5 (a) prikazana je odgovarajuća karakteristika zračenja za antenski niz od osam elemenata.

Bartlettova prozorska funkcija se formira konvolucijom dva pravougaona prozora [2]. Određivanje amplitudskih težinskih koeficijenata rezultuje nultim amplitudama na krajnjim elementima što dovodi do smanjenja aperture antenskog niza i širenja glavnog lista zračenja. Postepeno opadanje amplituda preostalih antenskih elemenata od centra antenskog niza

prema krajevima (tzv. tejperovanje) utiče na smanjenje nivoa bočnih listova zračenja u poređenju sa karakteristikom zračenja bez primenjene prozorske funkcije, Slika 2.5 (b). Izrazi za određivanje amplitudskih težinskih koeficijenata razlikuju se u zavisnosti od toga da li je broj elemenata antenskog niza, N , paran:

$$\mathbf{w}(n) = \begin{cases} \frac{2n}{N-1} & 0 \leq n \leq \frac{N-1}{2} \\ 2 - \frac{2n}{N-1} & \frac{N-1}{2} < n \leq N-1 \end{cases} \quad (2.9)$$

ili neparan:

$$\mathbf{w}(n) = \begin{cases} \frac{2n}{N-1} & 0 \leq n \leq \frac{N}{2}-1 \\ \frac{2(N-n-1)}{N-1} & \frac{N}{2}-1 < n \leq N-1 \end{cases} \quad (2.10)$$

Blackmanova prozorska funkcija predstavlja generalizovanu kosinusnu funkciju. Odgovarajući amplitudski težinski koeficijenti se izračunavaju na sledeći način:

$$\mathbf{w}(n) = 0.42 - 0.5 \times \cos\left(\frac{2\pi n}{N-1}\right) + 0.08 \times \cos\left(\frac{4\pi n}{N-1}\right). \quad (2.11)$$

Dijagram zračenja koji odgovara ovoj prozorskoj funkciji je prikazan na Slici 2.5 (c). Može se uočiti da je nivo bočnih listova zračenja jako snižen po cenu šireg glavnog lista zračenja.

Hammingova prozorska funkcija je takođe primer generalizovane kosinusne funkcije kod koje se amplitudski težinski koeficijenti određuju na osnovu izraza:

$$\mathbf{w}(n) = 0.54 - 0.46 \times \cos\left(\frac{2\pi n}{N-1}\right), \quad (2.12)$$

gde je $n=0, 1, 2, \dots, N-1$. Odgovarajući dijagram zračenja je prikazan na Slici 2.5 (d).

U slučaju *Kaiserove* prozorske funkcije odnos između energije bočnih listova zračenja i glavnog lista je maksimalan. Amplitudski težinski koeficijenti se izračunavaju na osnovu izraza

$$\mathbf{w}(n) = \frac{I_0(\alpha \sqrt{1-(2(n-N/2))^2})}{I_0}, \quad (2.13)$$

gde je α parametar koji kontršti nivo bočnih listova dok je I_0 modifikovana *Besselova* funkcija nultog reda. Na Slici 2.5 (e), prikazan je dijagram zračenja antenskog niza za slučaj $\alpha=5$. Veća vrednost α daje niže bočne listove po cenu šireg glavnog lista zračenja. Za $\alpha=1$,

dijagram zračenja antenskog niza sličan je dijagramu sa primjenom pravougaonom prozorskom funkcijom.

Dolph-Chebyshevjeva prozorska funkcija daje glavni list zračenja minimalne širine za dati nivo bočnih listova zračenja. Nivo svih bočnih listova je konstantan i drastično smanjen. Izračunavanje amplitudskih težinskih koeficijenata se znatno razlikuje od ostalih prozorskih funkcija i predstavlja primer sinteze antenskog niza. Karakteristika zračenja niza se formira na osnovu zadatih parametara, kao što su širina glavnog lista zračenja i nivo bočnih listova. Nedostatak ove prozorske funkcije dolazi do izražaja kod velikih antenskih nizova gde daljim povećanjem broja elemenata dolazi do zasićenja direktivnosti [45].

Amplitudski težinski koeficijenti se određuju na osnovu karakteristike zračenja antenskog niza. Karakteristika zračenja niza se može definisati kao zbir kosinusnih funkcija i u slučaju neparnog broja antenskih elemenata može se napisati u sledećem obliku:

$$E(\theta, \varphi) = \sum_{n=0}^{\left(\frac{N-1}{2}\right)} \alpha_n \cos(2nu), \quad (2.14)$$

dok se u slučaju parnog broja elemenata koristi izraz:

$$E(\theta, \varphi) = \sum_{n=0}^{\left(\frac{N-1}{2}\right)} \alpha_n \cos[(2N+1)nu], \quad (2.15)$$

gde je $u=(\pi d/\lambda)\sin\theta\sin\varphi$, N je broj antenskih elemenata, n je redni broj elementa i α_n je n -ta amplitudska težina.

Dolph-Chebyshevjeva funkcija omogućava izračunavanje vrednosti α_n za zadat maksimalni nivo bočnih listova zračenja. Zbir kosinusa i sinusa u jednačinama (2.14) i (2.15), sastoji se od $N-1$ harmonika. Daljim razvojem ovih izraza primenom *Eulerove* formule:

$$e^{jmn} = \cos(mn) + j\sin(mn), \quad (2.16)$$

gde m označava redni broj harmonika ($m=0, 1, 2, \dots, M-1$), i uvodeći smenu $z=\cos(u)$, izrazi (2.14) i (2.15) se mogu napisati u obliku *Chebyshevjevih* polinoma $T_m(z)$, na sledeći način:

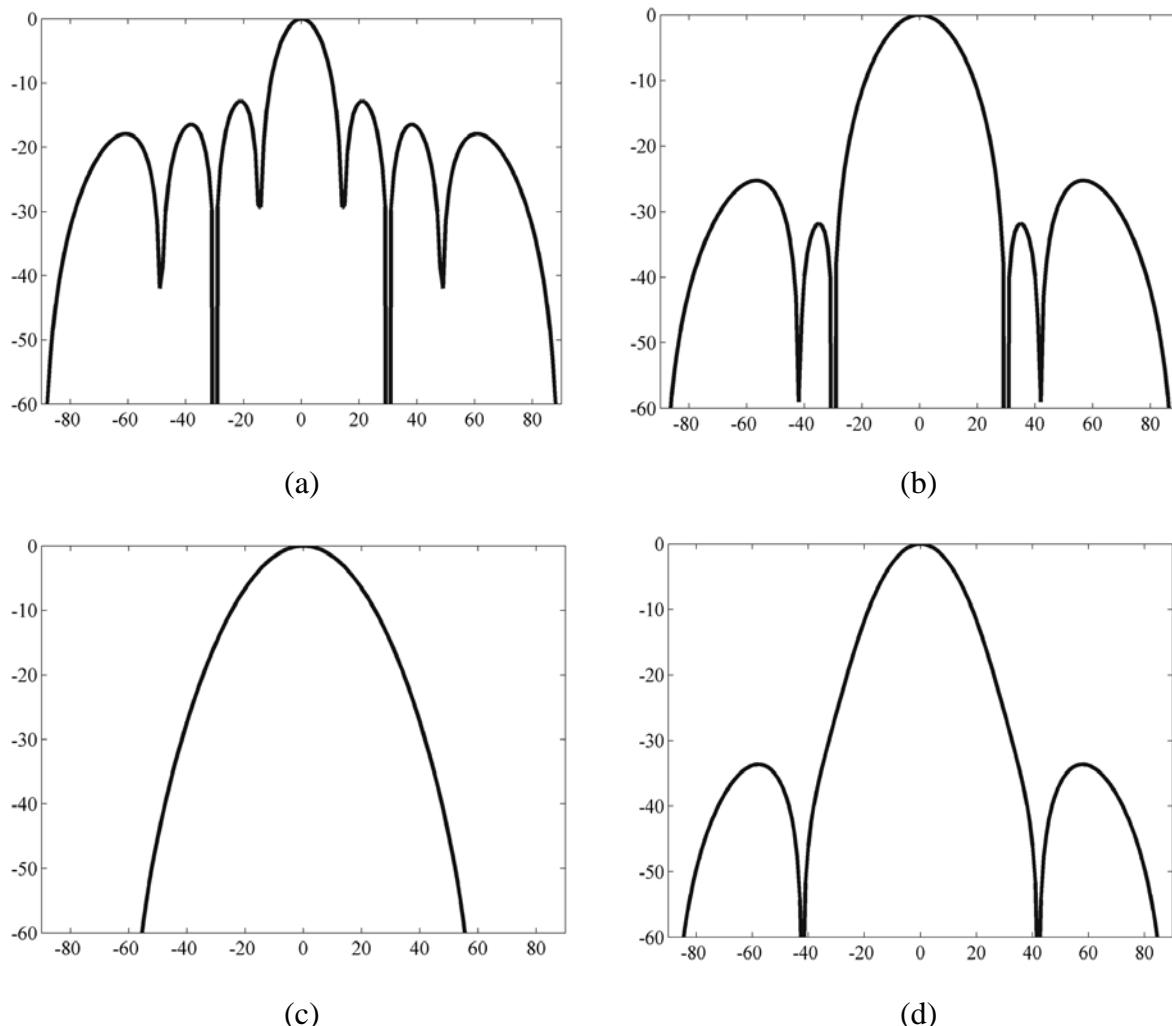
$$T_m(z) = \cos(m\cos^{-1}z), \quad -1 \leq z \leq +1 \quad (2.17)$$

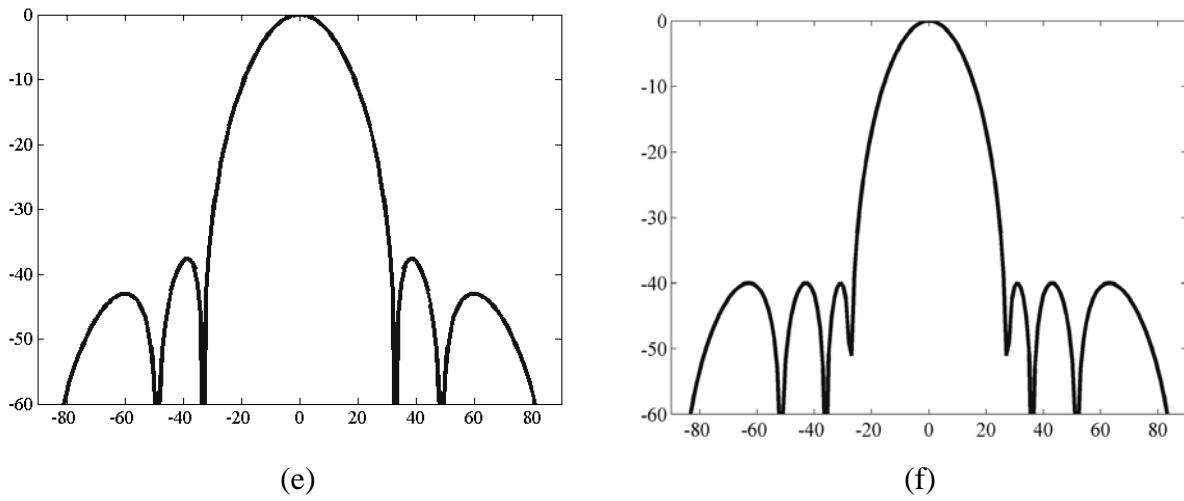
odnosno

$$T_m(z) = \cosh(m\cos^{-1}z). \quad |z| > +1 \quad (2.18)$$

Opseg $-1 \leq z \leq +1$ predstavlja oblast bočnih listova u karakteristici zračenja, dok $|z| > +1$ označava oblast glavnog lista zračenja. Na osnovu ovih polinoma, broja antenskih elemenata i zadatog nivoa bočnih listova zračenja, određuju se amplitudski težinski koeficijenti [2].

Na Slici 2.5 (a)-(f), prikazani su normalizovani faktori niza za šest prozorskih funkcija, pravougaonu, *Bartlettovu*, *Blackmanovu*, *Hammingovu*, *Kaiserovu* i *Dolph-Chebyshevlu* [2].





Slika 2.5 Faktor linearog niza od osam elemenata u zavisnosti od prozorske funkcije
(a) pravougaona, (b) Bartlettova, (c) Blackmanova, (d) Hammingova, (e) Kaiserova, (h)
Dolph-Chebyshevlujeva [2]

Kontrola položaja glavnog lista i nula u karakteristici zračenja antenskog niza

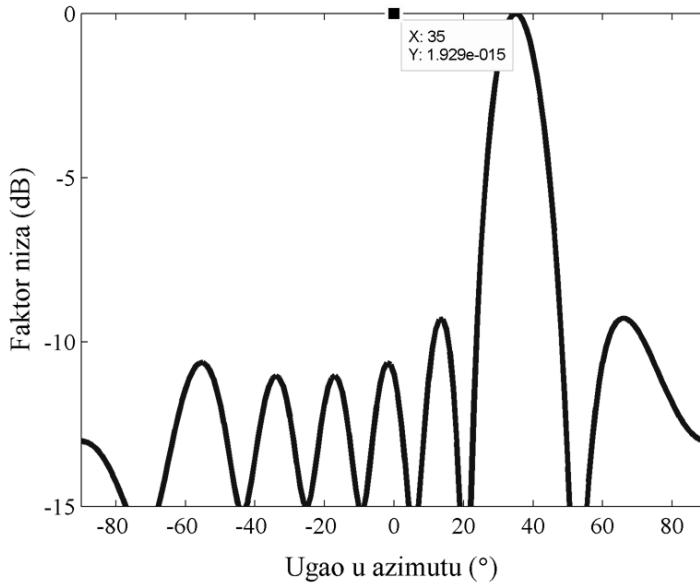
Položaj glavnog lista u karakteristici zračenja linearog antenskog niza se kontroliše primenom tzv. "faznog teđperovanja" elemenata niza. Fazne težine uskopojasnih antenskih nizova se podešavaju pomoću pomerača faze. Proračun faznih komponenti elemenata niza radi usmeravanja glavnog lista u određenom pravcu (θ, φ) , vrši se na sledeći način

$$\mathbf{w} = \frac{1}{N} \mathbf{S}_0, \quad (2.19)$$

gde je \mathbf{w} težinski vektor, N je broj antenskih elemenata i \mathbf{S}_0 je *steering* vektor. Prethodni izraz važi za usmeravanje glavnog lista u jednoj ravni. Na primer, ukoliko je potrebno usmeriti glavni list zračenja linearog antenskog niza od osam elemenata u pravcu $\theta=35^\circ$, težinski vektor na osnovu (2.19) ima sledeći oblik:

$$\mathbf{w} = \frac{1}{8} [1 e^{-j\pi \sin(35^\circ)} e^{-j2\pi \sin(35^\circ)} e^{-j3\pi \sin(35^\circ)} e^{-j4\pi \sin(35^\circ)} e^{-j5\pi \sin(35^\circ)} e^{-j6\pi \sin(35^\circ)} e^{-j7\pi \sin(35^\circ)}] \quad (2.20)$$

Odgovarajući dijagram zračenja dat je na Slici 2.6.



Slika 2.6 Usmeravanje glavnog lista zračenja u pravcu $\theta=35^\circ$

Nule u karakteristici zračenja se usmeravaju na sličan način kao i glavni list zračenja. Ovo podešavanje je posebno korisno kada je potrebno oslabiti interferentne signale koji pristižu iz pravaca koji se ne poklapaju sa pravcem glavnog lista zračenja [2]. Na ovaj način se uz manje proračune efikasno postiže bolji odnos signal/interferencija i značajno poboljšavaju performanse sistema.

Neka je \mathbf{S}_0 *steering* vektor glavnog lista zračenja i neka su $\mathbf{S}_1, \dots, \mathbf{S}_{M_0}$ *steering* vektori M_0 nula. U ovom slučaju, težinski vektori se mogu dobiti kao rešenja sledećeg sistema jednačina

$$\mathbf{w}^H \mathbf{S}_0 = 1 \quad (2.21)$$

$$\mathbf{w}^H \mathbf{S}_{M_0} = 0. \quad (2.22)$$

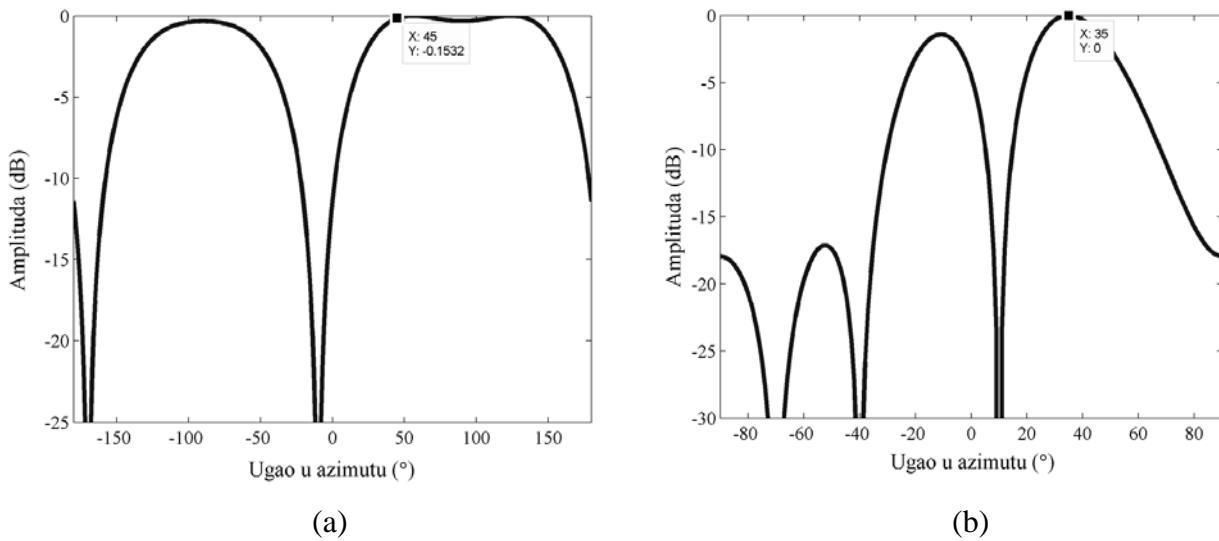
Neka je sa \mathbf{A} označena matrica čija M_0+1 kolona predstavlja *steering* vektore glavnog lista zračenja i nula. Za $M_0=N-1$, gde je N broj elemenata i \mathbf{A} kvadratna matrica, prethodni izrazi se mogu napisati u matričnom obliku:

$$\mathbf{W}^H \mathbf{A} = \mathbf{c}^T, \quad (2.23)$$

gde je $\mathbf{c}=[1 \ 0 \ \dots \ 0]^T$. Na osnovu izraza (2.23) lako se izračunava matrica težinskih koeficijenata \mathbf{W} . Da bi se obezbedilo postojanje matrice \mathbf{A} , potrebno je da svi *steering* vektori budu linearno nezavisni. Ukoliko ovo nije slučaj, umesto nje se može izračunati pseudoinverzna matrica. Za $M_0 < N-1$, matrica \mathbf{A} nije kvadratna pa se u tom slučaju težinski vektori izračunavaju pomoću sledećeg izraza:

$$\mathbf{W}^H = \mathbf{c}^T \mathbf{A}^H (\mathbf{A} \mathbf{A}^H)^{-1}. \quad (2.24)$$

Na Slici 2.7 (a) dat je dijagram zračenja 2-elementnog antenskog niza čiji je glavni list zračenja na $\theta_{\text{main}} = 45^\circ$, dok se nula zračenja javlja na $\theta_{\text{null1}} = -10^\circ$ [2]. Rastojanje između nule i glavnog lista je dovoljno veliko tako da nula ne utiče na oblik glavnog lista zračenja. Ukoliko se zahteva da nula bude bliža glavnom listu zračenja tada se mora napraviti kompromis, jer će u suprotnom doći do pogoršanja prijema željenog signala. Povećanjem broja antenskih elementa u nizu dobija se više prostora za manipulaciju nulama u karakteristici zračenja. Slika 2.7 (b) prikazuje dijagram zračenja 4-elementnog antenskog niza kod kojeg je glavni list usmeren na $\theta_{\text{main}} = 35^\circ$, dok se nule generišu na $\theta_{\text{null1}} = 10^\circ$, $\theta_{\text{null2}} = -40^\circ$ i $\theta_{\text{null3}} = -70^\circ$.

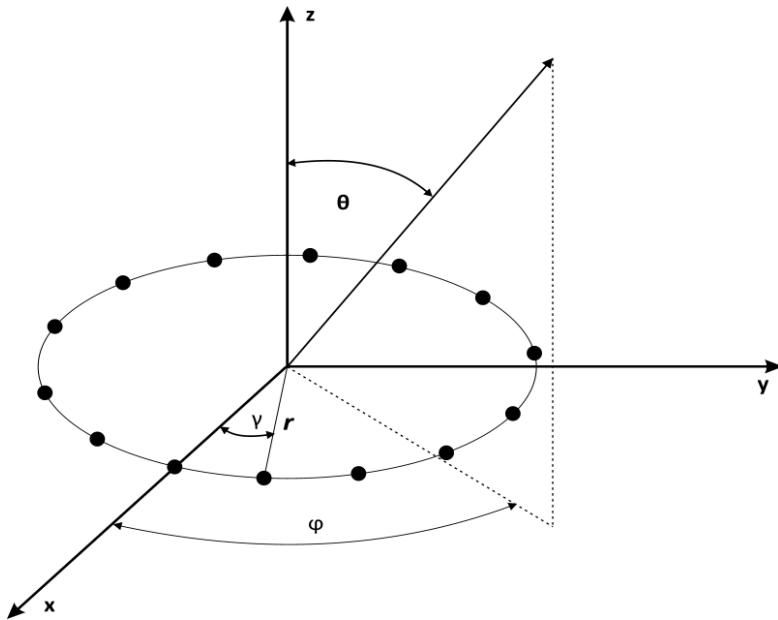


Slika 2.7 *Usmeravanje glavnog lista i nula u karakteristici zračenja antenskog niza od (a) dva elementa, (b) četiri elementa [2]*

Pored blizine nule i glavnog lista zračenja, drugi problem koji se javlja prilikom oblikovanja karakteristike zračenja je dubina nula. Kao što se može zaključiti na osnovu Slike 2.7, sa malom ugaonom promenom dolazi do značajne promene u slabljenju interferentnih signala. Iz navedenog razloga, pribegava se tehnikama za „proširenje nula”, kao što je npr. usmeravanje više nula prema istom interferentnom signalu ali sa malim ugaonim razmakom između njih. Nule se takođe mogu poboljšati i optimalnim praktičnim dizajnom sistema i primenom kalibracije.

2.3.2 Kružni antenski niz

Posmatraćemo kružni antenski niz sastavljen od N identičnih izotropnih antenskih elemenata. Elementi su ravnomerno raspoređeni na kružnici poluprečnika r u x-y ravni (Slika 2.8).



Slika 2.8 Uniformni kružni antenski niz

Faktor kružnog antenskog niza se može izraziti u sledećem obliku:

$$AF_{circular}(\varphi, \theta) = \sum_{n=0}^{N-1} I_n e^{j\left(\frac{2\pi}{\lambda} r \sin \theta \cos(\varphi - \gamma_n) + \delta_n\right)} \quad (2.25)$$

gde su I_n i δ_n amplituda i faza ekscitacije n -tog elementa antenskog niza, dok $\gamma_n = (2\pi n/N)$ predstavlja ugaonu poziciju n -tog elementa. Maksimum faktora niza se javlja kada su sve faze iz izraza (2.25) jednake, odnosno kada je ispunjen uslov

$$\frac{2\pi}{\lambda} r n \sin \theta \cos(\varphi - \gamma_n) + \delta_n = 2\pi a. \quad a = 0, \pm 1, \pm 2, \dots \quad (2.26)$$

Za $\delta_n = 0$ za sve antenske elemente, maksimum ($a = 0$) se javlja za $\theta = 0$. Ukoliko je raspodela amplituda uniformna, $I_n = 1$, za sve vrednosti n ($n = 0, 1, 2, \dots, N-1$), izraz (2.25) može biti pojednostavljen:

$$AF_{circular} \approx NJ_0\left(\frac{2\pi}{\lambda}rsin\theta\right), \quad (2.27)$$

gde je $J_0(\cdot)$ *Besselova* funkcija nultog reda [44]. Kružni antenski nizovi se primenjuju kod intelligentnih antenskih sistema gde obezbeđuju adaptivni beamforming, odnosno usmeravanje glavnog lista u karakteristici zračenja prema željenom korisniku i nule prema interferentnim signalima.

Kontrola karakteristike zračenja

Ekscitacija antenskih elemenata kružnog antenskog niza odgovarajućim vrednostima amplituda i faza u suštini predstavlja daleko kompleksniji problem nego kod linearnih antenskih nizova. Pored toga, elektronsko usmeravanje dijagrama zračenja može biti komplikovano za implementaciju ukoliko se zahteva promena amplitude i faze svakog pojedinačnog antenskog elementa.

Kofazna ekscitacija antenskih elemenata predstavlja najjednostavniji način za napajanje kružnog niza. Signali svih elemenata se sabiraju i formiraju glavni list zračenja u pravcu $\theta=0$. Ekscitacija se u zavisnosti od ugla φ izražava na sledeći način:

$$F(\varphi) = e^{-j\frac{2\pi}{\lambda}rcos\varphi}. \quad (2.28)$$

U slučaju kada je niz sastavljen od velikog broja izotropnih antenskih elemenata, normalizovani dijagram zračenja se može napisati na sledeći način:

$$E(\theta) = J_0\left(\frac{4\pi}{\lambda}rsin\frac{\theta}{2}\right). \quad (2.29)$$

U odnosu na linearni antenski niz čija je dužina jednaka prečniku kružnog niza, kružni antenski niz daje nešto uži glavni list zračenja i viši nivo bočnih listova zračenja. Nivo bočnih listova se može smanjiti primenom simetričnog tejerovanja amplituda elemenata na jednoj polovini niza i neznatnom (ili nultom) ekscitacijom preostalih elemenata. Elektronska kontrola pravca glavnog lista zračenja zahteva kontrolu ekscitacije amplitude i faze svakog antenskog elementa. Pored toga, ovakav kružni niz ne omogućava nezavisnu kontrolu horizontalnih i vertikalnih listova zračenja, za šta se zahtevaju koncentrični kružni nizovi. Takođe, tejerovanje amplituda koje se primenjuje za smanjenje bočnih listova zračenja u horizontalnoj ravni ima za posledicu povećanje širine glavnog lista zračenja u vertikalnoj ravni [45]-[46].

Za sintezu usmerenih dijagrama zračenja kružnih antenskih nizova posebno je značajan pristup zasnovan na primeni *Furierove* analize, kako na ekscitaciju elemenata niza tako i na odgovarajući dijagram zračenja u dalekoj zoni. Funkcija eksitacije svakog kružnog antenskog niza je periodična funkcija, sa periodom λ radijana. Samim tim, ovakva funkcija se može razviti u *Fourierov* red:

$$F(\varphi) = \sum_{m=-M}^M C_m e^{jm\varphi}, \quad (2.30)$$

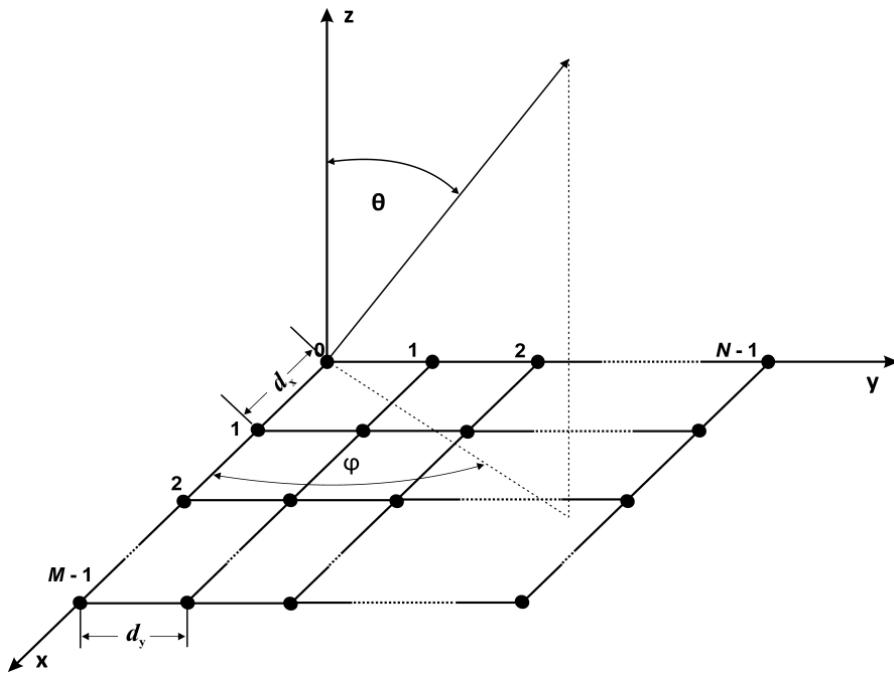
gde je C_m kompleksni *Fourierov* koeficijent m -toga prostornog harmonika. Izraz (2.30) predstavlja funkciju $F(\varphi)$ kao zbir $2M+1$ harmonika, a svaki harmonik označava fazni mod eksitacije elemenata niza. Fazni mod daje konstantne amplitudske težine dok se fazne težine menjaju linearne sa uglom na osnovu čega se može zaključiti da postoji ukupno m ciklusa promene faze od 0° do 360° . Usmereni dijagram zračenja koji proističe iz m -toga faznog moda je identičan funkciji (2.30), sa sličnom promenom faze i konstantnom amplitudom (datom *Besselovom* funkcijom):

$$E_m(\theta) = C_m j^m J_m \left(\frac{2\pi}{\lambda} r \right) e^{jm\theta}. \quad (2.31)$$

Na ovaj način, moguće je željenu karakteristiku zračenja razviti u *Fourierov* red i dobijene članove reda upotrebiti za eksitaciju elemenata antenskog niza. *Besselova* funkcija za određeni mod je direktno povezana sa jačinom signala u dalekoj zoni zračenja.

2.3.3 Pravougaoni antenski niz

Na Slici 2.9, ilustrovan je pravougaoni antenski niz sastavljen od $M \times N$ izotropnih antenskih elemenata. Svaki antenski element je određen svojim koordinatama (m, n) , gde je $m=0, 1, 2, \dots, M-1$ i $n=0, 1, 2, \dots, N-1$. Elementi su raspoređeni paralelno sa x i y-osi, na podjednakom međusobnom rastojanju od d_x i d_y , respektivno. Da bi se izbegla pojava prostornog aliasinga, rastojanje između elemenata u nizu jednako je polovini talasne dužine EM talasa, $d_x=d_y=\lambda/2$.



Slika 2.9 Pravougaoni antenski niz

Za pravougaoni antenski niz faktor niza se može napisati pomoću sledećeg izraza:

$$AF_{planar}(\varphi, \theta) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} I_{mn} e^{j\left(\frac{2\pi}{\lambda}d_x m \sin \theta \cos \varphi + \frac{2\pi}{\lambda}d_y n \sin \theta \sin \varphi + \delta_{mn}\right)}. \quad (2.32)$$

Za uniformnu raspodelu amplituda ($I_{mn}=1$) i jednake faze antenskih elemenata ($\delta_{mn}=0$), normalizovani faktor pravougaonog antenskog niza se definiše na sledeći način:

$$\begin{aligned} |AF_{norm_{planar}}(\varphi, \theta)| &= \left| \frac{\sin\left(\frac{M}{2}\frac{2\pi}{\lambda}d_x \sin \theta \cos \varphi\right)}{M \sin\left(\frac{\frac{2\pi}{\lambda}d_x \sin \theta \cos \varphi}{2}\right)} \cdot \frac{\sin\left(\frac{N}{2}\frac{2\pi}{\lambda}d_y n \sin \theta \sin \varphi\right)}{N \sin\left(\frac{\frac{2\pi}{\lambda}d_y n \sin \theta \sin \varphi}{2}\right)} \right| \\ &= S_M(\alpha)S_N(\beta), \end{aligned} \quad (2.33)$$

gde su koordinate α i β određene izrazima $\sin \alpha = \sin \theta \cdot \cos \varphi$ i $\sin \beta = \sin \theta \cdot \sin \varphi$, odnosno:

$$S_M(\alpha) = \left| \frac{\sin\left(\frac{M}{2}\frac{2\pi}{\lambda}d_x \sin \alpha\right)}{M \sin\left(\frac{\frac{2\pi}{\lambda}d_x \sin \alpha}{2}\right)} \right| \quad (2.34)$$

$$S_N(\beta) = \left| \frac{\sin\left(\frac{N2\pi}{2} \frac{d_y}{\lambda} \sin\beta\right)}{N \sin\left(\frac{\frac{2\pi}{\lambda} d_y \sin\beta}{2}\right)} \right| \quad (2.35)$$

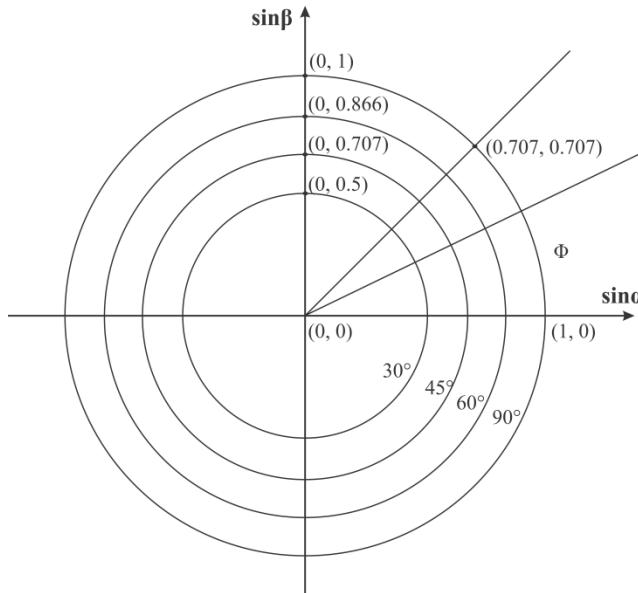
Oblast vidljivosti je određena sa:

$$\sqrt{\sin^2\alpha + \sin^2\beta} \leq 1, \quad (2.36)$$

odnosno, za $d_x=d_y=\lambda/2$ sledi da je:

$$\sqrt{\left(\frac{\pi \sin\alpha}{d_x}\right)^2 + \left(\frac{\pi \sin\beta}{d_y}\right)^2} \leq \frac{2\pi}{\lambda}. \quad (2.37)$$

Preslikavanje između prostora kosinusa direkcionih uglova ($\sin\alpha, \sin\beta$) i prostora uglova u azimutu i elevaciji (φ, θ) je jednoznačno. Na Slici 2.10, prikazan je specijalan slučaj za $d_x=d_y=\lambda/2$.

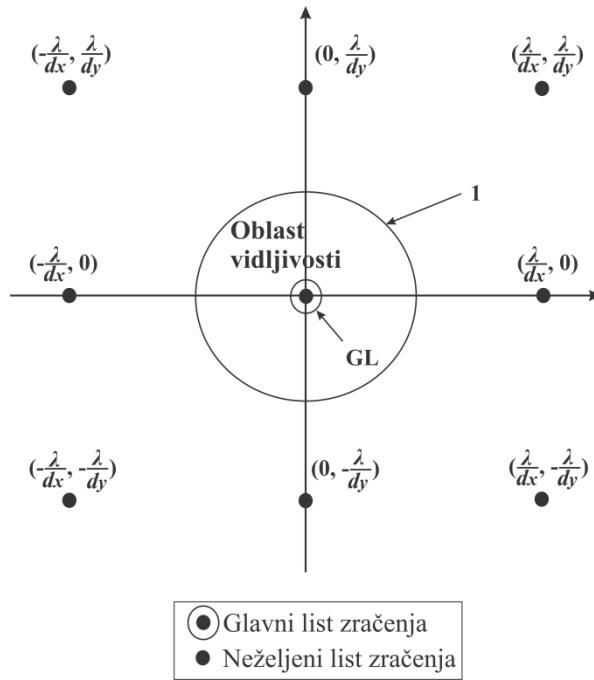


Slika 2.10 Preslikavanje između prostora (φ, θ) i prostora $(\sin\alpha, \sin\beta)$

Za razliku od linearnih antenskih nizova kod kojih je moguće usmeravanje glavnog lista zračenja samo u jednoj ravni, pravougaoni nizovi imaju mogućnost generisanja jako usmerenog lista zračenja (*pencil beam*) i njegovu kontrolu u azimutu i elevaciji. Na sličan način kao kod linearnih nizova, glavni list i neželjeni listovi zračenja (*grating lobes*) se mogu pronaći na osnovu izraza (2.4) i (2.5). Potrebno je da sledeći uslovi budu zadovoljeni:

$$\sin\alpha = \pm a_1 \frac{\lambda}{d_x}; \quad \sin\beta = \pm a_2 \frac{\lambda}{d_y}; \quad a_1 = 0, 1, 2, \dots; \quad a_2 = 0, 1, 2, \dots; \quad (2.38)$$

Glavni list zračenja odgovara prethodnom izrazu za $a_1=0$ i $a_2=0$. Kako bi se izbegli neželjeni listovi zračenja, rastojanja d_x i d_y između antenskih elemenata moraju biti manja od talasne dužine. Periodičnost maksimuma u karakteristici zračenja prikazana je u ($\sin\alpha, \sin\beta$) ravni na Slici 2.11.



Slika 2.11 *Maksimumi u karakteristici zračenja pravougaonog antenskog niza [39]*

Izrazi (2.34) i (2.35) prikazuju karakteristiku zračenja pravougaonog antenskog niza kao proizvod dva kombinovana ortogonalna linearne niza [44]. Ovi izrazi pokazuju da ugaona rezolucija pravouganog antenskog niza od N^2 antenskih elemenata može biti ekvivalentna rezoluciji niza sačinjenog od dva ortogonalna linearne niza sa ukupnim brojem elemenata $2N$.

Direktivnost pravougaonog niza, sastavljenog od većeg broja izotropnih elemenata, može se predstaviti jednostavnom aproksimacijom:

$$D_{planar} \approx \pi \cdot D_{linearx} \cdot D_{lineary} \quad (2.39)$$

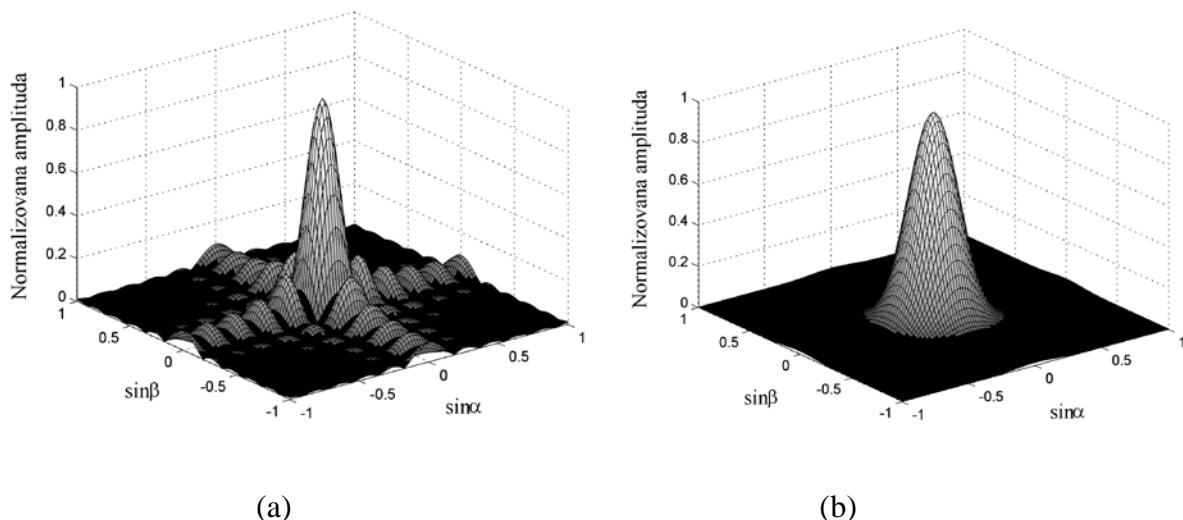
gde su $D_{linearx}$ i $D_{lineary}$ direktivnosti linearnih nizova duž x i y -ose, respektivno. Ukoliko je rastojanje između susednih antenskih elemenata u nizu jednako polovini talasne dužine, tada je direktivnost proporcionalna ukupnom broju elemenata u nizu odnosno, $D_{planar} \sim \pi \cdot M \cdot N$.

Kontrola nivoa bočnih listova zračenja

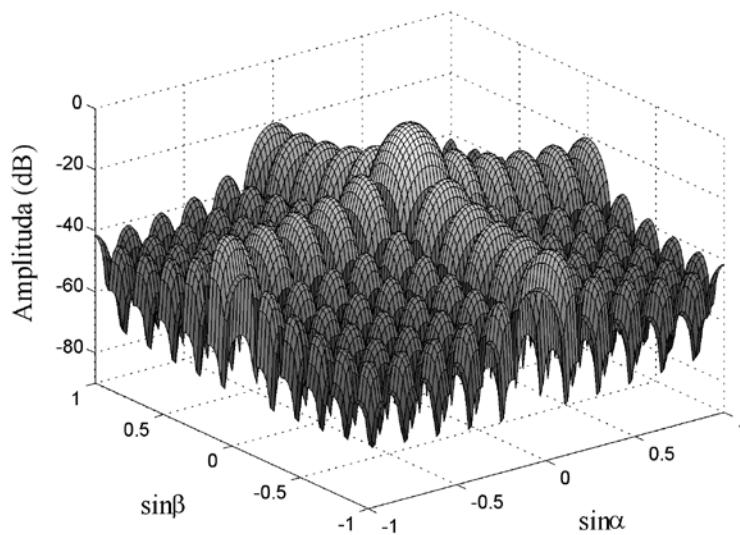
Karakteristika zračenja pravougaonog antenskog niza se može kontrolisati na sličan način kao kod linearnih antenskih nizova. Izrazi za prozorske funkcije se mogu modifikovati tako da budu primenljivi i na pravougaone antenske nizove. Direktan pristup određuje težinske koeficijente elemenata pravougaonog niza množenjem težinskih koeficijenata dva linearne niza postavljenih duž x i y-ose, odnosno,

$$w_{mn} \approx w_m \cdot w_n, \quad (2.40)$$

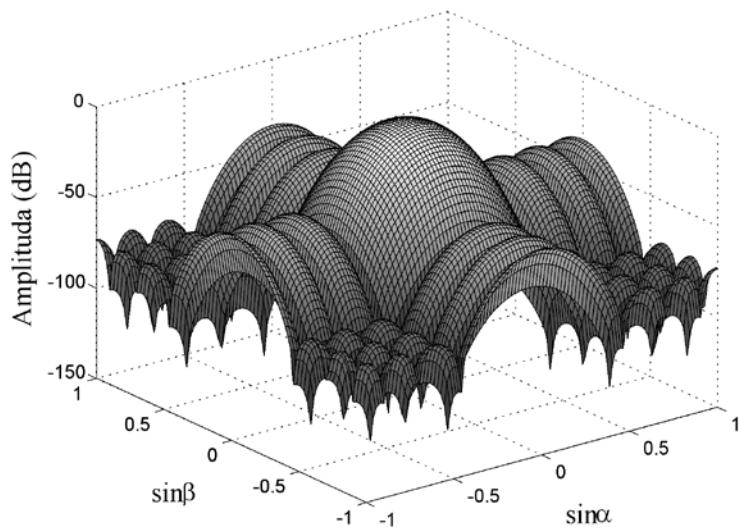
gde su w_m težinski koeficijenti duž x-ose ($m=0, 1, \dots, M-1$), dok su w_n težinski koeficijenti duž y-ose ($n=0, 1, \dots, N-1$). Karakteristika zračenja koja se dobija na ovaj način predstavlja proizvod dijagrama zračenja dva linearne antenske niza. Na primer, za *Hammingovu* prozorskiju funkciju, primenjenu na pravougani niz dimenzija $M=11$ i $N=11$, odgovarajuća karakteristika zračenja je prikazana na Slikama 2.12 i 2.13 napored sa standardnom karakteristikom, bez primenjene prozorske funkcije.



Slika 2.12 Karakteristika zračenja 11×11 pravougaonog antenskog niza u linearnoj skali
(a) bez primenjene prozorske funkcije, (b) sa Hammingovom prozorskom funkcijom



(a)



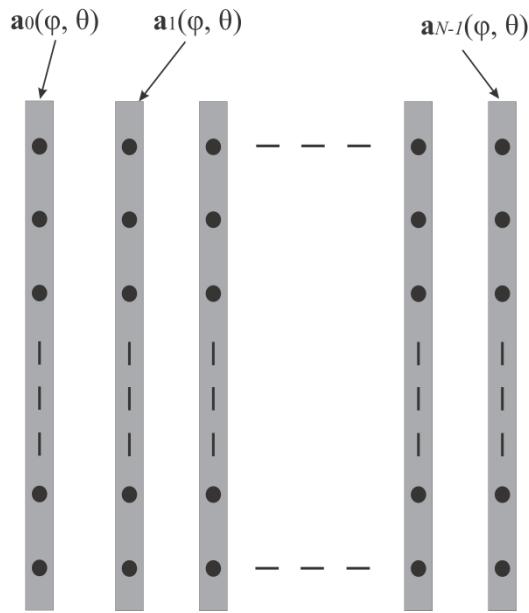
(b)

Slika 2.13 Karakteristika zračenja 11×11 pravougaonog antenskog niza u decibelskoj skali (a) bez primenjene prozorske funkcije, (b) sa Hammingovom prozorskom funkcijom

Druge metode za primenu prozorskih funkcija na pravougaone antenske nizove date su u [46]-[47].

Kontrola položaja glavnog lista i nula u karakteristici zračenja antenskog niza

Kontrola glavnog lista zračenja kod pravougaonog antenskog niza vrši se na sličan način kao kod linearnih antenskih nizova. Potrebno je $M \times N$ matricu koja definiše strukturu niza napisati u obliku $MN \times 1$ vektora.



Slika 2.14 Struktura pravougaonog antenskog niza

Na Slici 2.14, prikazana je struktura pravougaonog antenskog niza gde je:

$$\mathbf{a}_n(\varphi, \theta) = \begin{bmatrix} e^{j\left(\frac{2\pi}{\lambda}d_y n \sin \theta \sin \varphi + \delta_{0n}\right)} \\ e^{j\left(\frac{2\pi}{\lambda}d_x n \sin \theta \cos \varphi + \frac{2\pi}{\lambda}d_y n \sin \theta \sin \varphi + \delta_{1n}\right)} \\ \vdots \\ e^{j\left(\frac{2\pi}{\lambda}d_x(M-1) n \sin \theta \cos \varphi + \frac{2\pi}{\lambda}d_y n \sin \theta \sin \varphi + \delta_{(M-1)n}\right)} \end{bmatrix}. \quad n = 0, 1, \dots, N-1 \quad (2.41)$$

Matrica niza se može napisati u sledećem obliku:

$$\mathbf{A}(\varphi, \theta) = [\mathbf{a}_0(\varphi, \theta) \quad \mathbf{a}_1(\varphi, \theta) \quad \dots \quad \mathbf{a}_n(\varphi, \theta) \quad \dots \quad \mathbf{a}_{N-1}(\varphi, \theta)]_{M \times N}. \quad (2.42)$$

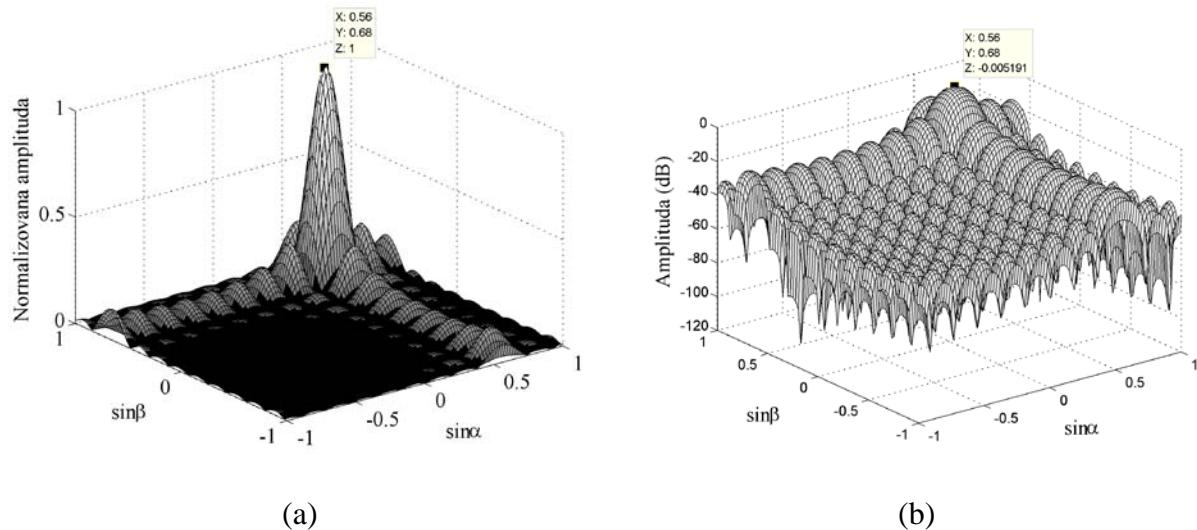
Kolone matrice $\mathbf{A}(\varphi, \theta)$ se dalje organizuju u jedinstven vektor na sledeći način:

$$\mathbf{a}(\varphi, \theta) = \begin{bmatrix} \mathbf{a}_0(\varphi, \theta) \\ \mathbf{a}_1(\varphi, \theta) \\ \vdots \\ \mathbf{a}_{N-1}(\varphi, \theta) \end{bmatrix}_{MN \times 1} \quad (2.43)$$

Uslov za usmeravanje glavnog lista zračenja definiše se na isti način kao kod linearnih antenskih nizova:

$$\mathbf{w}^H \mathbf{c}_1 = 1, \quad (2.44)$$

gde je sa \mathbf{c}_1 označen *steering* vektor glavnog lista zračenja, Slika 2.15.



Slika 2.15 *Usmeravanje glavnog lista zračenja antenskog niza u prostoru ($\sin\alpha, \sin\beta$) za $\varphi_1=40^\circ$ i $\theta_1=60^\circ$, (a) u linearnoj skali, (b) u dB skali*

Postoji više metoda za kontrolu nula kod pravougaonog antenskog niza [46]. Matrica koja definiše nule u karakteristici zračenja data je sledećim izrazom:

$$\mathbf{C}_0 = [\mathbf{a}(\varphi_1, \theta_1) \ \mathbf{a}(\varphi_2, \theta_2) \ \dots \ \mathbf{a}(\varphi_{m_0}, \theta_{m_0}) \ \dots \ \mathbf{a}(\varphi_{M_0}, \theta_{M_0})]_{MN \times M_0}, \quad (2.45)$$

gde je M_0 broj nula koje je potrebno generisati. Uslov za generisanje nula u željenim pravcima definiše se na sledeći način:

$$\mathbf{w}^H \mathbf{C}_0 = 0. \quad (2.46)$$

Prepostavićemo da je željeni vektor težina dat vektorom \mathbf{w}_d , dimenzija $MN \times 1$. Procedura optimizacije za ostvarivanje željene karakteristike zračenja odnosi se na smanjenje srednje kvadratne greške između željenih i trenutnih težina antenskih elemenata, odnosno:

$$\varepsilon = \|\mathbf{w}_d - \mathbf{w}\|^2. \quad (2.47)$$

Rešenje ovog metoda nisu željeni već optimalni težinski koeficijenti \mathbf{w}_o dati sa:

$$\mathbf{w}_0^H = \mathbf{w}_d^H - [\mathbf{w}_d^H \mathbf{C}_0 [\mathbf{C}_0^H \mathbf{C}_0]^{-1} \mathbf{C}_0^H]. \quad (2.48)$$

U praksi se primenjuju i drugi metodi za generisanje nula kao što su genetički algoritam, *Particle Swarm Optimization* (PSO), Taguchiev metod i drugi [48]-[51].

2.4 Modeli signala

U daljem tekstu biće razmotreni modeli primljenih signala na antenskim nizovima standardnih geometrija. Prepostavka je da svaki antenski niz prima signale koji potiču od K uskopojasnih EM izvora.

Linearni antenski niz

Razmotrićemo uniformni linearni antenski niz sastavljen od N ($n = 0, 1, 2, \dots, N-1$) elemenata (Slika 2.3). Elementi su ravnomerno raspoređeni na rastojanju d i primaju signale koji potiču od K izvora, $k = 1, 2, \dots, K$. Kako bi se izbegla pojava prostornog aliasinga, rastojanje d između antenskih elemenata je izabранo tako da bude jednako polovini talasne dužine incidentnih talasa. Samim tim, može se pretpostaviti da su signali primljeni na različitim antenskim elementima korelisani [3]. Incidentni talas prenosi signal $s(t)$. Svaki antenski element prima ovaj signal u različitom vremenskom trenutku. Ukoliko se element sa oznakom $n=0$ odabere za referentni tada će faza signala $s(t)$, primljenog na različitim elementima niza biti proračunata u odnosu na ovaj element.

Da bi se odredila fazna razlika neophodno je izmeriti vremensku razliku između trenutaka kada signal $s(t)$ stigne do referentnog elementa i n -tog elementa, $n=0, 1, \dots, N-1$. Vremenska razlika (TOA, *Time Delay of Arrival*) može se odrediti na osnovu izraza:

$$\Delta t_n = \frac{nd\sin\theta}{c}, \quad (2.49)$$

gde je c brzina svetlosti, dok θ označava pravac iz kog dolazi signal $s(t)$. Dalje, ukoliko pretpostavimo da je $s(t)$ uskopojasni digitalno modulisani signal sa niskopropusnom komponentom $s_l(t)$, nosiocem f_c , i periodom simbola T , $s(t)$ se može predstaviti u sledećem obliku:

$$s(t) = \operatorname{Re}\{s_l(t)e^{j2\pi f_c t}\}. \quad (2.50)$$

Signal primljen na n -tom elementu se može definisati na sledeći način:

$$x_n(t) = \operatorname{Re}\{s_l(t - \Delta t_n)e^{j2\pi f_c(t - \Delta t_n)}\}. \quad (2.51)$$

Na prijemu se signal konvertuje na nižu frekvenciju i uzorkuje (sa periodom T), odnosno

$$x_n(iT) = s_l(iT - \Delta t_n)e^{-j2\pi f_c \Delta t_n}, \quad (2.52)$$

gde je $T \gg \Delta t_n$, $n=0, 1, \dots, N-1$. Dalje, primenom aproksimacije $iT - \Delta t_n \approx iT$ i zamenom Δt_n iz jednačine (2.49), dobija se sledeći izraz:

$$x_n(iT) \approx s_l(iT - \Delta t_n)e^{-j\pi n \sin \theta}. \quad (2.53)$$

Prethodni izraz se može napisati i u sledećem obliku:

$$x_n[i] \approx s_l[n]e^{-j\pi n \sin \theta} = s_l[n]a_n(\theta). \quad (2.54)$$

Konačno, uzorkovani signal na n -tom elementu, koji potiče od ukupno K izvora, dat je sa:

$$x_n[i] \approx \sum_{k=1}^K s_k[i]a(\theta_k). \quad (2.55)$$

Uzimajući u obzir sve antenske elemente ($n = 0, 1, \dots, N-1$), primljeni signali se mogu predstaviti u matričnom obliku:

$$\begin{bmatrix} x_0[i] \\ x_1[i] \\ \vdots \\ x_{N-1}[i] \end{bmatrix} = \begin{bmatrix} a_0(\theta_1) & a_0(\theta_2) & \dots & a_0(\theta_K) \\ a_1(\theta_1) & a_1(\theta_2) & \dots & a_1(\theta_K) \\ \vdots & \vdots & \ddots & \vdots \\ a_{N-1}(\theta_1) & a_{N-1}(\theta_2) & \dots & a_{N-1}(\theta_K) \end{bmatrix} \begin{bmatrix} s_0[i] \\ s_1[i] \\ \vdots \\ s_{N-1}[i] \end{bmatrix} + \begin{bmatrix} n_0[i] \\ n_1[i] \\ \vdots \\ n_K[i] \end{bmatrix}, \quad (2.56)$$

odnosno

$$\mathbf{x}_n = \mathbf{A}\mathbf{s}_n + \mathbf{n}_n, \quad (2.57)$$

gde je \mathbf{x}_n , $N \times 1$ vektor primljenih signala, \mathbf{A} je $N \times K$ steering matrica, \mathbf{s}_n je $K \times 1$ vektor signala dok je \mathbf{n}_n $N \times 1$ vektor šuma.

Kružni antenski niz

Razmatraćemo uniformni kružni antenski niz, sačinjen od N izotropnih antenskih elemenata. Poluprečnik niza je označen sa r (Slika 2.4), a rastojanje između susednih antenskih elemenata sa d ($d=\lambda/2$, gde je λ talasna dužina incidentnih EM talasa). Ugaona pozicija n -tog elementa u nizu data je sa $\gamma_n=2\pi n/N$, $n = 0, 1, 2, \dots, N-1$. Pravac iz kog dolazi signal k -tog izvora određen je uglovima u azimutu i elevaciji φ_k i θ_k , respektivno. *Steering* vektor prema k -tom izvoru $\mathbf{a}_k(\varphi_k, \theta_k)$, $k=1, 2, \dots, K$, definiše se na sledeći način:

$$\mathbf{a}_k(\varphi_k, \theta_k) = \left[e^{j\left(\frac{2\pi}{\lambda}\right)r\sin\theta_k\cos\varphi_k - j\gamma_0} \ e^{j\left(\frac{2\pi}{\lambda}\right)r\sin\theta_k\cos\varphi_k - j\gamma_1} \ \dots \ e^{j\left(\frac{2\pi}{\lambda}\right)r\sin\theta_k\cos\varphi_k - j\gamma_{N-1}} \right] \quad (2.58)$$

Dalje, *steering* matrica \mathbf{A} dimenzija $N \times K$ se može definisati na sledeći način

$$\mathbf{A}(\varphi, \theta) = [\mathbf{a}(\varphi_1, \theta) \ \mathbf{a}(\varphi_2, \theta) \ \mathbf{a}(\varphi_3, \theta) \ \dots \ \mathbf{a}(\varphi_K, \theta)]. \quad (2.59)$$

Podrazumevajući novu strukturu *steering* matrice prikazane u (2.59), izraz (2.57) se može primeniti kao signal model za kružni antenski niz. U ovom slučaju, \mathbf{x}_n je $N \times 1$ vektor primljenih signala, \mathbf{A} je $N \times K$ *steering* matrica, \mathbf{s}_n je $K \times 1$ vektor signala i \mathbf{n}_n je $N \times 1$ vektor šuma.

Pravougani antenski niz

Na Slici 2.5, prikazan je pravougaoni antenski niz koji se sastoji od $M \times N$ izotropnih elemenata. Svaki antenski element je određen svojim koordinatama (m, n) , gde je $m = 0, 1, \dots, M-1$ i $n = 0, 1, \dots, N-1$. Elementi niza su raspoređeni paralelno sa x i y -osom, sa konstantnim rastojanjem između susednih elemenata od d_x and d_y , respektivno. Da bi se izbegla pojava prostornog alijasinga, rastojanje između antenskih elemenata jednako je polovini talasne dužine incidentnih talasa, $d_x=d_y=\lambda/2$.

Ukoliko je referentni element za proračun faze lociran na $(m=0, n=0)$, faza k -tog incidentnog talasa na elementu sa koordinatama (m, n) može se odrediti na osnovu izraza:

$$\Phi_{m,n}^{(k)}(\varphi_k, \theta_k) = \frac{2\pi}{\lambda} (d_x m \sin \theta_k \cos \varphi_k + d_y n \sin \theta_k \sin \varphi_k). \quad (2.60)$$

Steering vector k -tog incidentnog talasa može se odrediti u funkciji faze na sledeći način:

$$\mathbf{a}_{m,n}^{(k)}(\varphi_k, \theta_k) = e^{j\Phi_{m,n}^{(k)}(\varphi_k, \theta_k)}, \quad (2.61)$$

gde je $m = 0, 1, \dots, M-1$, $n = 0, 1, \dots, N-1$ i $k = 1, 2, \dots, K$. $\mathbf{A}(\varphi, \theta)$ je *steering* matrica čije kolone predstavljaju *steering* vektore K različitih pravaca iz kojih dolaze signali, odnosno:

$$\mathbf{A}(\varphi, \theta) = [\mathbf{a}(\varphi_1, \theta_1) \ \mathbf{a}(\varphi_2, \theta_2) \ \mathbf{a}(\varphi_3, \theta_3) \ \dots \ \mathbf{a}(\varphi_K, \theta_K)]. \quad (2.62)$$

Na kraju, primljeni signali neophodni za procenu prostorne kovarijanske matrice mogu se napisati u obliku jednačine (2.57), gde je \mathbf{x}_n , $MN \times 1$ vektor primljenih signala, \mathbf{A} je $MN \times K$ *steering* matrica, \mathbf{s}_n je $K \times 1$ vektor signala, i \mathbf{n}_n je $MN \times 1$ vektor šuma.

3 Veštačke neuronske mreže

Razvoj veštačkih neuronskih mreža je inspirisan radom biološkog nervnog sistema. Naime, iako su biološki neuroni veoma spori u poređenju sa elektronskim kolima (10^{-3} s u poređenju sa 10^{-9} s), ljudski mozak obavlja mnoge zadatke znatno efikasnije od konvencionalnih računara. Iz tog razloga, uložen je napor ka stvaranju veštačkih struktura koje će oponašati obradu informacija u ljudskom mozgu. Iako veštačke neuronske mreže po svojoj složenosti još uvek daleko zaostaju za biološkim, one su uprkos tome poslužile za rešavanje brojnih problema kod kojih su se standardni metodi pokazali neuspešnim. Neki od zadataka koje neuronske mreže uspešno rešavaju su prepoznavanje govora, slika i oblika, aproksimacija funkcija, klasifikacija, pretraživanje velikih baza podataka (*data mining*) i drugi.

Veštačka neuronska mreža predstavlja masivan paralelan sistem za obradu podataka. Sačinjena je od velikog broja međusobno povezanih procesnih jedinica, sličnih biološkim neuronima. Sličnost između veštačkih i bioloških neuronskih mreža se ogleda u mogućnosti da stiču znanje iz svog okruženja kroz proces učenja. Za čuvanje stečenog znanja se koriste sinaptičke težine veza između procesnih jedinica. Pod procesom učenja neuronske mreže podrazumeva se pronalaženje vrednosti sinaptičkih težina kako bi mreža bila u stanju da obavlja neki unapred definisan zadatak. Pored podešavanja veza, u procesu učenja je moguće menjati i topologiju mreže dodavanjem novih procesnih jedinica, tzv. neurona.

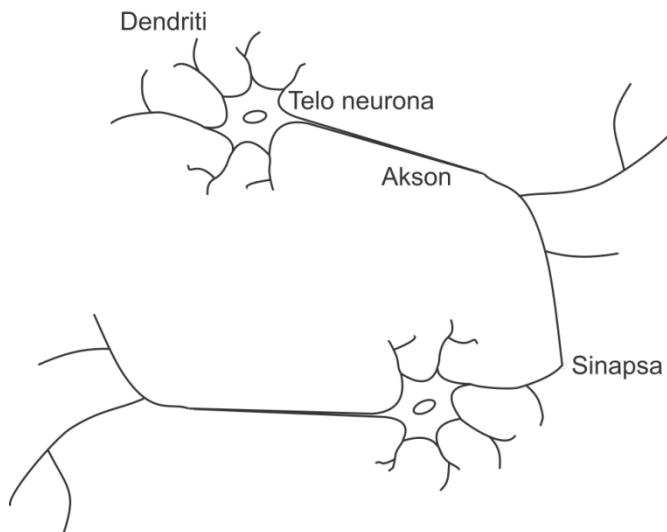
Neuronske mreže se mogu softverski simulirati na računaru ili implementirati pomoću elektronskih komponenti. Njihova paralelna struktura ih čini idealnim za implementaciju pomoću VLSI (*Very Large Scale Integration*) tehnologije, optičkih uređaja i paralelnih procesorskih sistema, [52]–[53].

3.1 Biološki nervni sistem

Biološki nervni sistem čini veliki broj međusobno povezanih neurona. Svaki neuron se sastoji od dendrita, tela neurona i aksona, Slika 3.1. Dendriti su razgranati produžeci na telu neurona koji prihvataju i prenose električne signale do tela neurona. Telo neurona prima sve pristigle signale i obrađuje ih. Ukoliko je signal koji se ovom prilikom dobija veći od praga osetljivosti neurona, tada će se on preko aksona preneti do drugih neurona.

Najveći broj neurona daje svoje izlaze u vidu niza kratkih impulsa. Impulse ili tzv. akcione potencijale generiše telo neurona odakle se oni dalje prostiru prema ostalim neuronima konstantnom brzinom i amplitudom. Razlog za upotrebu akcionih potencijala u komunikaciji između neurona baziran je na fizičkim karakteristikama aksona, s obzirom da je akson dugačak i tanak i da ga karakterišu velika električna otpornost i kapacitivnost.

Veza između aksona jednog neurona i dendrita drugog naziva se sinapsom. Sinapse imaju različitu efikasnost koja je podložna promenama tokom životnog ciklusa neurona. Ukoliko je sinapsa ekscitatorna tada dolazi do pojačanja signala, u suprotnom inhibitorna sinapsa smanjuje signal koji prenosi. Povezanost neurona i jačina svake sinapse je određena složenim hemijskim procesima.



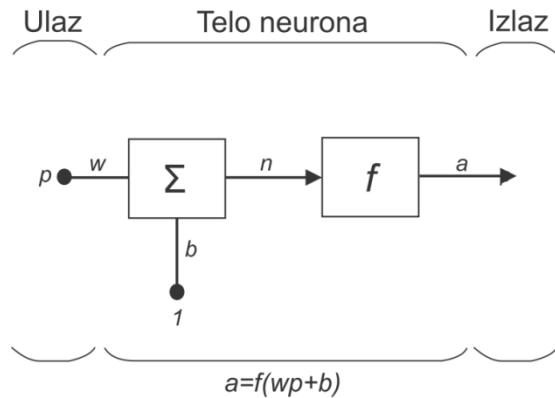
Slika 3.1 Prikaz bioloških neurona

Neke neuronske strukture su definisane pri samom rođenju dok se druge postepeno razvijaju u procesu učenja, pri čemu se stvaraju nove veze između neurona i razgrađuju stare. Ovakav razvoj je karakterističan za prve godine života jedinke. Biološke neuronske mreže se menjaju tokom života pri čemu se promene uglavnom odnose na jačanje i slabljenje veza između neurona.

3.2 Neuroni i aktivacione funkcije

Matematički model neurona sa jednim ulazom je prikazan na Slici 3.2. Skalarni ulaz p se množi skalarnom težinom w i dobijeni proizvod šalje do sabirača. Drugi ulaz sabirača je

jedinica koja se množi biasom b . Izlaz sabirača, n , argument je aktivacione funkcije f koja se često naziva i prenosnom funkcijom. Izlaz neurona je skalar označen sa a . Ukoliko se jednostavan model neurona sa Slike 3.2 uporedi sa biološkim neuronom može se zaključiti da težina w odgovara jačini sinapse, bias b određuje aktivacioni prag neurona, telo neurona je prikazano sabiračem i aktivacionom funkcijom, dok izlaz neurona a predstavlja signal aksona.



Slika 3.2 Matematički model neurona sa jednim ulazom [52]

Izlaz neurona se jednostavno izračunava pomoću izraza:

$$a = f(n) = f(wp + b), \quad (3.1)$$

gde bias b ima ulogu težinskog koeficijenta, sa izuzetkom što uvek ima konstantne ulaze jednake 1, dok u nekim slučajevima može biti i izostavljen. Skalarni parametri w i b se podešavaju u toku procesa učenja kako bi odnos između ulaza i izlaza zadovoljio unapred definisane kriterijume.

Ukoliko je ulaz u neuron vektor \mathbf{p} dimenzija $N \times 1$, $\mathbf{p} = [p_1 \ p_2 \ \dots \ p_N]^T$, tada izraz (3.1) dobija sledeći oblik:

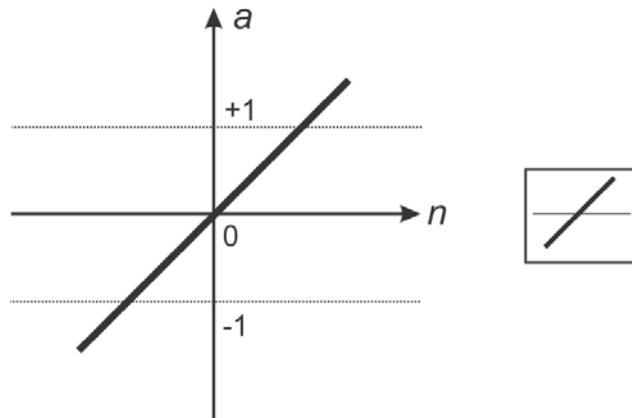
$$\mathbf{a} = f(\sum_{i=1}^N p_i w_i + \mathbf{b}). \quad (3.2)$$

Na osnovu prethodnih izraza može se zaključiti da izlaz neurona direktno zavisi od primenjene aktivacione (ili prenosne) funkcije $f(\cdot)$. Postoji nekoliko tipova funkcija koje se mogu primeniti u modelu neurona sa Slike 3.2. U tekstu koji sledi biće opisana tri osnovna tipa aktivacione funkcije: linearna, odskočna i sigmoidna [52]-[53].

Linearna aktivaciona funkcija je data sledećim izrazom:

$$f(n) = n. \quad (3.3)$$

Ova funkcija prosleđuje ulaz neurona direktno na izlaz, bez ikakvih promena (Slika 3.3).



Slika 3.3 Linearna aktivaciona funkcija

Odskočna aktivaciona funkcija je opisana sledećim izrazom:

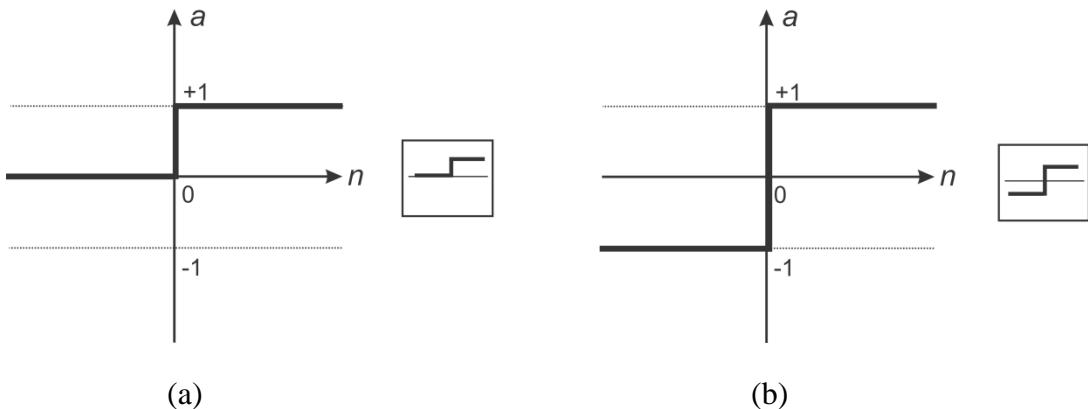
$$f(n) = \begin{cases} 0, & n < 0 \\ 1, & n \geq 0 \end{cases} \quad (3.4)$$

i daje 0 na izlazu neurona ukoliko je argument funkcije manji od 0, odnosno 1 ako je argument funkcije veći od 0, Slika 3.4 (a).

Često je u upotrebi i drugi oblik ove funkcije dat izrazom:

$$f(n) = \begin{cases} -1, & n < 0 \\ 1, & n \geq 0 \end{cases} \quad (3.5)$$

Ova funkcija daje -1 na izlazu neurona za argument aktivacione funkcije manji od 0, odnosno 1 za argument veći od 0, Slika 3.4 (b).



Slika 3.4 Odskočna aktivaciona funkcija

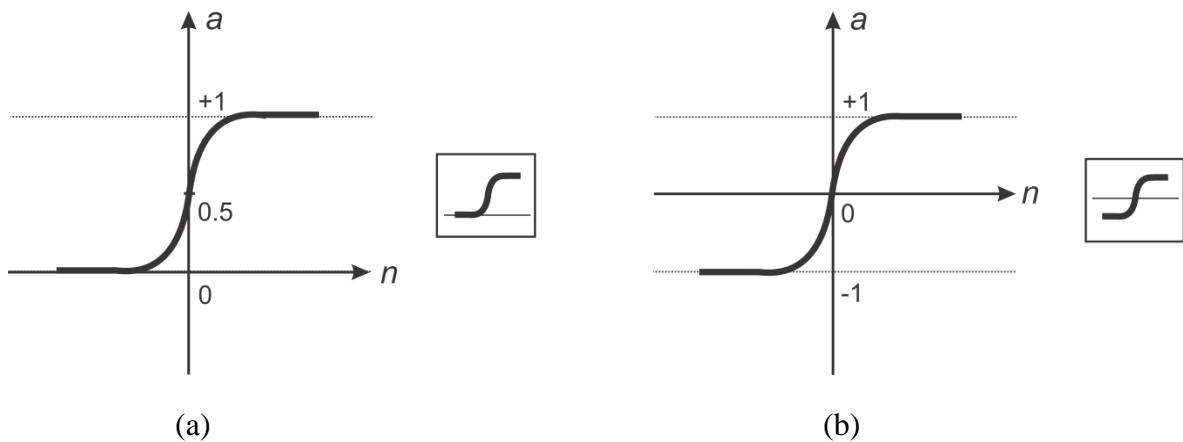
Kod sigmoidnih aktivacionih funkcija razlikujemo log-sigmoidnu:

$$a = \frac{1}{1+e^{-n}}, \quad (3.6)$$

i tan-sigmoidnu funkciju:

$$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}. \quad (3.7)$$

Log-sigmoidna funkcija preslikava sve ulaze iz opsega $(-\infty, +\infty)$ u opseg $[0, 1]$, Slika 3.5 (a). Tan-sigmoidna funkcija vrši preslikavanje svih ulaza u opseg $[-1, 1]$, Slika 3.5 (b).



Slika 3.5 Sigmoidne aktivacione funkcije (a) log-sigmoidna, (b) tan-sigmoidna

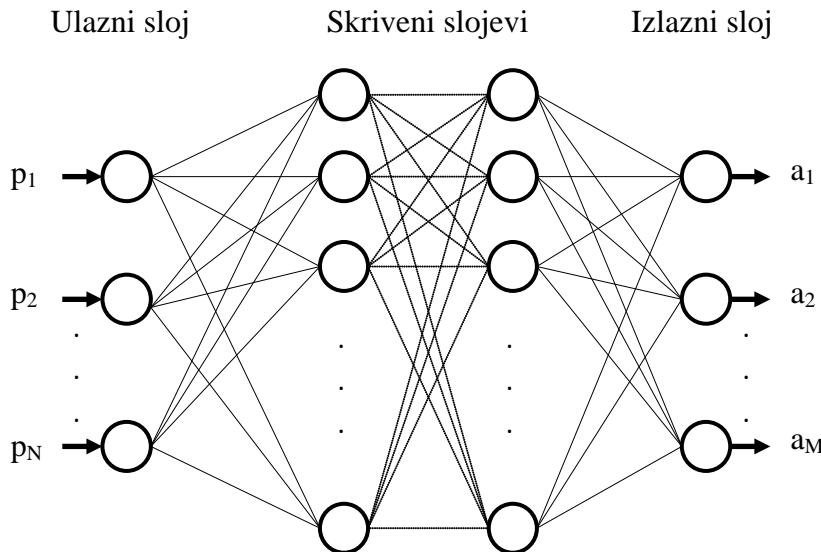
Sigmoidne aktivacione funkcije su karakteristične za neurone u skrivenim slojevima višeslojnih neuronskih mreža.

3.3 Višeslojna neuronska mreža – MLP

Neuronska mreža predstavlja skup međusobno povezanih neurona. Kod višeslojne neuronske mreže MLP (*Multi-Layer Perceptron*), neuroni su organizovani u nekoliko slojeva. Svaki neuron u jednom sloju mreže, povezan je sa svim neuronima iz narednog sloja, dok veze između neurona koji pripadaju istom sloju nisu dozvoljene. Iz tog razloga, MLP mreže pripadaju *feedforward* strukturama, odnosno, strukturama sa prostiranjem signala unapred.

MLP mreža se sastoji od ulaznog, izlaznog i jednog, ili više, skrivenih slojeva. Ulazni sloj mreže sadrži neurone sa linearnom prenosnom funkcijom i služi za prihvatanje podataka iz okruženja. Broj neurona u ovom sloju jednak je broju ulaza. Neuroni u skrivenim

slojevima, okarakterisani nelinearnim prenosnim funkcijama, obavljaju svu obradu podataka u mreži. Njihov optimalan broj nije unapred poznat i određuje se u procesu obuke mreže. Izlazni sloj mreže ima zadatok da dobijene rezultate prosledi okruženju. Neuroni u ovom sloju obično imaju linearne prenosne funkcije i njihov broj je jednak broju izlaza neuronske mreže.



Slika 3.6 Višeslojna neuronska mreža, MLP

Ukoliko je sa \mathbf{W}^l označena matrica težinskih koeficijenata l -tog sloja u mreži, a sa \mathbf{b}^l vektor biasa, tada se izlaz l -tog sloja može napisati u sledećem obliku:

$$\mathbf{a}^l = f^l(\mathbf{W}^l \mathbf{a}^{l-1} + \mathbf{b}^l), \quad (3.8)$$

gde su \mathbf{a}^l i \mathbf{a}^{l-1} izlazi l -tog i $l-1$ -og sloja neuronske mreže, respektivno, dok je f^l aktivaciona funkcija neurona l -tog sloja. Prilikom obuke neuronske mreže vrši se podešavanje matrica težina i vektora biasa kako bi mreža dala što tačnije rezultate [53].

3.3.1 Pravila učenja MLP neuronskih mreža

Najznačajnija karakteristika neuronskih mreža je njihova sposobnost da uče na osnovu prikazanih primera. Pod pravilom učenja neuronske mreže podrazumeva se procedura za modifikovanje parametara mreže, težina i biasa. Pravilo učenja se često naziva i algoritmom za obuku mreže. Krajnji cilj učenja je formiranje neuronske mreže koja će uspešno obavljati određeni zadatak.

Pravila učenja se mogu svrstati u sledeće tri kategorije:

- nadgledano učenje (*supervised learning*)
- nенадгледано учење (*unsupervised learning*)
- постепено учење (*reinforcement learning*)

Kod nadgledanog učenja, na raspolaganju je skup za obuku koji opisuje ponašanje mreže:

$$\{\mathbf{p}(1), \mathbf{t}(1)\}, \{\mathbf{p}(2), \mathbf{t}(2)\}, \dots, \{\mathbf{p}(q), \mathbf{t}(q)\}, \dots, \{\mathbf{p}(Q), \mathbf{t}(Q)\}, \quad (3.9)$$

gde je $\mathbf{p}(q)$ ulaz u mrežu dok je $\mathbf{t}(q)$ odgovarajući željeni izlaz, $q=1, 2, \dots, Q$. Kada se mreži prikažu svi ulazi, dobijeni izlazi mreže se porede sa željenim izlazima. Pravilo učenja se zatim primenjuje kako bi se, podešavanjem parametara mreže, njen odziv što više približio korektnim vrednostima.

Kod nенадгледаног учења, parametri mreže se podešavaju samo na osnovu ulaza u mrežu. U ovom slučaju, željeni izlazi nisu dostupni. Najveći broj algoritama za nенадгледано учење vrši podelu ulaznih vektora u konačan broj skupova (klastera). Uobičajena primena ovog učenja je u oblasti vektorske kvantizacije.

Postepeno učenje je slično nadgledanom učenju, s tim što ovo pravilo ne raspolaže korektnom vrednošću izlaza za svaki ulaz mreže, već samo „stepenom učenja“ koji predstavlja ocenu performansi mreže na određenoj sekvenci ulaza. Ovaj tip učenja neuronskih mreža je najpogodniji za primenu u oblasti kontrolnih sistema.

Nadgledano učenje MLP mreža

Nadgledani algoritmi za obuku mreža podrazumevaju postojanje skupa za obuku u vidu parova ulazno-izlaznih vektora. U procesu obuke, mreži se u nekoliko iteracija prikazuju primeri, pri čemu se parametri mreže optimizuju tako da razlika između odziva mreže i željenih vrednosti zadovolji unapred zadate kriterijume. Sa dovoljnim brojem neurona u skrivenom sloju, mogu se naći vrednosti težina za aproksimaciju bilo koje kontinualne, diferencijabilne funkcije. Optimizacija težina veza između neurona nije jednostavan zadatak. Za najveći broj praktičnih primera gradijentni metodi su dali najbolje rezultate.

Najzastupljeniji algoritam za nadgledano učenje neuronskih mreža je *backpropagation* algoritam koji vrši izračunavanje izvoda greške za svaku težinu u mreži. Standardna funkcija greške predstavlja kvadrat razlike između željenog i stvarnog izlaza

mreže. Za svaki primer za obuku mreže, prilikom njegovog prolaska kroz mrežu izračunavaju se izlazi pojedinih neurona. Zatim, počevši od neurona u izlaznom sloju, vrši se povratan prolaz kroz mrežu kako bi se izračunali izvodi funkcije greške za sve ulaze jednog neurona. Na osnovu dobijenih izvoda greške lako se izračunavaju izvodi greške za sve težine veza u mreži [53].

Postoji nekoliko načina za upotrebu izvoda greške, izračunatih primenom *backpropagation* algoritma:

- Kod *online* učenja, težine se podešavaju posle svakog prikazanog primera za obuku, srazmerno izvodima greške za taj slučaj.
- Sa druge strane, kod *batch* učenja izvodi se akumuliraju u toku prolaska svih primera iz skupa za obuku kroz mrežu a zatim se težine podešavaju u pravcu najvećeg pada (nagiba) funkcije greške, ili u nekom drugom pravcu izračunatom metodom kao što su momentum, konjugovani gradijent ili delta pravilo.

Jednostavan *online* metod je najefikasniji u slučaju velikih skupova za obuku, koji pri tom sadrže i veliku količinu redundantnih podataka. Sa druge strane *batch* pravilo je jednostavnije i efikasnije u slučaju malih skupova za obuku. Postoje i konstruktivni metodi koji postepeno dodaju neurone u skriveni sloj mreže dok vrednosti težina veza između postojećih neurona ostaju nepromenjene [54].

MLP neuronske mreže sa jednim ili više skrivenih slojeva, obučene *backpropagation* algoritmom, pokazale su se veoma uspešnim u rešavanju problema kao što su razlikovanje sličnih fonema [55] i prepoznavanje ručno pisanih cifara [56]. Performanse mreže je moguće znatno poboljšati ukoliko se prirodna simetrija problema implementira u mrežu tako što se različitim vezama dodele iste vrednosti težinskih koeficijenata.

U slučaju kada je na raspolaganju ograničen skup za obuku, može doći do stvaranja kompleksne mreže sa velikim brojem težina i sa velikom verovatnoćom da mreža bude preobučena, odnosno, da daje veoma dobre rezultate za primere iz skupa za obuku ali veoma loše za primere koji nisu prikazani mreži u toku procesa obuke. Sa druge strane, jednostavna mreža sa malim brojem težina može imati loše performanse i na skupu za obuku i na test skupu, jer nije u stanju da dobro aproksimira originalnu funkciju.

Do sada je razvijeno nekoliko različitih metoda za optimizaciju kompleksnih mreža. Ukoliko se iz skupa za obuku izdvoji određeni broj primera i formira validacioni skup, tada se može obučiti više neuronskih mreža sa različitim brojem neurona u skrivenom sloju. Za dalju primenu, biraju se mreže koje imaju najbolje performanse na validacionom skupu. U

slučaju ograničenih računarskih resursa pogodno je primeniti metod ranog zaustavljanja (*early stopping*), koji prekida obuku kompleksne mreže kada dođe do pogoršanja performansi na validacionom skupu.

Backpropagation algoritam

Backpropagation algoritam za obuku MLP mreže predstavlja generalizaciju metoda najmanjih kvadrata, LMS (*Least Mean Squares Method*). Oba algoritma koriste srednje kvadratnu grešku kao merilo za procenu performansi obučene neuronske mreže.

Na početku procesa obuke, *backpropagation* algoritam raspolaže skupom za obuku, odnosno parovima ulaz – željeni izlaz mreže:

$$\{\mathbf{p}(1), \mathbf{t}(1)\}, \{\mathbf{p}(2), \mathbf{t}(2)\}, \dots, \{\mathbf{p}(q), \mathbf{t}(q)\}, \dots, \{\mathbf{p}(Q), \mathbf{t}(Q)\}. \quad (3.10)$$

Algoritam se izvršava u nekoliko koraka:

1. *Inicijalizacija.* Na početku obuke se vrši inicijalizacija parametara mreže, težina i biasa. Parametri uzimaju proizvoljne vrednosti iz uniformne raspodele sa nultom srednjom vrednošću. Varijansa parametara je odabrana tako da standardna devijacija indukovanih lokalnih polja neurona leži u tranziciji između linearnih i zasićenih delova sigmoidne aktivacione funkcije [53].
2. *Prikaz skupa za obuku.* Mreži se prikazuje skup za obuku. Jedan prolaz celokupnog skupa za obuku kroz mrežu naziva se epoha. Za svaki primer iz skupa, vrše se izračunavanja za prostiranje signala u mreži unapred, i izračunavanje izvoda greške unazad (*backpropagation*).
3. *Prostiranje signala unapred.* Posmatraćemo jedan primer iz skupa za obuku označen sa $(\mathbf{p}(q), \mathbf{t}(q))$, u jednoj epohi. Na ulaz neuronske mreže dovodi se vektor $\mathbf{p}(q)$, dok se željeni izlazni vektor $\mathbf{t}(q)$ prikazuje izlaznom sloju mreže. Prostirući se kroz mrežu, ulazni signal indukuje odzive svih neurona, redom sloj po sloj. Ulaz j -tog neurona u l -tom sloju, $v_j^{(l)}(q)$, dat je sledećim izrazom:

$$v_j^{(l)}(q) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(q) a_i^{(l-1)}(q), \quad (3.11)$$

gde je $a_i^{(l-1)}(q)$ izlaz i -tog neurona u prethodnom $l-1$ -om sloju u q -toj iteraciji (odnosno za q -ti primer iz skupa za obuku), m_0+1 je broj neurona u $l-1$ -om sloju, dok je $w_{ji}^{(l)}(q)$ težina veze između j -tog neurona u l -tom sloju i i -tog neurona u $l-1$ -om sloju. Za $i=0$, sledi da je $a_0^{(l)}$

$w_{j0}^{(l)}(q) = +1$ i $w_{j0}^{(l)}(q) = b_j^{(l)}(q)$, gde je $b_j^{(l)}(q)$ bias koji odgovara neuronu j u sloju l . Podrazumevajući upotrebu sigmoidne aktivacione funkcije, izlazni signal j -tog neurona u l -tom sloju je:

$$a_j^{(l)}(q) = \varphi_j(v_j(q)). \quad (3.12)$$

Ukoliko se neuron j nalazi u prvom skrivenom sloju ($l=1$), tada je

$$a_j^{(0)}(q) = p_j(q), \quad (3.13)$$

gde je $p_j(q)$ j -ti element ulaznog vektora $\mathbf{p}(q)$. Ukoliko se neuron j nalazi u izlaznom sloju mreže ($l=L$), može se napisati:

$$a_j^{(L)} = o_j(q). \quad (3.14)$$

Signal greške se jednostavno izračunava na sledeći način:

$$e_j(q) = t_j(q) - o_j(q), \quad (3.15)$$

gde je $t_j(q)$ j -ti element željenog odziva mreže $\mathbf{t}(q)$ dok je $o_j(q)$ j -ti element stvarnog odziva mreže, $j=1, 2, \dots, M$.

4. *Prostiranje signala greške unazad.* U ovom koraku se izračunavaju lokalni gradijenti mreže definisani na sledeći način:

$$\delta_j^{(l)}(q) = \begin{cases} e_j^{(L)}(q) \varphi_j'(v_j^{(L)}(q)) & \text{za neuron } j \text{ u izlaznom sloju } L \\ \varphi_j'(v_j^{(L)}(q)) \sum_k \delta_k^{(l+1)}(q) w_{kj}^{(l+1)}(q) & \text{za neuron } j \text{ u skrivenom sloju } l \end{cases} \quad (3.16)$$

gde $\varphi_j'(\cdot)$ označava operaciju izvoda funkcije. Težine veza u sloju l podešavaju se u skladu sa generalizovanim delta pravilom:

$$w_{ji}^{(l)}(q+1) = w_{ji}^{(l)}(q) + \alpha [w_{ji}^{(l)}(q-1)] + \eta \delta_j^{(l)}(q) a_i^{(l-1)}(q), \quad (3.17)$$

gde je η parametar brzine učenja dok je α konstanta momentuma.

5. *Iteracija.* Izračunavanja za prostiranje signala unapred kroz mrežu i podešavanje parametara mreže u suprotnom pravcu ponavljaju se kroz nekoliko epoha. Proces se završava

kada se ispunи unapred zadat kriterijum za obuku mreže, a to je tačnost aproksimacije ili maksimalan broj epoha.

Redosled prikazivanja primera za obuku mreže može biti tačno definisan ili slučajan, od epohe do epohe. Momentum i parametar brzine učenja mreže se obično podešavaju (smanjuju se) sa porastom broja iteracija. U praksi se najčešće koriste modifikacije *backpropagation* algoritma sa višim stepenom konvergencije kao što je metod konjugovanog gradijenta (*conjugate gradient*) i *quasi-Newtonova* metoda, [57]. Ovo su u osnovi gradijentni metodi koji grešku odziva mreže za ceo skup za obuku svode na minimum.

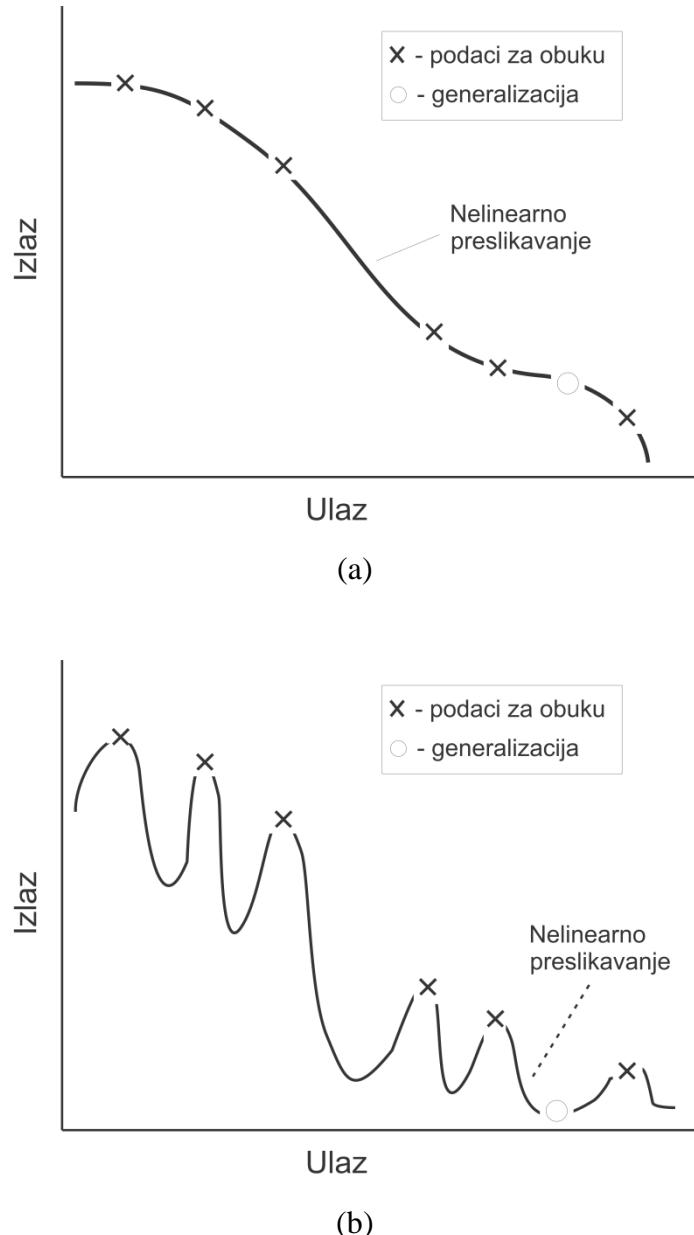
3.3.2 Sposobnost generalizacije MLP neuronskih mreža

Backpropagation algoritam vrši optimizaciju težina veza između neurona propuštanjem primera za obuku kroz mrežu u određenom broju iteracija. Krajnji cilj obuke je formiranje neuronske mreže sa dobrom generalizacionim sposobnostima. Dobro obučena neuronska mreža ima korektan odziv čak i za test podatke koji nisu korišćeni u procesu obuke mreže. Pri tome se podrazumeva da su test podaci uzeti iz istog opsega kao i podaci za obuku mreže.

Proces obuke neuronske mreže može se posmatrati kao problem aproksimacije funkcije pri čemu mreža vrši nelinearno preslikavanje. U ovom slučaju, sposobnost generalizacije mreže ogleda se u mogućnosti korektne nelinearne interpolacije ulaznih podataka. Neuronske mreže dobro interpoliraju ulazne podatke iz razloga što višeslojni perceptroni sa kontinualnim aktivacionim funkcijama daju izlazne funkcije koje su takođe kontinualne.

Efekat generalizacije jedne hipotetičke neuronske mreže je ilustrovan na Slici 3.7 (a). Nelinearno preslikavanje koje je prikazano krivom linijom predstavlja odziv neuronske mreže. Podaci za obuku mreže su označeni krstićima, dok je podatak za testiranje mreže označen kružićem. Kao što je ilustrovano na slici, dobro obučena neuronska mreža vrši korektno ulazno-izlazno preslikavanje čak i kada se ulazi u određenoj meri razlikuju od primera korišćenih za obuku mreže. Međutim, ukoliko se mreži u procesu obuke prikaže previše primera, može doći do situacije da mreža jednostavno memoriše primere za obuku. Do ove pojave dolazi usled toga što mreža modeluje neke karakteristike koje poseduju podaci u skupu za obuku (npr. šum), ali ne i stvarnu funkciju koju je potrebno modelovati. Za mrežu se u ovom slučaju kaže da je pre-obučena (*overfitted*) jer gubi sposobnost generalizacije [53].

Pored toga, propuštanje podataka kroz MLP mrežu zahtevaće više neurona u skrivenom sloju nego što je to zaista potrebno. Primer loše generalizacije mreže zbog memorisanja podataka za obuku je prikazan na Slici 3.7 (b). Može se uočiti da kada se na ulaz mreže dovedu test podaci odziv mreže znatno odstupa od korektnih vrednosti. Kao posledica memorizacije, ulazno-izlazno preslikavanje neuronske mreže jako osciluje u prostoru između dva podatka za obuku.



Slika 3.7 Primer (a) dobre generalizacije i (b) loše generalizacije neuronske mreže [53]

Na generalizacione sposobnosti neuronske mreže utiču sledeći faktori:

- Veličina skupa za obuku,

- Mera u kojoj je skup reprezentativan za problem koji se modeluje,
- Arhitektura neuronske mreže,
- Kompleksnost problema koji se rešava.

U kontekstu prva tri faktora, problem generalizacije se može razmatrati na dva načina:

- Arhitektura mreže je unapred određena u skladu sa fizičkom kompleksnošću problema koji se rešava. U ovom slučaju je potrebno odrediti veličinu skupa za obuku da bi se postigla dobra generalizacija.
- Veličina skupa za obuku je unapred određena i problem koji je potrebno rešiti je određivanje najbolje arhitekture mreže da bi se ostvarila dobra generalizacija.

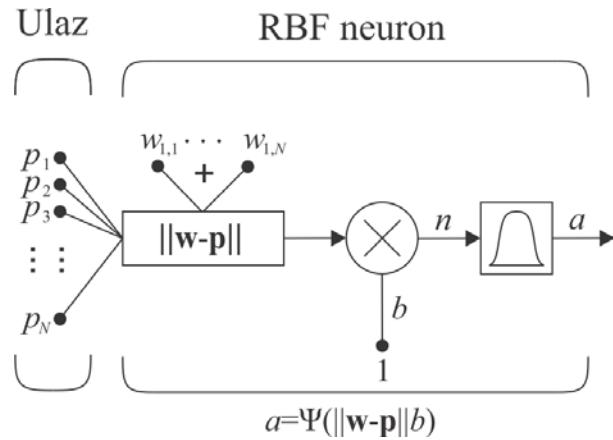
Oba načina za obuku neuronske mreže sa dobim generalizacionim sposobnostima su validna na svoj način. Izbor pogodnijeg pristupa se može izvršiti u zavisnosti od prirode problema koji se rešava.

3.4 Radijalna bazisna neuronska mreža – RBF

Radijalne bazisne neuronske mreže (RBFNNs, *Radial Basis Function Neural Networks*) se sastoje iz tri sloja: ulaznog, izlaznog i jednog skrivenog sloja. Za razliku od višeslojnih MLP neuronskih mreža, RBF mreže mogu da sadrže znatno veći broj neurona u skrivenom sloju. Sa druge strane, ovaj tip neuronskih mreža ima bolje vreme konvergencije i daje odlične rezultate u slučaju velikih skupova za obuku. Model neurona i struktura RBF mreže biće opisani u tekstu koji sledi.

3.4.1 Model neurona

Na Slici 3.8, prikazan je model jednog RBF neurona. Može se zapaziti da se izraz koji opisuje ulaz RBF neurona znatno razlikuje od ulaza MLP neurona (Slika 3.2). U ovom slučaju se elementi ulaznog vektora ne množe težinskim koeficijentima veza, već se određuje vektor rastojanja između vektora težina w i ulaznog vektora p . Funkcija $\|w-p\|$ na Slici 3.8, uzima ulazni vektor p i jednu vrstu matrice težinskih koeficijenata i kao izlaz daje njihov skalarni proizvod [52].

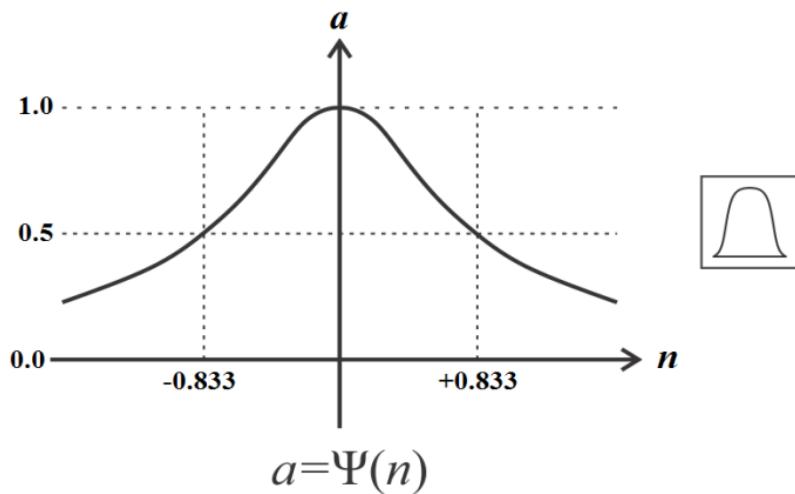


Slika 3.8 Matematički model RBF neurona [52]

Prenosna funkcija RBF neurona data je sledećim izrazom:

$$\psi(n) = e^{-n^2}. \quad (3.18)$$

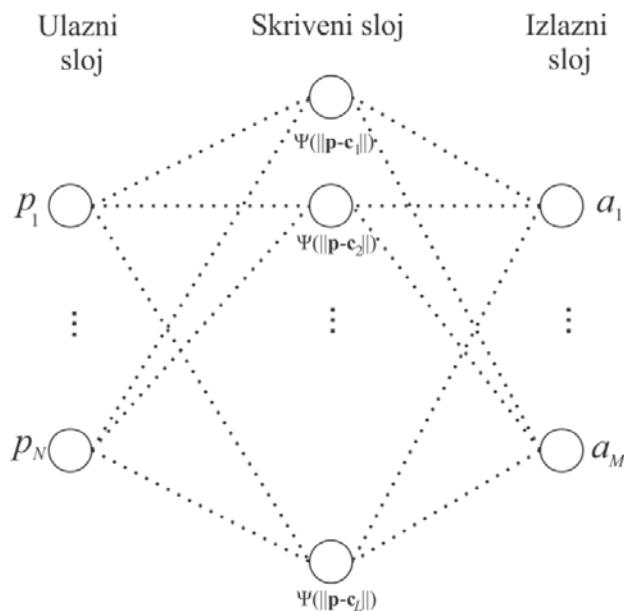
Na Slici 3.9, ilustrovana je RBF funkcija. Funkcija dostiže svoj maksimum, jednak jedinici, za ulaz jednak nuli. Sa smanjenjem rastojanja između vektora \mathbf{w} i \mathbf{p} , izlaz funkcije raste. Može se zaključiti da RBF neuron ima ulogu detektora koji daje na svom izlazu jedinicu uvek kada je ulaz \mathbf{p} jednak svom težinskom vektoru \mathbf{w} . Bias b omogućava podešavanje osetljivosti RBF neurona. Na primer, ukoliko neuron ima bias jednak 0.1, on će dati na svom izlazu 0.5 za svaki ulazni vektor \mathbf{p} na rastojanju 8.326 (0.8326/b) od težinskog vektora \mathbf{w} .



Slika 3.9 Radijalna bazisna funkcija

3.4.2 Struktura RBF mreže

RBF mrežu čine tri sloja: ulazni, izlazni i jedan skriveni sloj, Slika 3.10. Broj neurona u ulaznom sloju mreže jednak je broju elemenata ulaznog vektora, N . Skriveni sloj ima ukupno L neurona, od kojih svaki ima odgovarajući centar \mathbf{c}_l , $l=1, 2, \dots, L$. Skriveni sloj najpre vrši izračunavanje rastojanja između ulaznog vektora i odgovarajućeg centra, nakon čega se primjenjuje radikalna funkcija, označena sa ψ . Dobijena skalarna vrednost se prosleđuje do izlaznog sloja. Izlazni sloj mreže izračunava linearne kombinacije vrednosti dobijenih u skrivenom sloju i prosleđuje ih okruženju. Ovaj sloj je linearan, sa dimenzijama jednakim broju izlaza neuronske mreže, M .



Slika 3.10 Struktura RBF neuronske mreže

Prikazivanjem ulaznog vektora mreži, svaki neuron u skrivenom sloju daje neku izlaznu vrednost u zavisnosti od toga koliko je ulazni vektor blizak težinskom vektoru neurona. Samim tim, RBF neuroni čiji se težinski vektori znatno razlikuju od ulaznog vektora \mathbf{p} , daće izlazne vrednosti bliske nuli. Ove male vrednosti imaju neznatan efekat na linearne neurone u izlaznom sloju mreže. Sa druge strane, RBF neuroni čiji su težinski vektori bliski ulaznom vektoru \mathbf{p} daju izlaz blizu jedinice. Ukoliko neuron ima izlaz 1, njegove težine prema izlaznom sloju prosleđuju svoje vrednosti do linearnih neurona u izlaznom sloju.

Princip funkcionisanja skrivenog sloja se može opisati na sledeći način:

- Za svaki ulazni vektor u neuronsku mrežu izračunava se razlika između ulaznog vektora i težinskog vektora, odnosno, centra neurona,
- Proizvod vektora razlike i biasa predstavlja ulaz neurona u skrivenom sloju,
- Na dobijeni proizvod primenjuje se radijalna bazisna funkcija i izračunava se izlaz neurona,
- Ukoliko je težinski vektor jednak ulaznom vektoru tada je ulaz u neuron jednak 0, a izlaz 1,
- Izlaz neurona će biti blizak 0 u slučaju da je razlika između težinskog vektora i ulaznog vektora velika.

3.4.3 Pravila učenja RBF neuronskih mreža

Pravila za učenje RBF neuronskih mreža se međusobno razlikuju po načinu izbora centara radijalnih bazisnih funkcija. Naime, određivanje centara neurona u skrivenom sloju se suštinski razlikuje od izračunavanja linearnih težina od skrivenog prema izlaznom sloju RBF mreže. Optimizacija centara je nelinearan proces i samim tim je znatno sporiji od linearne optimizacije težina prema izlaznom sloju mreže. S obzirom da različiti slojevi RBF mreže obavljaju različite zadatke, procesi optimizacije težina skrivenog i izlaznog sloja se mogu razdvojiti i izvršiti u različitim vremenskim intervalima. Za performanse RBF mreža, najkritičniji deo obuke predstavlja izbor centara RBF funkcija.

U daljem tekstu, biće dat pregled najzastupljenijih metoda za učenje RBF mreža.

Nasumično odabrani centri RBF funkcija

Najjednostavniji pristup u izboru centara radijalnih bazisnih funkcija neurona u skrivenom sloju predstavlja odabir fiksnih centara. Time se podrazumeva nasumičan odabir određenog broja centara iz skupa podataka za obuku mreže. Ovaj pristup je okarakterisan i kao veoma osetljiv jer podrazumeva da su podaci za obuku raspodeljeni na reprezentativan način za problem koji se rešava. Izbor radijalne bazisne funkcije može biti izotropna *Gaussova* funkcija sa fiksnom standardnom devijacijom u skladu sa rastojanjima između centara. U tom slučaju je normalizovana radijalna bazisna funkcija sa centrom \mathbf{c}_i definisana sledećim izrazom:

$$G(\|\mathbf{p} - \mathbf{c}_i\|^2) = \exp\left(-\frac{L}{d_{max}^2}\|\mathbf{p} - \mathbf{c}_i\|^2\right), \quad i = 1, 2, \dots, L \quad (3.19)$$

gde je L broj centara, dok je d_{max} maksimalno rastojanje između odabralih centara. U suštini, standardna devijacija svih *Gaussovih* radijalnih bazisnih funkcija ima istu vrednost:

$$\sigma = \frac{d_{max}}{\sqrt{2L}} \quad (3.20)$$

Ovaj izraz obezbeđuje da svaka pojedinačna radijalna bazisna funkcija ne budu previše izražena ali ni previše ravna, jer ova ekstremna slučaja treba izbeći [53]. Kao alternativa izrazu (3.20), mogu se upotrebiti skalirani centri, sa većim standardnim devijacijama u oblastima manje gustine podataka. Određivanje ovih centara zahteva eksperimentisanje sa podacima za obuku.

Parametri koje je potrebno optimizovati nakon odabira centara su linearne težine između skrivenog i izlaznog sloja mreže. Direktna procedura koja se može upotrebiti u ovu svrhu je pseudoinverzni metod [58]. Linearne težine se mogu odrediti na osnovu sledećeg izraza:

$$\mathbf{w} = \mathbf{G}^+ \mathbf{t}, \quad (3.21)$$

gde je \mathbf{t} vektor željenih izlaza neuronske mreže dok matrica \mathbf{G}^+ označava pseudoinverznu matricu \mathbf{G} , definisanu kao:

$$\mathbf{G} = \{g_{ji}\}, \quad (3.22)$$

gde je

$$g_{ji} = \exp\left(-\frac{L}{d_{max}^2}\|\mathbf{p}_j - \mathbf{c}_i\|^2\right), \quad j = 1, 2, \dots, Q; i = 1, 2, \dots, L \quad (3.23)$$

gde je \mathbf{p}_j j -ti ulazni vektor iz skupa za obuku. Osnova svih algoritama za izračunavanje pseudoinverzne matrice je dekompozicija matrice i određivanje sopstvenih vrednosti (SVD, *Singular Value Decomposition*). Ako se prepostavi da je \mathbf{G} realna $Q \times L$ matrica, tada postoji ortogonalne matrice \mathbf{U} i \mathbf{V} , definisane izrazima:

$$\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_Q], \quad (3.24)$$

$$\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_L], \quad (3.25)$$

tako da je ispunjen uslov:

$$\mathbf{U}^T \mathbf{G} \mathbf{V} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_K), \quad K = \min(L, Q) \quad (3.26)$$

gde je:

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_K > 0. \quad (3.27)$$

Vrednosti σ_k ($k=1, 2, \dots, K$), predstavljaju jedinstvene vrednosti matrice \mathbf{G} . Prema teoremi o dekompoziciji singularnih vrednosti, $L \times Q$ pseudoinverzna matrica \mathbf{G} definisana je sa:

$$\mathbf{G}^+ = \mathbf{V} \Sigma^+ \mathbf{U}^T, \quad (3.28)$$

gde je $\Sigma^+ N \times N$ matrica koja se može odrediti preko sopstvenih vrednosti matrice \mathbf{G} :

$$\Sigma^+ = \text{diag}\left(\frac{1}{\sigma_1}, \frac{1}{\sigma_2}, \dots, \frac{1}{\sigma_K}, 0, \dots, 0\right). \quad (3.29)$$

Nasumičan odabir fiksnih centara pri formiranju RBF mreže je metod koji daje dobre rezultate u slučaju velikih skupova za obuku, sa homogenom raspodelom ulaznih podataka.

Ortogonalni metod najmanjih kvadrata, OLS

Za određivanje parametara RBF mreže se može primeniti OLS (*Orthogonal Least Squares*) metod [59]. Izbor centara RBF funkcija se vrši iz skupa za obuku mreže, na osnovu procene opadanja greške u algoritmu sa selekcijom tipa “unapred”. Neuronska mreža se formira postepeno, tako što se u svakoj iteraciji dodaje po jedan centar čiji je doprinos opadanju greške najveći. Svaki odabrani centar daje najveći inkrement objašnjenoj varijansi (*explained variance*) ili energiji željenog odziva.

RBF mreža se može predstaviti u obliku linearног modela na sledeći način:

$$\mathbf{t} = \mathbf{P} \mathbf{Q} + \mathbf{E}, \quad (3.30)$$

gde je:

$$\mathbf{t} = [t(1) \ t(2) \ \dots \ t(N)]^T \quad (3.31)$$

$$\mathbf{P} = [\mathbf{p}_1 \ \mathbf{p}_2 \ \dots \ \mathbf{p}_M], \quad (3.32)$$

$$\mathbf{p}_i = [p_i(1) \ p_i(2) \ \dots \ p_i(N)], \quad i=1, 2, \dots, M \quad (3.33)$$

$$\mathbf{Q} = [Q_1 \ Q_2 \ \dots \ Q_M]^T \quad (3.34)$$

$$\mathbf{E} = [\varepsilon(1) \ \varepsilon(2) \ \dots \ \varepsilon(N)]^T. \quad (3.35)$$

Zbog jednostavnosti prikaza, prepostavlja se da mreža ima skalarni izlaz t . N označava broj podataka u skupu za obuku, M je broj RBF centara, \mathbf{p}_i je tzv. vektor regresije dok je sa \mathbf{E} označen vektor greške. $\widehat{\mathbf{Q}}$ predstavlja rešenje metoda najmanjih kvadrata, koje zadovoljava uslov da je $\mathbf{P}\widehat{\mathbf{Q}}$ projekcija vektora \mathbf{t} na prostor koji je određen bazisnim vektorima \mathbf{p}_i [59].

OLS metod podrazumeva transformaciju niza vektora \mathbf{p}_i , u niz ortogonalnih bazisnih vektora čime se omogućava izračunavanje individualnih doprinosa svakog bazisnog vektora na željeni izlaz. Dekompozicijom matrice \mathbf{P} se dobija:

$$\mathbf{P} = \mathbf{W}\mathbf{A}, \quad (3.36)$$

gde \mathbf{A} označava $M \times M$ matricu sa elementima jednakim jedinici na glavnoj dijagonali, odnosno, nuli ispod dijagonale, dok je \mathbf{W} matrica dimenzija $N \times M$, sa ortogonalnim kolonama \mathbf{w}_i . Prostor obuhvaćen ortogonalnim bazisnim vektorima \mathbf{w}_i poklapa se sa prostorom obuhvaćenim vektorima \mathbf{p}_i , tako da se (3.30) može napisati u sledećem obliku:

$$\mathbf{t} = \mathbf{W}\mathbf{g} + \mathbf{E} \quad (3.37)$$

Ortogonalna rešenja metoda najmanjih kvadrata $\widehat{\mathbf{g}}$ izračunavaju se na osnovu izraza:

$$\widehat{g}_i = \frac{\mathbf{w}_i^T \mathbf{t}}{\mathbf{w}_i^T \mathbf{w}_i}, \quad i=1, 2, \dots, M \quad (3.38)$$

Veličine $\widehat{\mathbf{g}}$ i $\widehat{\mathbf{Q}}$ zadovoljavaju sledeći uslov:

$$\mathbf{A}\widehat{\mathbf{Q}} = \widehat{\mathbf{g}}, \quad (3.39)$$

nakon čega se može primeniti *Gram-Schmidtov* metod, ili neka njegova modifikacija, za određivanje $\widehat{\mathbf{Q}}$. Ovaj metod izračunava jednu kolonu matrice \mathbf{A} po iteraciji i vrši ortogonalizaciju matrice \mathbf{P} u nekoliko koraka:

1. Za $i=1, 2, \dots, M$, izračunava se:

$$\mathbf{w}_1^{(i)} = \mathbf{p}_1 \quad (3.40)$$

$$g_1^{(i)} = \frac{(\mathbf{w}_1^{(i)})^T \mathbf{t}}{(\mathbf{w}_1^{(i)})^T (\mathbf{w}_1^{(i)})} \quad (3.41)$$

$$[\text{err}]_1^{(i)} = \frac{(g_1^{(i)})^2 (\mathbf{w}_1^{(i)})^T \mathbf{w}_1^{(i)}}{\mathbf{t}^T \mathbf{t}} \quad (3.42)$$

$$[\text{err}]_1^{(i_1)} = \max\{[\text{err}]_1^{(i)}\} \quad i=1, 2, \dots, M \quad (3.43)$$

nakon čega se dobija:

$$\mathbf{w}_1 = \mathbf{w}_1^{i_1} = \mathbf{p}_{i_1} \quad i=1, 2, \dots, M \quad (3.44)$$

2. U k -tom koraku, gde je $k \geq 2$, $i=1, 2, \dots, M$, i $i \neq i_1, \dots, i \neq i_{k-1}$, slede dalja izračunavanja:

$$\alpha_{jk}^{(i)} = \frac{\mathbf{w}_j^T \mathbf{p}_i}{\mathbf{w}_j^T \mathbf{w}_j} \quad j=1, 2, \dots, k-1 \quad (3.45)$$

$$\mathbf{w}_k^i = \mathbf{p}_i - \sum_{j=1}^{k-1} \alpha_{jk}^{(i)} \mathbf{w}_j, \quad (3.46)$$

$$g_k^{(i)} = \frac{(\mathbf{w}_k^{(i)})^T \mathbf{t}}{(\mathbf{w}_k^{(i)})^T (\mathbf{w}_k^{(i)})} \quad (3.47)$$

$$[\text{err}]_k^{(i)} = \frac{(g_k^{(i)})^2 (\mathbf{w}_k^{(i)})^T \mathbf{w}_k^{(i)}}{\mathbf{t}^T \mathbf{t}} \quad (3.48)$$

$$[\text{err}]_k^{(i_k)} = \max\{[\text{err}]_k^{(i)}\}, \quad i=1, 2, \dots, M, \quad i \neq i_1, \dots, i \neq i_{k-1} \quad (3.49)$$

nakon čega se može napisati:

$$\mathbf{w}_k = \mathbf{w}_k^{(ik)} = \mathbf{p}_{ik} - \sum_{j=1}^{k-1} \alpha_{jk}^{(ik)} \mathbf{w}_j, \quad (3.50)$$

3. Procedura se završava u koraku M_s kada greška postane manja od unapred zadate tolerancije:

$$1 - \sum_{j=1}^{M_s} [\text{err}]_j < \rho, \quad 0 < \rho < 1 \quad (3.51)$$

gde M_s predstavlja broj značajnih regresora ($M_s << M$).

OLS metod predstavlja sistematski pristup izračunavanju centara RBF funkcija i daleko je superiorniji u odnosu na nasumičan izbor centara. Primenom OLS metoda, istovremeno se određuju centri i težine prema izlaznom sloju mreže.

Samoorganizovani centri RBF funkcija

Osnovni problem sa fiksnim, nasumično odabranim, RBF centrima je činjenica da zahtevaju velike skupove za obuku kako bi imali zadovoljavajuće performanse. Jedan od načina za prevazilaženje ovog ograničenja je upotreba hibridnog procesa učenja, koji se sastoji iz dve faze:

- Nenadgledana metoda – čiji je cilj da pronađe odgovarajuće centre RBF funkcija u skrivenom sloju,
- Nadgledana metoda – koja kompletira neuronsku mrežu tako što optimizuje linearne težine od skrivenog ka izlaznom sloju.

Iako se “batch” obuka može iskoristiti za implementiranje ove dve metode učenja, prednost se daje adaptivnom (iterativnom) pristupu.

Samoorganizovani izbor centara RBF funkcija vrši se *clustering* algoritmom koji deli dati skup za obuku mreže na podskupove. Cilj je da dobijeni podskupovi budu što homogeniji. Jedan takav algoritam je *k-means clustering* algoritam [60], koji locira centre RBF funkcija u onim regionima ulaznog prostora u kojima su prisutni najznačajniji podaci.

Neka je sa L označen broj RBF funkcija. Optimalna vrednost za L nije unapred poznata i određuje se eksperimentalnim putem. Sa $\{\mathbf{c}_i(n)\}_{i=1}^L$ označeni su centri RBF funkcija u n -toj iteraciji algoritma. *K-means clustering* algoritam se odvija na sledeći način:

1. *Inicijalizacija* – U toku ove faze, biraju se slučajne vrednosti za početne centre $\mathbf{c}_i(0)$. Jedini uslov je da svi odabrani centri budu međusobno različiti. Kao dodatni uslov može se javiti zahtev da Euklidovo rastojanje između centara bude što manje.

2. *Uzorkovanje* – Uzima se vektor-uzorak \mathbf{p} iz skupa za obuku sa određenom verovatnoćom. Vektor \mathbf{p} je ulaz algoritma u n -toj iteraciji.

3. *Pronalaženje sličnosti* – Neka je sa $i(\mathbf{p})$ označen indeks najpogodnjeg (najbližeg) centra ulaznom vektoru \mathbf{p} . Traženi indeks u n -toj iteraciji pronalazi se na osnovu kriterijuma minimalnog Euklidovog rastojanja:

$$i(\mathbf{p}) = \operatorname{argmin}_i \|\mathbf{p}(n) - \mathbf{c}_i(n)\|, \quad i = 1, 2, \dots, L \quad (3.52)$$

gde je $\mathbf{c}_i(n)$ centar i -te RBF funkcije u n -toj iteraciji.

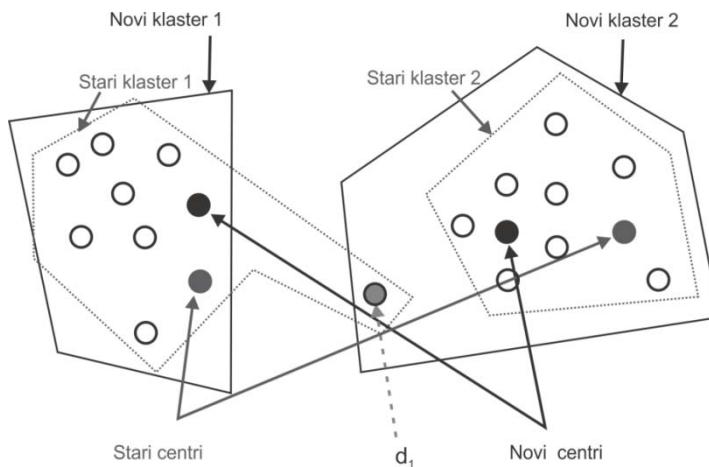
4. *Ažuriranje*. Izračunavaju se novi centri RBF funkcija na osnovu sledećeg pravila:

$$\mathbf{c}_i(n+1) = \begin{cases} \mathbf{c}_i(n) + \eta[\mathbf{p}(n) - \mathbf{c}_i(n)] & i = i(\mathbf{p}) \\ \mathbf{c}_i(n) & \text{u drugim slučajevima} \end{cases} \quad (3.53)$$

gde je η parametar brzine učenja koji leži u opsegu $0 < \eta < 1$.

5. *Nastavak procedure.* Broj iteracija n inkrementira se za 1, nakon čega se algoritam vraća na korak 2, sve dok ima značajnijih promena kod centara \mathbf{c}_i .

K-means clustering algoritam predstavlja specijalan slučaj jednog moćnijeg metoda učenja poznatog pod nazivom samo-organizovana mapa (*self-organizing map*).



Slika 3.11 Primer *k-means clustering* algoritma gde podatak d_1 prelazi iz klastera 1 u klaster 2 posle ažuriranja centara

Nedostatak *k-means clustering* algoritma predstavlja činjenica da on može pronaći samo lokalna optimalna rešenja koja zavise od početnog izbora centra klastera. Posledica toga je nepotrebno trošenje računarskih resursa ukoliko početni centri ostanu zarobljeni u oblastima ulaznog prostora sa nedovoljnom gustom podataka za obuku. Ukoliko se nađu u ovakvoj situaciji, centri nemaju nikakvih šansi da se premeste na nove lokacije gde su zaista potrebni. Najverovatniji krajnji rezultat je formiranje neuronske mreže sa nepotrebno velikim brojem neurona. U cilju pravazilaženja ovog problema predložena je modifikacija *k-means clustering* algoritma [61], koja omogućava algoritmu da konvergira prema optimalnoj ili približno optimalnoj konfiguraciji nezavisno od izbora početnih centara, Slika 3.11.

Nakon određivanja centara svih RBF funkcija i njihovih standardnih devijacija upotrebom *k-means clustering* algoritma ili nekom njegovom poboljšanom vezijom, pristupa se određivanju težina prema izlaznom sloju mreže. Najjednostavniji metod za njihovo izračunavanje je metod najmanjih kvadrata (*LMS – Least Mean Squares*).

Primena hibridnog metoda učenja RBF mreže, koji se sastoji iz nenadgledanog metoda (*k-means clustering*) i nadgledanog metoda (LMS), doprinosi značajnoj uštedi vremena s obzirom da se ove dve procedure mogu obavljati odvojeno.

Nadgledani izbor centara RBF mreža

Kod ovog pristupa, centri RBF funkcija se kao i svi ostali parametri mreže optimizuju metodom nadgledanog učenja. Drugim rečima, RBF mreža dobija svoju najopštiju formu. Metod učenja koji je uobičajen za ovaj proces je metod opadajućeg gradijenta (*descent gradient*) koji predstavlja generalizaciju LMS algoritma.

Prvi korak u razvoju ovog algoritma predstavlja definisanje trenutne vrednosti *cost* funkcije:

$$\varepsilon = \frac{1}{2} \sum_{j=1}^Q e_j^2 \quad (3.54)$$

gde je Q veličina skupa za obuku dok je e_j signal greške definisan sledećim izrazom:

$$\begin{aligned} e_j &= t_j - F * (\mathbf{p}_j) \\ &= t_j - \sum_{i=1}^L \omega_i G\left(\|\mathbf{p}_j - \mathbf{c}_i\|_{H_i}\right) \end{aligned} \quad (3.55)$$

Cilj je pronaći parametre ω_i , \mathbf{c}_i i Σ_i^{-1} (normalizovana težinska matrica \mathbf{H}_i), tako da se minimizuje funkcija greške. Rezultati minimizacije su prikazani u Tabeli 3.1 [61], na osnovu koje se mogu doneti sledeći zaključci:

- Funkcija greške ε je konveksna u odnosu na linearne parametre ω_i , ali je nekonveksna u odnosu na centre \mathbf{c}_i i matricu Σ_i^{-1} . Iz tog razloga, pri traženju optimalnih vrednosti za \mathbf{c}_i i Σ_i^{-1} , funkcija može biti zarobljena u nekom od lokalnih minimuma parametarskog prostora.
- Izrazima za ažuriranje vrednosti parametara ω_i , \mathbf{c}_i i Σ_i^{-1} , uglavnom se dodeljuju različite vrednosti parametara učenja η_1 , η_2 i η_3 , respektivno.
- Za razliku od *backpropagation* algoritma, metod opadajućeg gradijenta za RBF mrežu ne uključuje prostiranje signala greške unazad.
- Gradijentni vektor $\frac{\partial \varepsilon}{\partial \mathbf{c}_i}$ ima efekat sličan podeli podataka u klastere i zavisi od zadatka koji mreža treba da obavlja.

Prilikom inicijalizacije metoda opadajućeg gradijenta najpoželjnije je pretragu parametarskog prostora započeti od uslova koji ograničava region parametarskog prostora na već poznatu oblast, što se može postići implementacijom standardnog metoda za klasifikaciju modela i oblika. U tom slučaju, verovatnoća konvergencije ka nekom neželjenom lokalnom minimumu u prostoru težina je smanjena. Na primer, može se početi sa *Gaussovim* klasifikatorom koji podrazumeva da je svaki model u svakoj klasi uzet iz *Gaussove raspodele*.

Tabela 3.1 *Adaptivne formule za izračunavanje linearnih težina prema izlaznom sloju, centara i standardnih devijacija RBF funkcija [53]*

<p>1. Izračunavanje linearnih težina (izlazni sloj)</p> $\frac{\partial \varepsilon(n)}{\partial \omega_i(n)} = \sum_{j=1}^Q e_j(n) G\left(\ \mathbf{p}_j - \mathbf{c}_i(n)\ _{H_i}\right)$ $\omega_i(n+1) = \omega_i(n) - \eta_1 \frac{\partial \varepsilon(n)}{\partial \omega_i(n)}, \quad i = 1, 2, \dots, L$
<p>2. Određivanje pozicije centara (skriveni sloj)</p> $\frac{\partial \varepsilon(n)}{\partial \mathbf{c}_i(n)} = 2\omega_i(n) \sum_{j=1}^Q e_j(n) G'\left(\ \mathbf{p}_j - \mathbf{c}_i(n)\ _{H_i}\right) \Sigma_i^{-1} [\mathbf{p}_j - \mathbf{c}_i(n)]$ $\mathbf{c}_i(n+1) = \mathbf{c}_i(n) - \eta_2 \frac{\partial \varepsilon(n)}{\partial \mathbf{c}_i(n)}, \quad i = 1, 2, \dots, L$
<p>3. Izračunavanje standardnih devijacija</p> $\frac{\partial \varepsilon(n)}{\partial \Sigma_i^{-1}(n)} = -\omega_i(n) \sum_{j=1}^Q e_j(n) G'\left(\ \mathbf{p}_j - \mathbf{c}_i(n)\ _{H_i}\right) \mathbf{Q}_{ji}(n)$ $\mathbf{Q}_{ji}(n) = [\mathbf{p}_j - \mathbf{c}_i(n)][\mathbf{p}_j - \mathbf{c}_i(n)]^T$ $\Sigma_i^{-1}(n+1) = \Sigma_i^{-1}(n) - \eta_3 \frac{\partial \varepsilon(n)}{\partial \Sigma_i^{-1}(n)}$

*Termin $e_j(n)$ označava signal greške j -tog izlaznog neurona u n -toj iteraciji. Termin $G'(\cdot)$ predstavlja prvi izvod *Greenove* funkcije

Nelinearna optimizacija parametara koji definišu aktivacione funkcije neurona u skrivenom sloju je pogodna kada se zahteva da mreža ima minimalnu konfiguraciju. Prema literaturi [62], iste performanse u generalizaciji se mogu postići sa većom RBF mrežom tj. sa mrežom koja ima veći broj fiksnih centara u skrivenom sloju i kod koje se vrši linearna optimizacija težina prema izlaznom sloju.

Na osnovu eksperimenata čiji je cilj bio poređenje performansi RBF i MLP mreža, na primeru preslikavanja engleskih pisanih reči u fonetski izgovor [63], doneti su sledeći zaključci:

- RBF mreže sa nenadgledanim učenjem lokacija centara i nadgledanim učenjem težina prema izlaznom sloju, ne generalizuju tako dobro kao MLP mreže obučene *backpropagation* algoritmom.
- Generalizovane RBF mreže, sa nadgledanim učenjem primenjenim na pronalaženje lokacija centara kao i na težine prema izlaznom sloju, mogu da nadmaše performanse MLP mreže u pogledu generalizacije.

3.5 Testiranje neuronskih modela

Za procenu generalizacione sposobnosti neuronske mreže se posmatra odziv mreže kada se na njene ulaze dovedu test podaci, odnosno, podaci koji nisu korišćeni u procesu obuke mreže. Performanse obučenih mreža se mogu izraziti preko statističkih parametara kao što su maksimalna greška (WCE, *Worst Case Error*), srednja greška (ACE, *Average Case Error*) i *Pearson Product-Moment* korelacioni koeficijent, r [23].

Razmatraćemo neuronsku mrežu sa N ulaza i M izlaza (Slika 3.6 i Slika 3.10), pri čemu je sa \mathbf{W} označena matrica težina i biasa. Relativna greška odziva na j -tom izlazu mreže može se napisati u sledećem obliku:

$$\delta_{kj} = \frac{a_{kj} - t_{kj}}{t_{\max,j} - t_{\min,j}}, \quad j=1, 2, \dots, M, \quad k=1, 2, \dots, Q \quad (3.56)$$

gde je a_{kj} odziv j -og izlaza neuronske mreže kada je na ulazu k -ti test uzorak iz skupa za obuku, t_{kj} je željeni odziv dok su $t_{\max,j}$ i $t_{\min,j}$ maksimalna i minimalna vrednost na j -tom izlazu mreže, respektivno.

Srednja greška (ACE) se definiše preko srednje vrednosti apsolutne relativne greške na sledeći način:

$$ACE = |\bar{\delta}| = \text{mean}(\delta) = \frac{1}{Q \cdot M} \sum_{j=1}^M \sum_{k=1}^Q |\delta_{kj}|, \quad (3.57)$$

gde je Q ukupan broj elemenata u test skupu.

Maksimalna greška se takođe definiše preko relativne greške pomoću sledećeg izraza:

$$WCE = \max_k \max_j |\delta_{kj}|, \quad (3.58)$$

gde je $k=1, 2, \dots, Q$ i $j=1, 2, \dots, M$.

Korelacioni koeficijent se često koristi kao kriterijum prilikom testiranja obučenih neuronskih modela jer pokazuje u kojoj meri odziv neuronske mreže odgovara željenim vrednostima. Korelacioni koeficijent se izračunava na osnovu sledećeg izraza:

$$r = \frac{\sum_{j=1}^M \sum_{k=1}^Q (|a_{kj}| - |\bar{a}_{kj}|) \cdot (|t_{kj}| - |\bar{t}_{kj}|)}{\left[\sum_{j=1}^M \sum_{k=1}^Q (|a_{kj}| - |\bar{a}_{kj}|)^2 \right] \cdot \left[\sum_{j=1}^M \sum_{k=1}^Q (|t_{kj}| - |\bar{t}_{kj}|)^2 \right]}, \quad (3.59)$$

gde t_{kj} predstavlja željenu vrednost, a_{kj} je odziv neuronske mreže, \bar{t}_{kj} označava srednju vrednost željenih vrednosti, dok \bar{a}_{kj} predstavlja srednju vrednost odziva mreže. Što je vrednost korelacionog koeficijenta bliža jedinici, to su bolje performanse mreže.

3.6 Poređenje karakteristika MLP i RBF neuronskih mreža

MLP i RBF mreže pripadaju nelinearnim slojevitim strukturama sa prostiranjem signala unapred. Takođe, oba tipa neuronskih mreža predstavljaju univerzalne aproksimatore. To znači da je za svaku RBF mrežu moguće pronaći odgovarajuću MLP mrežu, i obratno. Međutim, pored ovih sličnosti MLP i RBF mreže se međusobno značajno razlikuju [53]:

- MLP mreže mogu imati jedan ili više skrivenih slojeva dok RBF mreže, u svojoj osnovnoj formi, imaju jedan skriveni sloj.
- Kod MLP mreža su modeli neurona u skrivenom i izlaznom sloju slični. Nasuprot tome, modeli neurona u skrivenom sloju RBF mreže, kao i njihova funkcija, suštinski se razlikuju od modela neurona u izlaznom sloju mreže.
- Skriveni i izlazni slojevi kod MLP mreža koje vrše klasifikaciju modela ili oblika su obično nelinearni. Kada se MLP mreže primenjuju u svrhu nelinearne aproksimacije izlazni sloj je u najvećem broju slučajeva linearan. Sa druge strane, skriveni sloj kod RBF mreža je nelinearan, dok je izlazni sloj uvek linearan.

- Argument aktivacione funkcije svakog neurona u skrivenom sloju MLP mreže izračunava se kao skalarni proizvod ulaznog vektora i vektora sinaptičke težine koji odgovara određenom neuronu. Kod RBF mreže argument aktivacione funkcije svakog neurona u skrivenom sloju predstavlja Euklidovo rastojanje između ulaznog vektora i centra neurona.
- MLP mreže konstruišu globalne aproksimacije za nelinearne funkcije dok RBF mreže koriste eksponencijalno opadajuće funkcije (npr. *Gaussovu*), da bi konstruisale lokalne aproksimacije za nelinearna preslikavanja.

RBF neuronske mreže mogu imati i do nekoliko puta više neurona od MLP mreža sa sigmoidnim neuronima u skrivenom sloju. Razlog tome je što neuroni sa radijalnom bazisnom funkcijom reaguju samo na relativno male oblasti u ulaznom prostoru dok sigmoidni neuroni daju odziv za ulaze u širokom opsegu ulaznog prostora. Pored toga, obuka RBF mreža je obično efikasnija od obuke MLP mreža.

4 Procena pravaca EM signala

U ovom poglavlju, dat je opis strukture prostorne kovarijansne matrice na primeru pravougaonog antenskog niza. Ukratko je opisan postupak određivanja pravaca EM signala primenom standardnog MUSIC algoritma a za slučaj korelisanih, ili potpuno koherentnih signala, uključena je i tehnika koja omogućava njihovo dekorelisanje i detekciju. Na kraju poglavlja, dat je princip rada veštačkih neuronskih mreža u oblasti procene pravaca EM signala, kao i njihova prednost u odnosu na standardne algoritme.

4.1 Prostorna kovarijansna matrica

Prostorna kovarijansna matrica predstavlja fundamentalni deo najvećeg broja algoritama za procenu pravaca EM signala. Naime, iako se za procenu pravaca mogu direktno upotrebiti vrednosti indukovanih napona na elementima prijemnog antenskog niza, daleko precizniji rezultati se dobijaju na osnovu prostorne kovarijansne matrice. Razlog tome je što se procenom kovarijansne matrice vrši njeno usrednjavanje u vremenu usled čega se u velikoj meri smanjuje nivo šuma u primljenim signalima.

Posmatraćemo jedan $M \times N$ pravougaoni antenski niz koji prima signale od ukupno K elektromagnetna izvora (Poglavlje 2). Neka je sa $\mathbf{x}(t)$ označen vektor primljenih signala na elementima antenskog niza. Prostorna kovarijansna matrica se može odrediti primenom sledećeg izraza:

$$\mathbf{R} = E\{\mathbf{x}(t)\mathbf{x}(t)^H\}, \quad (4.1)$$

gde E označava operator matematičkog očekivanja dok je H Hermitian operator koji vrši transponovanje konjugovanog vektora $\mathbf{x}(t)$. Prethodni izraz se može napisati u sledećem obliku:

$$\begin{aligned} \mathbf{R} &= \mathbf{A}E\{\mathbf{s}(t)\mathbf{s}(t)^H\}\mathbf{A}^H + E\{\mathbf{n}(t)\mathbf{n}(t)^H\} \\ &= \mathbf{A}\mathbf{R}_{xx}\mathbf{A}^H + \sigma_{sum}^2 \mathbf{I} = \sum_{i=1}^{M \cdot N} \lambda_i \mathbf{e}_i \mathbf{e}_i^H, \end{aligned} \quad (4.2)$$

gde je:

- \mathbf{A} - matrica dimenzija $M \cdot N \times K$ (*array manifold*),

- $\mathbf{s}(t)$ - vektor signala dimenzija $K \times 1$,
- $\mathbf{n}(t)$ - vektor belog šuma dimenzija $M \cdot N \times 1$,
- \mathbf{R}_{XX} - kovarijansna matrica,
- σ_{sum}^2 - varijansa statistički nezavisnog belog šuma,
- \mathbf{I} - matrica identiteta,
- λ_i - sopstvene vrednosti matrice \mathbf{R} ,
- \mathbf{e}_i – sopstveni vektori matrice \mathbf{R} .

Za $M \times N$ pravougaoni antenski niz, prostorna kovarijansna matrica je dimenzija $M \cdot N \times M \cdot N$ i može se napisati u sledećem obliku:

$$\mathbf{R} = \begin{bmatrix} R_{11} & R_{12} & \cdots & R_{1(M \cdot N)} \\ R_{21} & R_{22} & \cdots & R_{2(M \cdot N)} \\ \vdots & \vdots & \ddots & \vdots \\ R_{(M \cdot N)1} & R_{(M \cdot N)2} & \cdots & R_{(M \cdot N)(M \cdot N)} \end{bmatrix}, \quad (4.3)$$

Elementi na glavnoj dijagonali matrice \mathbf{R} imaju realne vrednosti i predstavljaju autokorelaciju primljenih signala na svakom pojedinačnom antenskom elementu (R_{ii} , $i=1, 2, \dots, M \cdot N$). Sa druge strane, elementi van glavne dijagonale predstavljaju kros-korelaciju primljenih signala na različitim antenskim elementima (R_{ij} , $i=1, 2, \dots, M \cdot N$, $j=1, 2, \dots, M \cdot N$, $i \neq j$).

U praksi je prostorna kovarijansna matrica \mathbf{R} nepoznata i procenjuje se na osnovu određenog broja vremenskih uzoraka:

$$R_{ij} = \frac{1}{S} \sum_{k=1}^S x_i(k) x_j^*(k), \quad (4.4)$$

gde je $x_i(k)$ k -ti uzorak signala na i -tom elementu antenskog niza, $x_j(k)$ označava k -ti uzorak na j -tom elementu, dok S predstavlja ukupan broj uzoraka primljenih signala na antenskom nizu. Sa porastom broja uzoraka vrši se vremensko usrednjavanje prostorne kovarijanske matrice što doprinosi boljoj tačnosti procenjenih pravaca dolaznih signala.

Na osnovu prethodnih izraza (4.1 – 4.4), može se zaključiti da antenski niz vrši preslikavanje $G: \mathbf{R}^K \rightarrow \mathbf{C}^{M \cdot N}$ iz prostora pravaca EM signala $(\Phi, \Theta) = [(\phi_1, \theta_1), (\phi_2, \theta_2), \dots, (\phi_K, \theta_K)]^T$, u prostor primljenih signala na elementima antenskog niza $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_{M \cdot N}(t)]^T$.

4.2 MUSIC algoritam

U cilju procene pravaca dolaska EM signala, MUSIC algoritam vrši dekompoziciju prostorne kovarijansne matrice na međusobno ortogonalne podprostore signala i šuma [6].

Posmatraćemo $M \times N$ pravougaoni antenski niz koji prima K nekorelisihih signala. Ukoliko su sa λ_i ($i=1, 2, \dots, M \cdot N$) označene sopstvene vrednosti matrice \mathbf{R} tada važe sledeći izrazi:

$$\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_K > \sigma_{\text{sum}}^2, \quad (4.5)$$

i

$$\lambda_{K+1} = \lambda_{K+2} = \lambda_{K+3} = \dots = \lambda_{M \cdot N} = \sigma_{\text{sum}}^2, \quad (4.6)$$

gde je σ_{sum}^2 varijansa statistički nezavisnog belog šuma. Na osnovu ovih izraza može se zaključiti da je ukupno K sopstvenih vrednosti veće od belog šuma. Za određivanje ugaonih pozicija izvora signala koristi se specifična karakteristika podprostora određenih sopstvenim vektorima koji odgovaraju velikim i malim sopstvenim vrednostima matrice \mathbf{R} . *Steering* vektori, koji su virtualno usmereni u pravcu izvora signala, predstavljaju linearu kombinaciju sopstvenih vektora kojima odgovaraju veće sopstvene vrednosti λ_i ($i=1, 2, \dots, K$). Samim tim, ovi vektori su ortogonalni na podprostor šuma određen sopstvenim vektorima kojima odgovaraju male sopstvene vrednosti λ_i ($i=K+1, K+2, \dots, M \cdot N$). Ukoliko su sa \mathbf{e}_i označeni sopstveni vektori koji odgovaraju sopstvenim vrednostima λ_i ($i=1, 2, \dots, M \cdot N$), *steering* vektor usmeren u pravcu (φ, θ) sa $\mathbf{a}(\varphi, \theta)$, tada se spektar MUSIC algoritma može odrediti na osnovu izraza:

$$\begin{aligned} P_{\text{MUSIC}} &= \frac{1}{\sum_{i=K+1}^{M \cdot N} |\mathbf{e}_i^H \mathbf{a}(\varphi, \theta)|^2} \times \mathbf{a}^H(\varphi, \theta) \mathbf{a}(\varphi, \theta) \\ &= \frac{\mathbf{a}^H(\varphi, \theta) \mathbf{a}(\varphi, \theta)}{\mathbf{a}^H(\varphi, \theta) \mathbf{E}_N \mathbf{E}_N^H \mathbf{a}(\varphi, \theta)}, \end{aligned} \quad (4.7)$$

gde je sa \mathbf{E}_N označen podprostor šuma. Drugim rečima, MUSIC algoritam vrši pretragu spektra u potrazi za maksimumima po svim uglovima u azimutu i elevaciji. U slučaju ortogonalnosti, izraz (4.7) će dati izrazite maksimume s obzirom je delilac u tom slučaju jednak nuli.

Za primenu MUSIC algoritma u praksi, neophodno je da broj signala čije je pravce potrebno odrediti bude unapred poznat i manji od broja elemenata antenskog niza kako bi

podprostor šuma uopšte postojao. Takođe, za njegovu primenu je neophodna precizna kalibracija antenskog niza radi kompenzacije efekata međusobne elektromagnetne sprege između antenskih elemenata. MUSIC daje rezultate visoke tačnosti ali je vremenski zahtevan usled kompleksnih matričnih izračunavanja.

4.3 MUSIC algoritam sa SSP metodom

Korelacija između signala ima značajan uticaj na performanse algoritama zasnovanih na određivanju podprostora. Za uspešnu primenu ovih algoritama u praksi neophodno je da K faznih vektora prisutnih izvora signala budu linearne nezavisne kao i da prostorna kovarijansna matrica bude nesingularna. Metod za pretprocesiranje poznat kao SSP (*Spatial Smoothing Preprocessing*) vrši dekorelaciju signala i daje modifikovanu kovarijansnu matricu koja zadovoljava ove uslove.

Neka je sa \mathbf{R} označena prostorna kovarijansna matrica primljenih koherentnih signala na antenskom nizu. Matrica je definisana izrazom identičnim (4.1):

$$\mathbf{R} = E\{\mathbf{x}(t)\mathbf{x}(t)^H\} = \mathbf{A}\mathbf{S}\mathbf{A}^H + \sigma_{\text{sum}}^2 \mathbf{I}, \quad (4.8)$$

gde je \mathbf{S} korelaciona matrica signala dimenzija $K \times K$. U slučaju koherentnih signala, matrica \mathbf{S} dobija sledeći oblik:

$$\mathbf{S} = E\{\mathbf{s}(t)\mathbf{s}(t)^H\} = E\{|s_l(t)|^2\}\mathbf{c}\mathbf{c}^H. \quad (4.9)$$

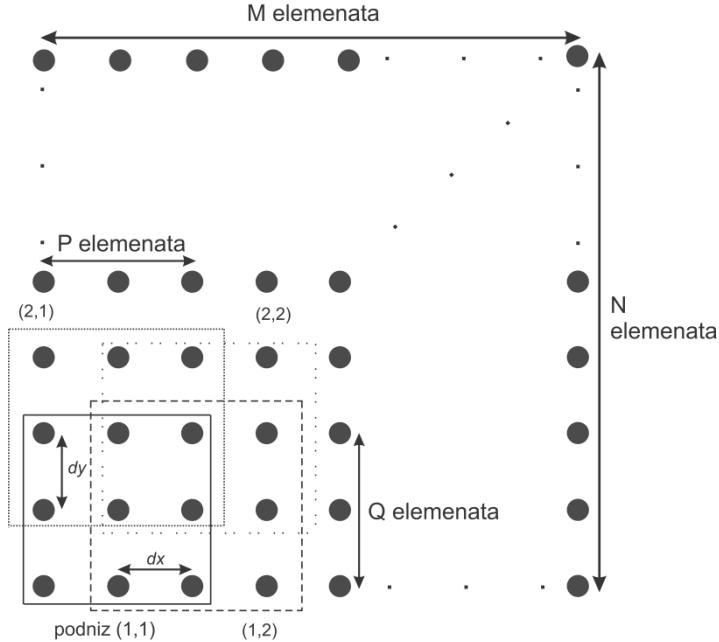
U izrazu (4.9), $\mathbf{c} = [\rho_1 \ \rho_2 \ \dots \ \rho_K]^T$ gde ρ_i , $i=1, 2, \dots, K$, označava relativnu amplitudu i fazu između i -tog i j -tog izvora signala ($\rho_i=1$). Može se zapaziti da je rang podprostora signala matrice \mathbf{R} jednak 1 umesto K , kao i da je podprostor šuma ortogonalan na $\mathbf{A}\mathbf{c}$ umesto na kolone matrice \mathbf{A} , što implicira nemogućnost primene metoda zasnovanih na podprostoru na prostornu kovarijansnu matricu u ovom obliku.

Da bi se rekonstruisao podprostor signala, $M \times N$ pravougaoni antenski niz je podeljen na više međusobno preklapajućih podnizova dimenzija $P \times Q$, (Slika 4.1). Modifikovana kovarijansna matrica \mathbf{R}_{SS} se zatim izračunava usrednjavanjem kovarijansnih matrica koje odgovaraju pojedinačnim podnizovima:

$$\mathbf{R}_{SS} = \frac{1}{P_S Q_S} \sum_{p=1}^{P_S} \sum_{q=1}^{Q_S} \mathbf{R}_{pq} = \mathbf{A}_1 \mathbf{S}_{SS} \mathbf{A}_1^H + \sigma_{\text{sum}}^2 \mathbf{I}, \quad (4.10)$$

gde je:

- $P_s = M - P + 1$, broj podnizova u pravcu x-ose,
- $Q_s = N - Q + 1$, broj podnizova u pravcu y-ose,
- \mathbf{A}_1 - matrica dimenzija $PQ \times K$ (*array manifold*).



Slika 4.1 Primer jednog $M \times N$ pravougaonog antenskog niza podeljenog na određeni broj medusobno preklapajućih $P \times Q$ podnizova

Dimenziije kovarijansne matrice \mathbf{R}_{SS} određene ovim postupkom su smanjene u odnosu na originalnu kovarijansnu matricu \mathbf{R} . Da bi se garantovala detekcija svih prisutnih EM izvora signala pravougaoni antenski niz mora da zadovolji zahteve za minimalnim dimenzijama. U slučaju primene *forward SSP* metoda [56], minimalne dimenziije antenskog niza su $2K \times 2K$ dok je sa *forward-backward SSP* metodom [57]-[58], ovaj uslov nešto poboljšan i iznosi $(3K/2) \times (3K/2)$.

4.4 Primena neuronskih mreža u proceni pravaca EM signala

Kao što je već rečeno u Poglavlju 3, MLP i RBF neuronske mreže su univerzalni aproksimatori koji vrše interpolaciju podataka u višedimenzionalnim prostorima. Kao takve,

one se uspešno primenjuju u mnogim oblastima za rešavanje problema aproksimacije nelinearnih funkcija i klasifikacije podataka. Neuronske mreže mogu da prevaziđu neka ograničenja standardnih algoritama i uspešno modeluju nedovoljno definisane probleme, koji se ne mogu opisati tačnim matematičkim modelima.

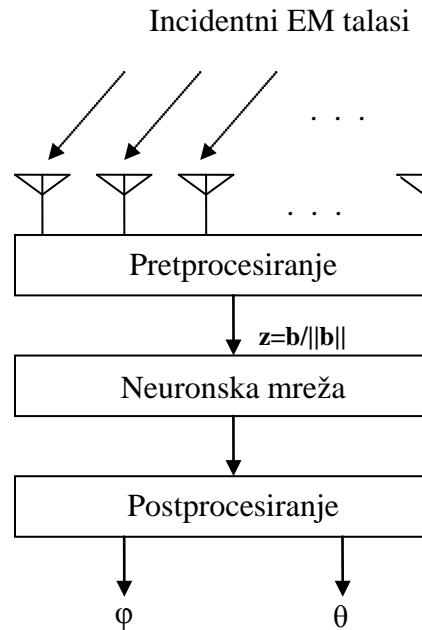
Primena veštačkih neuronskih mreža u oblasti procene pravaca predstavlja alternativu standardnim algoritmima zasnovanim na određivanju podprostora ili parametarskim metodama. Problem procene pravaca se razmatra kao preslikavanje $G': \mathbf{C}^{M \cdot N} \rightarrow \mathbf{R}^K$ iz prostora primljenih signala na elementima antenskog niza $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_{M \cdot N}(t)]^T$ u prostor pravaca EM signala $(\Phi, \Theta) = [(\varphi_1, \theta_1), (\varphi_2, \theta_2), \dots, (\varphi_K, \theta_K)]^T$ [24], [28], [67]. Slično kao kod standardnih algoritama, ulaz u neuronsku mrežu je prostorna kovarijansna matrica a njen izlaz su procenjeni pravci u azimutu i elevaciji. Međutim, način na koji neuronska mreža dobija informacije o pravcima dolaska EM signala suštinski se razlikuje od metoda koji se primenjuju kod standardnih algoritama.

Najpe je potrebno obučiti neuronsku mrežu propuštanjem određenog broja primera ulaz-željeni izlaz, odnosno, prostorna kovarijansna matrica – pravci iz kojih dolaze EM signali. Na osnovu primera, mreža uči zavisnost između ova dva skupa podataka. Znanje se čuva modifikovanjem parametara mreže kao što su veze između neurona i aktivacioni pragovi prenosnih funkcija. Ovako formirana mreža ne vrši dekompoziciju prostorne kovarijansne matrice, ni pretragu spektra. Samim tim, dovođenjem na ulaze neuronske mreže kovarijansne matrice koja nije korišćena u procesu obuke mreže, mreža će zahvajući svojoj paralelnoj strukturi i primeni samo osnovnih matematičkih operacija, dati rezultat u delu sekunde. Mogućnost primene neuronskih mreža u realnom vremenu je njihova osnovna prednost u odnosu na ostale algoritme. U zavisnosti od uslova obuke mreže, njen odziv po preciznosti može nadmašiti rezultate superrezolucijskih algoritama. S obzirom da performanse neuronske mreže nisu toliko zavisne od strukture kovarijansne matrice, one mogu detektovati EM signale čak i kada je njihov broj veći od broja elemenata antenskog niza [24]. Pored toga, karakteristike okruženja se mogu uključiti u proces obuke i na taj način poboljšati tačnost rezultata.

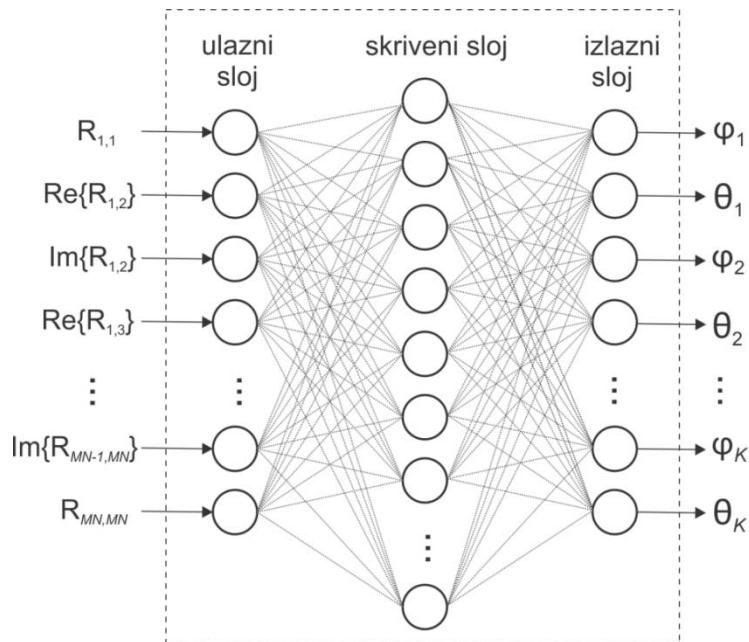
4.4.1 Preprocesiranje podataka

Na ulaz neuronske mreže se dovodi prostorna kovarijansna matrica primljenih signala, \mathbf{R} , dok su odziv mreže pravci dolaska EM signala. Broj neurona u ulaznom sloju

neuronske mreže zavisi od dimenzija matrice \mathbf{R} . U slučaju pravougaonog antenskog niza, radi se o kvadratnoj matrici dimenzija $M \cdot N \times M \cdot N$. Imajući u vidu da neuronske mreže ne rade sa kompleksnim brojevima, elementi matrice su organizovani u jedinstven vektor \mathbf{b} , pri čemu su njihovi realni i imaginarni delovi razdvojeni [16]. Pre nego što se dovede na ulaze neuronske mreže, vektor \mathbf{b} se normalizuje svojom sopstvenom normom, $\mathbf{z} = \mathbf{b}/\|\mathbf{b}\|$, Slika 4.2.



Slika 4.2 Procena pravaca EM signala pomoću neuronske mreže



Slika 4.3 Neuronska mreža za procenu pravaca EM signala u azimutu i elevaciji

U slučaju kada se antenski niz sastoji od identičnih elemenata, kovarijansna matrica je simetrična u odnosu na glavnu dijagonalu. Za procenu pravaca je dovoljno koristiti samo gornji trougaoni deo matrice što znači da ulazni sloj neuronske mreže sadrži ukupno $2(M \cdot N)^2$ neurona, Slika 4.3. Takođe, u slučaju detekcije međusobno nekorelisanih signala dovoljno je uzeti samo elemente prve vrste kovarijanske matrice. Na ovaj način se formira vektor **b** koji sadrži $2(M \cdot N) - 1$ elemenata što odgovara broju neurona u ulaznom sloju neuronske mreže [25]. Primenjujući ovaj postupak, dimenzionalnost ulaznih vektora značajno je smanjena čime se omogućava efikasnija obuka neuronske mreže.

Nakon što neuronska mreža završi nelinearna izračunavanja, izlazni rezultati se postprocesiraju. Pod time se najčešće podrazumeva skaliranje kako bi se rezultati prebacili u opseg od interesa.

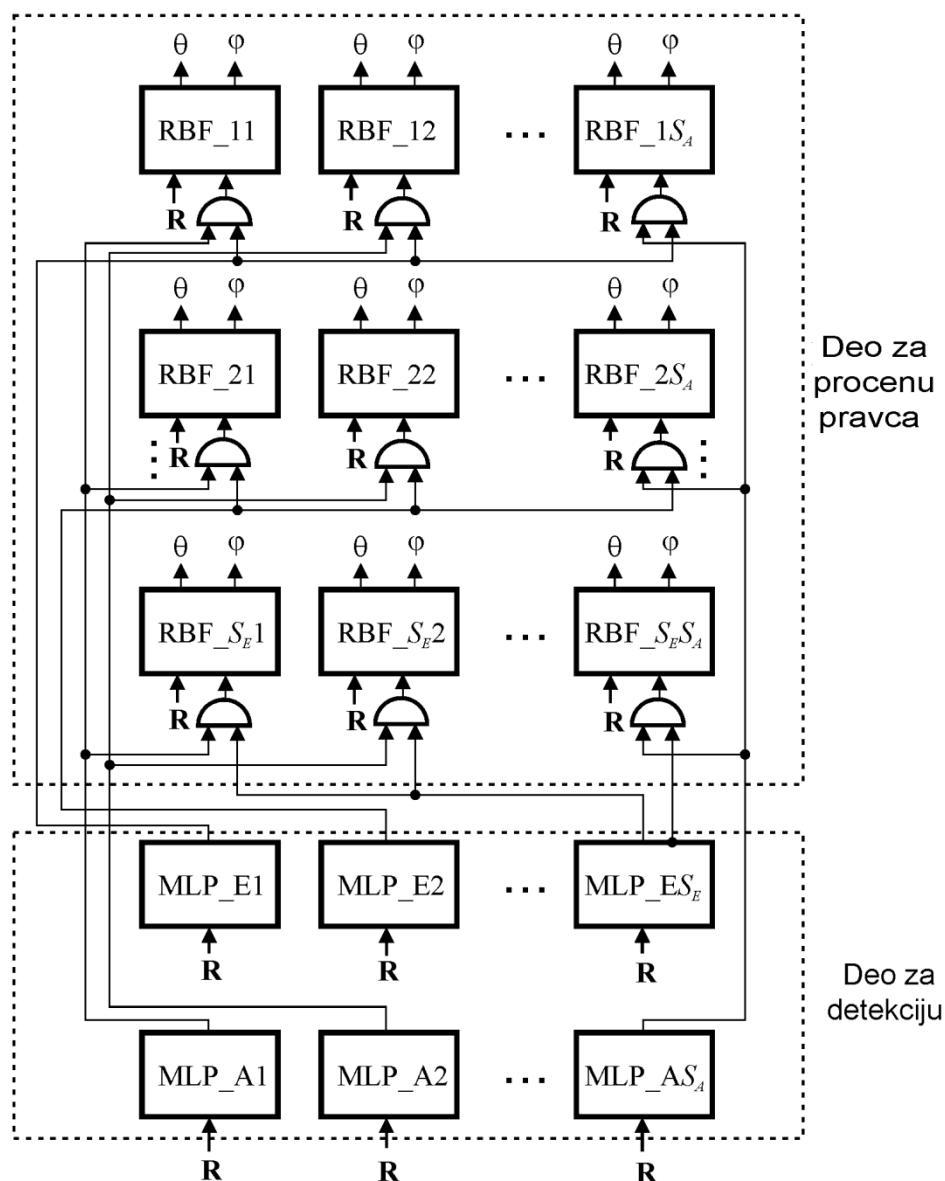
5 Sektorizacioni model za precizno određivanje pravca dolaska EM signala

Za procenu pravca dolaska EM signala u azimutu i elevaciji, na prijemnoj strani se koriste planarni ili trodimenzionalni antenski nizovi. Zbog povećane dimenzionalnosti problema, vremenski zahtevan proces dekompozicije prostorne kovarijanske matrice onemogućava upotrebu standardnih algoritama za procenu pravaca u realnom vremenu. Naime, 2D MUSIC i 2D ESPRIT algoritmi vrše dekompoziciju prostorne kovarijanske matrice, određujući podprostore signala i šuma. Pretraživanjem spektra primljenih signala, 2D MUSIC algoritam daje precizne rezultate po cenu veoma kompleksnih izračunavanja. Sa druge strane, 2D ESPRIT algoritam ima značajnu prednost u odnosu na 2D MUSIC jer ne traži maksimume u spektru. Međutim, modifikacija 1D ESPRIT algoritma za 2D slučaj gde je potrebno proceniti uglove u azimutu i elevaciji, nije trivijalan problem. Jedno od rešenja je dekompozicija problema na dva odvojena jednodimenzionalna problema koji daju dva niza parametara, koje je na kraju potrebno korektno upariti. Predložene su i modifikacije 2D ESPRIT algoritma koje prevazilaze problem uparivanja, odnosno korektnog kombinovanja uglova u azimutu i elevaciji [68]-[69]. Jedan od njih je 2D *Unitary* ESPRIT koji daje automatski uparene uglove u azimutu i elevaciji [70]. Za poboljšanje efikasnosti procene pravaca EM signala u azimutu elevaciji, predložen je propagatorski metod koji vršu samo linearne izračunavanja nad prostornom kovarijansnom matricom [71]. U poređenju sa 2D ESPRIT algoritmom predloženi metod ima bolju brzinu izračunavanja, posebno u slučaju antenskih nizova sa velikim brojem elemenata, ali i manju preciznost određenih pravaca EM signala.

Primena veštačkih neuronskih mreža u oblasti procene pravaca dolaska EM signala, u azimutu i elevaciji, predstavlja alternativu prethodno navedenim algoritmima. Cilj je da se ostvari procena pravaca u realnom vremenu, a da se istovremeno postigne približno ista tačnost kao kod 2D MUSIC algoritma. Veštačke neuronske mreže posmatraju problem procene pravca dolaska EM signala kao preslikavanje između kovarijanske matrice i prostora uglova u azimutu i elevaciji [24]. S obzirom na veoma brzo prostiranje signala kroz neuronske modele, njihova efikasnost u određivanju ugaonih pozicija EM izvora je neuporedivo veća od tehnika zasnovanih na dekompoziciji prostorne kovarijanske matrice i propagatorskog modela [72].

5.1 Osnovni koncept

Koncept sektorizacionog modela za precizno određivanje pravca dolaska EM signala, prikazan je na Slici 5.1. Kao što se može uočiti, model se sastoji od većeg broja manjih neuronskih mreža. Celokupni posmatrani prostor je podeljen na određeni broj sektora pri čemu S_A i S_E označavaju broj sektora u azimutu i elevaciji, respektivno. U prvom delu predloženog modela se detektuje prisustvo izvora signala u sektoru, nakon čega se u drugom delu određuje pravac njegovog dolaska.



Slika 5.1 Koncept sektorizacionog modela za procenu pravca EM signala

MLP mreže u delu za detekciju imaju ulogu klasifikatora. Na ulaz svake MLP mreže dovodi se prostorna kovarijansna matrica \mathbf{R} , pri čemu mreža daje na izlazu nulu ukoliko je izvor signala van posmatranog sektora, i jedinicu ukoliko je izvor signala prisutan u sektoru. Da bi se određivanje pravca učinilo što efikasnijim detekcija prisustva signala se najpre vrši u elevaciji a zatim u azimutu. Odgovarajuću RBF mrežu u delu za procenu pravca dolaska EM signala aktiviraće samo jedinica na izlazu obe MLP mreže (azimut i elevacija) određenog sektora. Na ovaj način, omogućena je detekcija izvora EM signala sa veoma visokom preciznošću.

Za ocenu performansi predloženog sektorizacionog modela izvršene su simulacije u MATLAB-u [73]. U simulacijama su korišćeni sledeći parametri:

- uniformni pravougaoni antenski niz sačinjen od 16 identičnih, omnidirekcionih elemenata,
- rastojanje između susednih elemenata niza $d=\lambda/2$,
- 1024 *snapshota* digitalno modulisanog signala,
- odnos signal/šum $SNR=20$ dB.

5.2 Numerički rezultati

Za razvoj sektorizacionog modela, posmatrani prostor je podeljen na tri sektora u elevaciji ($S_E=3$), od kojih je svaki širok 30° ($[-45^\circ, -15^\circ]$, $[-15^\circ, 15^\circ]$, $[15^\circ, 45^\circ]$), i pet sektora u azimutu ($S_A=5$) ($[-90^\circ, -60^\circ]$, $[-60^\circ, -20^\circ]$, $[-20^\circ, 20^\circ]$, $[40^\circ, 60^\circ]$, $[60^\circ, 90^\circ]$). Procedura za obuku MLP i RBF mreža korišćenih u detekcionom i delu za procenu pravca kreće od formiranja skupova za obuku i testiranje mreža. Najpre su podaci neophodni za obuku MLP neuronskih mreža neuniformno uzorkovani. Imajući u vidu da je najvažnije precizno definisati granice između sektora, finije uzorkovanje je primenjeno u njihovoј blizini dok su grublji podaci uzimani iz delova sektora bliskih centru. Nakon toga se, za izvor signala koji pripada određenom sektoru, koriste precizni i ravnomerno uzeti uzorci za obuku RBF mreža za procenu pravca dolaska EM signala. Sledeći ovu proceduru, formira se nekoliko manjih skupova podataka koji omogućavaju efikasniju obuku MLP i RBF neuronskih mreža.

U detekcionom delu predloženog sektorizacionog modela koriste se MLP neuronske mreže sa dva skrivena sloja. Neuroni u skrivenim slojevima imaju *tan-sigmoidne* prenosne funkcije. Njihov broj nije unapred poznat zbog čega se primenjuje poseban postupak kako bi

se pronašla optimalna mreža. Obično se formiraju neuronski modeli sa manjim brojem skrivenih neurona a zatim se njihov broj postepeno povećava sve dok se ne dobije neuronski model sa dobrom test statistikama. Za obuku MLP mreža u ovom modelu koristi se LM (*Levenberg-Marquardt*) algoritam. Na kraju procesa obuke izdvaja se najbolji model i koristi za dalje simulacije. U Tabeli 5.1, prikazane su test statistike modela za elevacioni sektor $[-15^\circ, 15^\circ]$. MLP neuronska mreža sa 22 neurona u oba skrivena sloja testirana je podacima koji nisu korišćeni u procesu njene obuke. Odziv mreže je ilustrovan na Slici 4(a). U Tabeli 5.2, date su performanse najboljih MLP mreža, obučenih za detekciju izvora signala u azimutnom sektoru $[-20^\circ, 20^\circ]$. MLP_2-22-22 mreža je simulirana za test podatke i njen odziv je prikazan na Slici 4(b). Vreme za obuku mreža u elevacionom sektoru je 17s, odnosno, 10s za mreže u azimutnom sektoru (Intel(R) Core(TM)2 Quad CPU računar sa 8 GB RAM memorije).

Tabela 5.1 *Test statistika MLP neuronske mreže za elevacioni (E) sektor $[-15^\circ, 15^\circ]$*

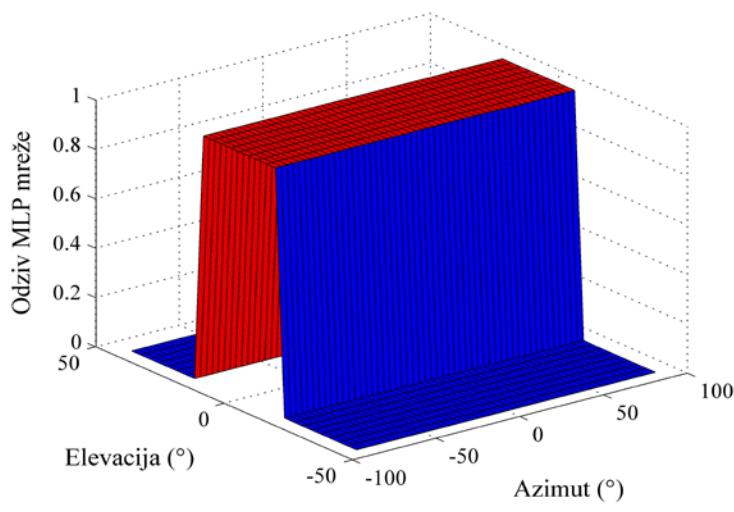
MLP neuronski model	WCE [%]	ACE [%]	<i>r</i>
MLP_E-22-22	2.3362	0.1370	1.0000
MLP_E-12-11	2.3628	0.0634	1.0000
MLP_E-14-11	2.8050	0.0658	1.0000
MLP_E-16-16	2.9050	0.3598	1.0000
MLP_E-30-16	3.1683	0.1777	1.0000

Tabela 5.2 *Test statistika MLP neuronske mreže za azimutni (A) sektor $[-20^\circ, 20^\circ]$*

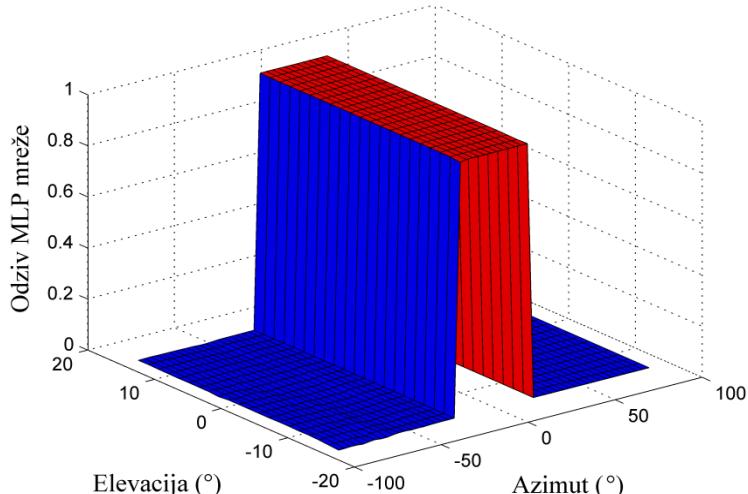
MLP neuronski model	WCE [%]	ACE [%]	<i>r</i>
MLP_A-22-22	1.7102	0.1359	1.0000
MLP_A-20-20	2.5157	0.0365	1.0000
MLP_A-14-11	3.1012	0.0657	1.0000
MLP_A-16-12	3.5327	0.0490	1.0000
MLP_A-18-18	3.8951	0.2885	0.9999

Tabela 5.3 *Test statistika RBF neuronske mreže*

RBF neuronski model	WCE [%]	ACE [%]	r
RBF_1 (<i>spread</i> 1.95)	2.7997	0.3341	0.9999
RBF_2 (<i>spread</i> 1.15)	2.9638	0.3498	0.9999
RBF_3 (<i>spread</i> 2.00)	3.0541	0.3600	0.9998
RBF_4 (<i>spread</i> 1.45)	4.8670	0.3617	0.9998
RBF_5 (<i>spread</i> 1.70)	2.6690	0.3752	0.9998



(a)

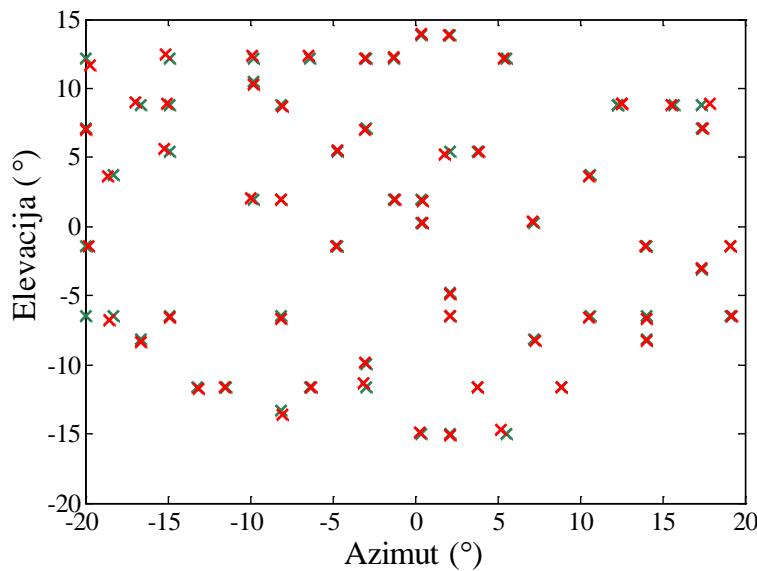


(b)

Slika 5.2 *Odziv MLP neuronske mreže u (a) elevacionom sektoru, (b) azimutnom sektoru*

Podaci za obuku RBF neuronskih mreža uzorkovani su veoma precizno u koracima od 0.5° u azimutu i elevaciji kako bi se povećala tačnost procenjenih pravaca. Samim tim, skup za obuku jedne RBF mreže u sektorizacionom modelu sadrži 4941 uzoraka [74]. Poređenja radi, ukoliko se samo jedna RBF mreža koristi u delu za procenu pravca signala, skup za njenu obuku sadrži znatno veći broj uzoraka (65341), [75].

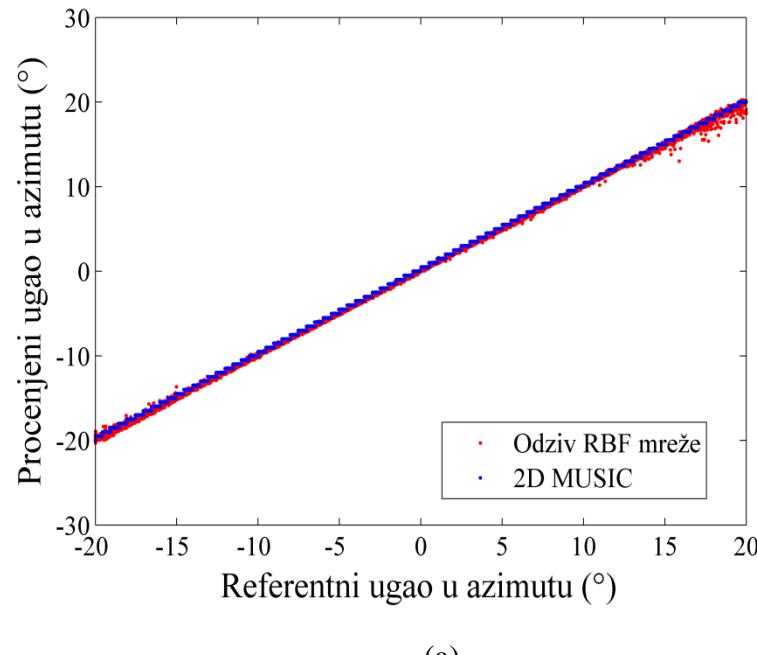
Za obuku RBF mreža u predloženom modelu koristi se OLS algoritam [59], [73]. Proces obuke jedne RBF neuronske mreže odvija se postepeno, dodavanjem po jednog neurona u skriveni sloj mreže po svakoj iteraciji sve dok se ne ispuni predefinisani uslov za grešku odziva mreže (MSE, *Mean Squared Error*) ili maksimalan broj neurona u skrivenom sloju. Na kraju obuke, RBF mreža sa najboljom test statistikom (WCE=2.7997 %, ACE=0.3341 %, r=0.9999), izdvaja se i primenjuje u daljoj analizi (Tabela 5.3). Skriveni sloj odabrane mreže sadrži 81 neuron sa *Gaussovom* prenosnom funkcijom. Vreme za obuku jedne ovakve mreže u delu za procenu pravca signala iznosi oko 1 min.



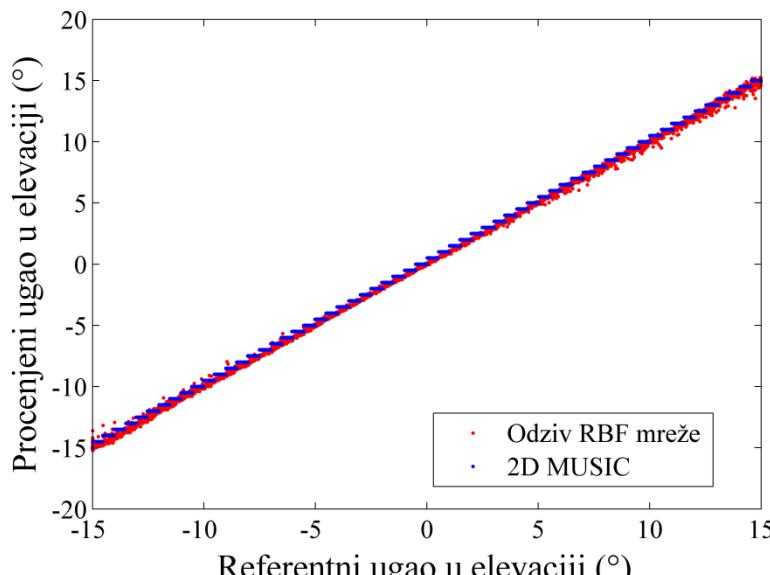
Slika 5.3 Rezultati sektorizacionog modela za test podatke (\times – odziv sektorizacionog modela, $\textcolor{green}{\times}$ – referentne pozicije izvora)

Kao što je prikazano na Slici 5.3, ugaone pozicije EM izvora procenjene RBF neuronskom mrežom u velikoj meri se poklapaju sa referentnim vrednostima čime su potvrđene dobre performanse predloženog modela. Na Slikama 5.4(a) i 5.4(b), izvršeno je poređenje rezultata sektorizacionog modela i 2D MUSIC algoritma rezolucije 0.5° . Rezultati su dobijeni slučajnim izborom pozicija izvora signala u azimutu i elevaciji. Na osnovu

prikazanog, može se zaključiti da su performanse predloženog sektorizacionog modela uporedive sa 2D MUSIC algoritmom. Međutim, veliku prednost sektorizacionog modela predstavlja brzina procene pravca – sektorizacioni model daje pozicije u azimutu i elevaciji za svega nekoliko milisekundi dok je 2D MUSIC algoritmu za pretragu spektra i pronalaženje maksimuma potrebno oko 20 s (Intel(R) Core(TM)2 Quad CPU računar sa 8 GB RAM memorije).



(a)



(b)

Slika 5.4 Korelacioni dijagram sektorizacionog modela i 2D MUSIC algoritma za uglove u (a) azimutu, (b) elevaciji

Ključna prednost prikazanog sektorizacionog modela u odnosu na super-rezolucijski 2D MUSIC algoritam je njegova efikasnost u proceni ugaonih pozicija EM izvora. Zaobilaženjem složenih matričnih izračunavanja, predloženi model je znatno pogodniji za primenu u realnom vremenu. S obzirom da su za mreže u detekcionom i delu za procenu pravca upotrebljeni različiti skupovi za obuku, drastično je smanjeno vreme za obuku pojedinačnih manjih mreža, a time i vreme za razvoj celokupnog modela.

6 Empirijski neuronski model za određivanje pravca dolaska EM signala

Najveći broj algoritama za procenu pravca iz kog dolazi EM signal podrazumeva idealno okruženje za prostiranje EM talasa. Pored toga, smatra se da je prijemni antenski niz sačinjen od idealnih izotropnih antenskih elemenata koji su precizno raspoređeni u određenim intervalima. Primena standardnih algoritama u realnim scenarijima najčešće rezultuje greškama u proceni pravca zbog čega se zahtevaju dodatne kalibracione procedure. Greške su uzrokovane realnim uslovima kao što su nesavršenosti u izradi antenskog niza, elektromagnetna sprege između antenskih elemenata, refleksije u kablovima i konektorima za napajanje, rasejanje EM signala od same antenske strukture ili obližnjih objekata. Svi ovi efekti mogu biti vremenski i frekvencijski promenljivi što dodatno otežava procenu pravca. Posledica toga je narušavanje strukture prostorne kovarijansne matrice, a samim tim i procesa određivanja sopstvenih vektora i sopstvenih vrednosti na kom su zasnovani standardni algoritmi (MUSIC, ESPRIT). Iz tog razloga je kod praktične primene algoritama za procenu pravaca EM signala obavezna kalibracija antenskog niza kako bi se smanjili efekti elektromagnetne sprege između elemenata. Najpoznatiji metod za kalibraciju koristi međusobne impedanse između antenskih elemenata za karakterizaciju elektromagnetne sprege, i nalazi primenu kod predajnih i prijemnih antenskih nizova [76]-[79].

Sa druge strane, moguće je razviti neuronske mreže za procenu pravca EM signala koje daju precizne rezultate u realnom okruženju, bez kalibracije. U ovom slučaju je znanje o okruženju i osobinama merne opreme sačuvano u samoj strukturi neuronskog modela prilikom procesa obuke. Pored efikasnosti neuronskih mreža u samom postupku procene pravca, postiže se dodatna ušteda vremena jer nije potrebno vršiti kalibraciju antenskog niza, odnosno meriti međusobne impedanse antenskih elemenata.

Pristup koji koristi MLP neuronske mreže za procenu pravca i podatke o amplitudama signala sa prijemnog L-niza, prikazan je i eksperimentalno verifikovan u [80]. U literaturi je dat i metod za procenu pravca u polusfernem prostoru, zasnovan na RBF neuronskim mrežama i kružno polarizovanim *patch* antenama, raspoređenim u koncentričnim krugovima oko elementa za napajanje, [81]. Razvoj i verifikacija empirijskog neuronskog modela, zasnovanog na RBF neuronskoj mreži i kružnom antenskom nizu, za procenu pravca EM signala u azimutu prikazani su u [82]. Efikasnost neuronskih modela proizilazi iz činjenice da se nakon procesa obuke, pravci dolaska EM signala određuju uz mnogo manje memorijске

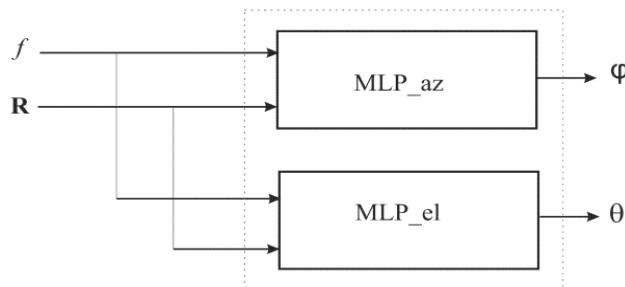
zahteve s obzirom da se ne vrši pretraga spektra u azimutu, odnosno, u azimutu i elevaciji.

U tekstu koji sledi, dat je razvoj i verifikacija empirijskog neuronskog modela za procenu pravaca u azimutu i elevaciji primenom pravougaonog antenskog niza. Takođe je dat opis opreme i merne procedure za dobijanje podataka za obuku i testiranje neuronskog modela. Krajnji cilj obuke neuronskog modela je prevazilaženje nedostataka matematičkih modela usled neslaganja između pretpostavljenih i realnih uslova okruženja.

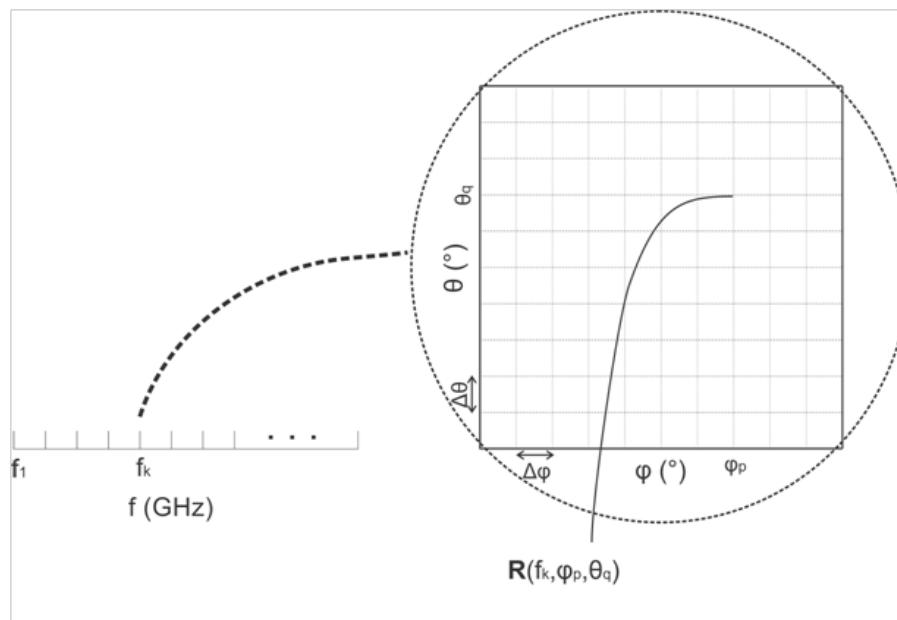
6.1 Osnovni koncept

Na Slici 6.1, prikazan je empirijski neuronski model za efikasno određivanje ugaonih pozicija EM izvora u realnim uslovima. Radi postizanja bolje tačnosti, procena pravaca u azimutu i elevaciji vrši se pomoću dve odvojene neuronske mreže. Predviđeno je da neuronski model daje precizne rezultate u odredenom frekvencijskom opsegu. Za razvoj neuronskog modela koriste se mereni podaci dobijeni u prostorno-frekvencijskom domenu. Ulaz u neuronski model su vrednosti frekvencije i odgovarajuća prostorna kovarijansna matrica dok su na izlazu ugaone pozicije EM izvora u azimutu i elevaciji. Tokom procesa obuke, potrebno je razviti neuronski model koji korektno preslikava zavisnost između skupa frekvencijski zavisnih kovarijansnih matrica i skupa uglova u azimutu i elevaciji. Za razliku od 2D MUSIC algoritma, predloženi model uzima u obzir efekte međusobne elektromagnetne sprege između antenskih elemenata, nesavršenosti u izradi antenskog niza i uslove okruženja. Od ovako obučenog neuronskog modela se očekuje precizna procena pravca čak i u uslovima frekvencijski zavisne EM sprege između antenskih elemenata.

Na Slici 6.2, ilustrovana je struktura podataka za obuku i testiranje neuronskog modela. Mereni podaci su dobijeni pomoću pravougaonog antenskog niza sastavljenog od 16 elemenata. Za svaku poziciju izvora signala u posmatranom prostoru (ϕ, θ) i određeni broj frekvencija, procenjena je prostorno-frekvencijska kovarijansna matrica \mathbf{R} .



Slika 6.1 Koncept empirijskog neuronskog modela

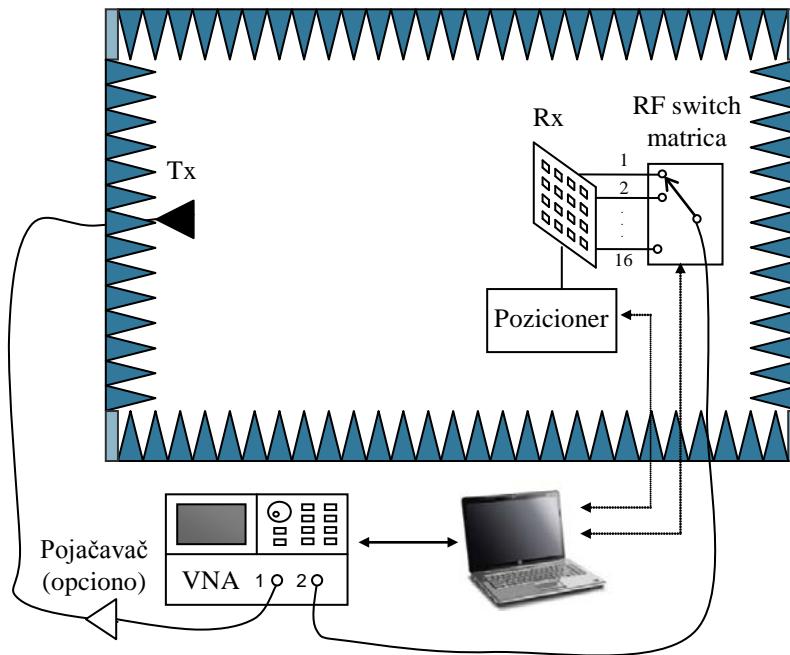


Slika 6.2 *Ilustracija strukture podataka za obuku neuronskog modela*

6.2 Postavka mernog sistema u anehoičnoj komori

Sva merenja neophodna za prikupljanje podataka za razvoj i procenu performansi predloženog empirijskog neuronskog modela izvršena su u anehoičnoj komori dimenzija $7.44 \times 4.97 \times 4.69$ m. Anehoična komora je obložena mikrotalasnim piramidalnim apsorberom visine 0.46 m i pogodna je za izvođenje različitih merenja kao što je snimanje karakteristike zračenja antena i merenje radarskog preseka (RCS, *Radar Cross Section*) u frekvencijskom opsegu od 2 - 40 GHz. S obzirom da u anehoičnoj komori ne postoji mogućnost generisanja signala usled višestrukog prostiranja, razmatra se samo direktni signal između predajne T_x i prijemne R_x antene, Slika 6.3.

Merni sistem je zasnovan na klasičnoj tehnici koja koristi vektorski analizator mreže (VNA, *Vector Network Analyzer*). U ovom slučaju se pomoću VNA meri parametar rasejanja S_{21} , odnosno kompleksni frekvencijski odziv uspostavljenog radio kanala između dve antene.



Slika 6.3 Ilustracija mernog sistema u anehoičnoj komori

Mernu opremu za izvođenje merenja u anehoičnoj komori čine sledeći instrumenti, Slika 6.4:

- 1) Signal generator HP 83650B (10 MHz – 50 GHz),
- 2) Pretvarač frekvencije HP 8511A Opt. H41 (40 GHz),
- 3) Vektorski analizator mreže HP 8530A,
- 4) Pojačavač HP 83018A (2 – 26.5 GHz),
- 5) Pozicioner Orbit AL 4906-3A,

i pasivna komponenta:

- 6) 16 dB sprežnik (2 – 50 GHz).

Frekvencijska ograničenja mernih instrumenata su sledeća:

- pojačavač i sprežnik se koriste za $f > 1$ GHz,
- nema pojačavača za 26.5 GHz.

A. Standardna procedura za merenje karakteristika antena

Antena koja se ispituje radi u prijemnom režimu, dok je predajna antena jedna od referentnih antena sa poznatim pojačanjem i karakteristikom zračenja.

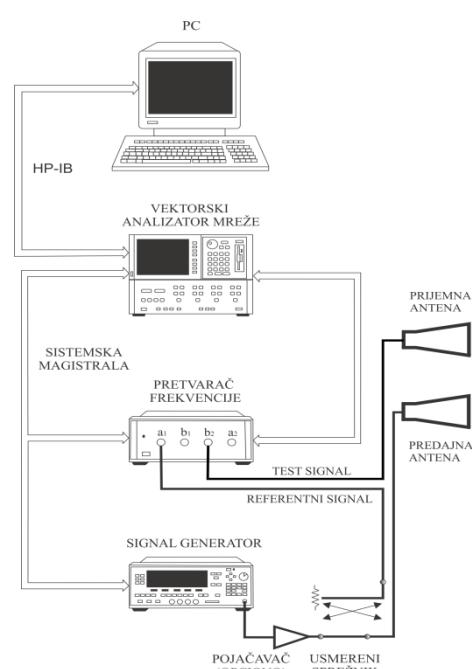
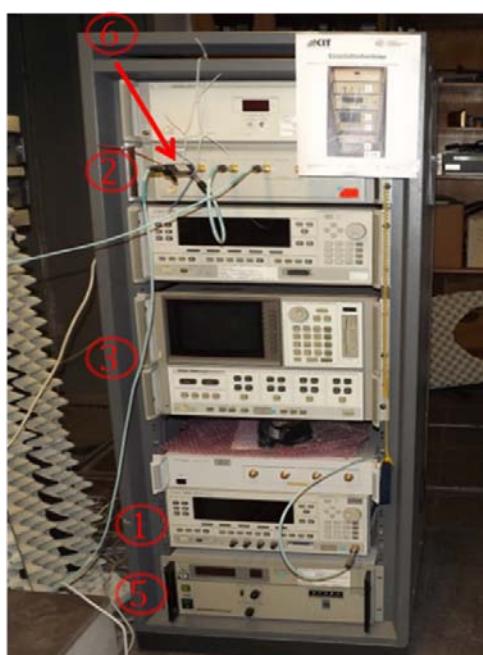
a) Kalibracija sistema

Za merenja u anehoičnoj komori se koristi softver razvijen u MATLAB-u, SPAM 3D (*S-Parameter and Amplitude Measurement 3D*), gde na raspolaganju stoji procedura za merenja u frekvencijskom domenu. Prvi korak pri snimanju karakteristike zračenja antene ili S-parametara je kalibracija sistema. Kalibracija je neophodna kako bi se uklonile greške koje unosi sam izvor signala, odnosno, kako bi se eliminisali bilo koji frekvencijski zavisni efekti mernog sistema kao što su refleksije u kablovima i konektorima. Tačnost kalibracionog procesa efikasno postavlja dinamički opseg mernog sistema.

Za merenje transmisije, kao što je slučaj sa karakterizacijom radio kanala, koristi se “*response*” kalibracija. Prenosna funkcija S_{21} celokupnog sistema se meri u anehoičnoj komori sa referentnim antenama na predaji i prijemu. Pre početka merenja kalibracionih podataka potrebno je uraditi sledeće:

- uneti radne frekvencijske opsege referentnih antena kao i ukupan broj frekvencijskih tačaka,
- učitati vrednosti pojačanja antena u svim frekvencijskim tačkama,
- postaviti pozicioner u položaj $(\varphi, \theta)=(0, 0)$, tako da su antene postavljene tačno jedna naspram druge.

Nakon toga, pokreće se kalibracija čiji se rezultati automatski upisuju u određeni .mat fajl.



Slika 6.4 Fotografija i blok-šema sistema za merenja u anehoičnoj komori

b) Merenje karakteristike antene

Prilikom merenja karakteristike antene, na mesto prijemne antene montira se test antena (antena koja se ispituje). Pre početka samog postupka merenja, potrebno je odrediti fazni centar antene pomoću VNA i montirati je iznad njega. Nakon toga se vrši odabir vrste merenja – S parametara ili karakteristike zračenja antene. Sledi podešavanje frekvencijskog opsega, rezolucije merenja, opsega uglova u azimutu i elevaciji, nakon čega se bira kalibracioni set za kalibraciju merenja. Na kraju merenja, pojavljuje se opcija za čuvanje podataka u željenom fajlu.

c) Modifikovana procedura za merenje primljenih signala na antenskim nizovima

U odnosu na merenje karakteristike jedne antene, za merenje antenskih nizova je potrebno izvršiti određene izmene u mernoj postavci kao i softveru za akviziciju podataka. Razlika u odnosu na osnovni merni sistem je u RF switch matrici koja se sastoji od:

- kućišta NI PXI-1033,
- PXI kontrolera PXI-PCIe8361,
- pet RF multiplekserskih kartica PXI-2594.

Matrica ovog tipa je pogodna za merenja u frekvencijskom opsegu od 1 – 2.5 GHz. Ulazi RF switch matrice su povezani sa svim antenskim elementima prijemnog antenskog niza, pri čemu se antenski elementi switchuju jedan za drugim.

Za automatizaciju procesa merenja, kontrolu VNA, pozicionera u anehoičnoj komori i RF switch matrice, softver SPAM 3D je modifikovan tako da uključuje funkciju RF switch matrice. U program *Measurement & Automation Explorer* (MAX) [83], definisana je konfiguracija ulaznih i izlaznih kanala matrice. Kodovi za kontrolu matrice, odnosno biranje odgovarajućeg kanala, napisan je u programskom jeziku C, nakon čega su formirane *dll* biblioteke koje se učitavaju iz MATLAB-a pozivom odgovarajuće funkcije. U kodovima se može definisati koji se antenski elementi switchuju i kojim redosledom.

B. Opis mernog postupka za snimanje S_{21} parametra

Na jednoj strani anehoične komore je postavljena levak antena koja radi u predajnom režimu i emituje signal na centralnoj frekvenciji $f_c=2.44$ GHz, Slika 6.5. Na drugoj strani je montiran 4×4 pravougaoni antenski niz, realizovan pomoću *microstrip patch* elemenata,

Slika 6.6. Elementi antenskog niza su ravnomerno raspoređeni u intervalima jednakim polovini talasne dužine incidentnih EM talasa. Dimenzije antenskih elemenata su optimizovane u 3D EM simulatoru CST *Microwave Studio*, ($L=39.6$ mm, $W=49.4$ mm) i praktično realizovane na *Duroid Rogers RT5880* supstratu dielektrične konstante $\epsilon_r=2.2$ i debljine $t=1.57$ mm. Jedan izolovani antenski element ima rezonantnu frekvenciju na 2.44 GHz sa impedansnim (10 dB) opsegom od oko 60 MHz. Izmereni S_{11} parametar jednog antenskog elementa je -37 dB, trodecibelska širina glavnog lista zračenja (HPBW, *Half Power Beamwidth*) 82.5° i pojačanje 6.7 dBi na rezonantnoj frekvenciji [84], [85].

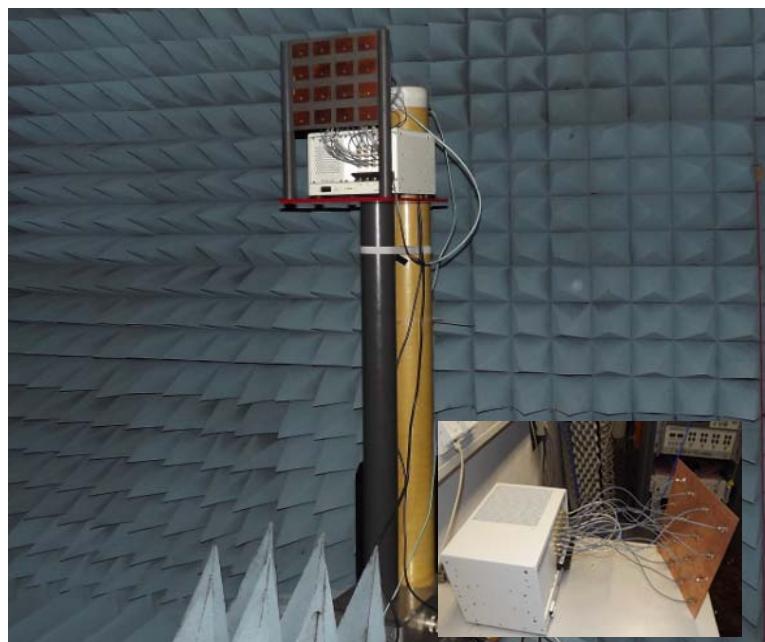
Levak antena i antenski niz su postavljeni na istoj visini ($H=1.9$ m), na međusobnom rastojanju $R=5.1$ m, čime je obezbeđeno da se antenski niz nalazi u dalekoj zoni zračenja levak antene, Slika 6.3.

Za merenje prenosne funkcije uspostavljenog radio kanala između dve antene koristi se sistem prikazan na Slici 6.4. Za uzorkovanje primljenih signala na svakom elementu antenskog niza upotrebljen je RF switch. Naime, RF switch matrica je postavljena neposredno iza antenskog niza tako da je svaki antenski element povezan sa jednim od 16 ulaza matrice preko 40 cm dugačkog koaksijalnog kabla. Na ovaj način je u jednom trenutku aktivan samo jedan antenski element dok se ostali ponašaju kao parazitski. Međutim, zbog međusobne elektromagnetne sprege između antenskih elemenata i ovi elementi će u nekoj meri zračiti.

Nakon konfigurisanja mernog sistema, mogu se započeti merenja u anehoičnoj komori. Na početku se vrši kalibracija automatizovanog mernog sistema. Kalibracioni podaci se čuvaju odvojeno od merenih podataka i koriste se kasnije u procesu postprocesiranja. Primljeni podaci na antenskom nizu su uzorkovani za nekoliko vrednosti frekvencija pri čemu su sačuvana po 2 snapshota (snapshot – uzorkovanje primljenih signala na svim elementima antenskog niza u jednom prolazu), za svaki položaj predajne antene. Mereni rezultati su usrednjeni kod VNA 16 puta. Softver za merenja u anehoičnoj komori je modifikovan kako bi se RF switch matrica integrisala u postojeći sistem. Nakon toga, merni sistem je u stanju da radi automatizovano i prikuplja podatke.

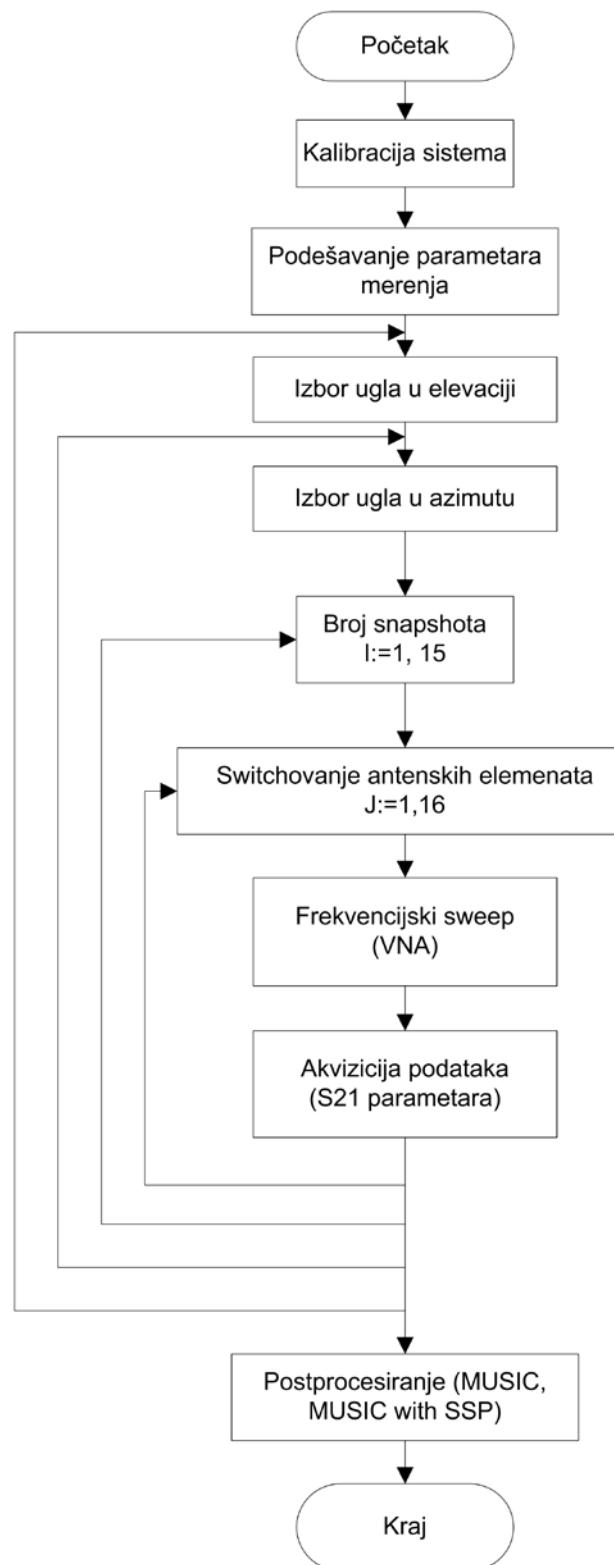


Slika 6.5 *Predajna levak antena*



Slika 6.6 *Pravougaoni antenski niz na antenskom tornju*

Različite pozicije u azimutu su ostvarene rotacijom antenskog tornja u opsegu $[-45^\circ, 45^\circ]$, sa najmanjim korakom $\Delta\phi=1^\circ$. Promena ugla u elevaciji je izvršena promenom visine predajne levak antene ($\Delta H=10$ cm). Na ovaj način su dobijeni mereni podaci ($S_{21}=b_2/a_1$) za ukupno 19 elevaciona ugla u oblasti $[-10^\circ, 10^\circ]$ i sačuvani za dalju obradu. Odgovarajući dijagram toka merenja je prikazan na Slici 6.7.



Slika 6.7 Dijagram toka merenja

6.3 Rezultati

Za obuku i testiranje neuronskog modela sa Slike 6.1, formirani su odgovarajući skupovi podataka korišćenjem prethodno opisane merne procedure. Skup za obuku sadrži ukupno 7905 uzoraka za 31 ugao u azimutu od - 45° do 45° ($\Delta\phi=3^\circ$), 15 uglova u elevaciji (0, ± 1.12 , ± 3.36 , ± 4.48 , ± 5.6 , ± 7.81 , ± 8.92 , ± 10), i 17 frekvencijskih tačaka od 2.4100 GHz do 2.4700 GHz ($\Delta f=3.6$ MHz). Sa druge strane, skup za testiranje sadrži 868 uzoraka, uključujući 31 ugao u azimutu od - 45° do 45° ($\Delta\phi=3^\circ$), 4 ugla u elevaciji (± 2.25 , ± 6.71), i 7 frekvencijskih tačaka. Na ovaj način je obezbeđeno da skupovi za obuku i testiranje neuronskog modela budu potpuno odvojeni, tj. da nema uzoraka koji pripadaju i jednom i drugom skupu.

Za neuronski model sa Slike 6.1, odabrane su MLP neuronske mreže sa po dva skrivena sloja i *tan-sigmoidnim* neuronima u njima. MLP mreže se obučavaju LM (*Levenberg-Marquardth*) algoritmom. Na ovaj način se formira veći broj MLP mreža, posebno za azimut i elevaciju, sa različitim brojem neurona u skrivenim slojevima. Krajnji cilj učenja je formiranje optimalne neuronske mreže, sa minimalnom greškom na test skupu.

U Tabeli 6.1, prikazana je test statistika nekoliko obučenih modela, gde MLP-az_H1-H2 označava MLP neuronsku mrežu za određivanje pravca u azimutu, koja sadrži $H1$ i $H2$ neurona u prvom i drugom skrivenom sloju, respektivno. MLP-el_H1-H2 označava MLP neuronsku mrežu za određivanje pravca u elevaciji, gde $H1$ i $H2$ takođe predstavljaju broj neurona u skrivenim slojevima mreže. Neuronske mreže sa najboljim test statistikama, MLP_az-20-12 za azimut i MLP_el-16-12 za elevaciju, odabrane su za dalju analizu. Odgovarajući korelacioni koeficijent za MLP_az-20-12 iznosi 0.9997, pri čemu mreža sadrži 20 i 12 neurona u skrivenim slojevima. Za procenu pravca u elevaciji, odabrana je mreža MLP_el-16-12 sa korelacionim koeficijentom 0.9987. U dva skrivena sloja, ova mreža sadrži 16 i 12 neurona, respektivno.

Odziv neuronskog modela za procenu pravaca u azimutu i elevaciji prikazan je na Slikama 6.8, 6.9 i 6.10. Korelacioni dijagrami su generisani za test podatke i ilustruju generalizacione sposobnosti neuronskog modela. Na slikama su dati rezultati za tri test frekvencije $f=2.4220$ GHz, $f=2.4400$ GHz i $f=2.4700$ GHz, pri čemu je sivim tačkama označen odziv neuronskog modela a crnim tačkama rezultati dobijeni pomoću 2D MUSIC algoritma. Na osnovu ovih grafika se može zaključiti da neuronski model demonstrira bolje performanse od 2D MUSIC u pogledu tačnosti procenjenih pravaca u azimutu i elevaciji.

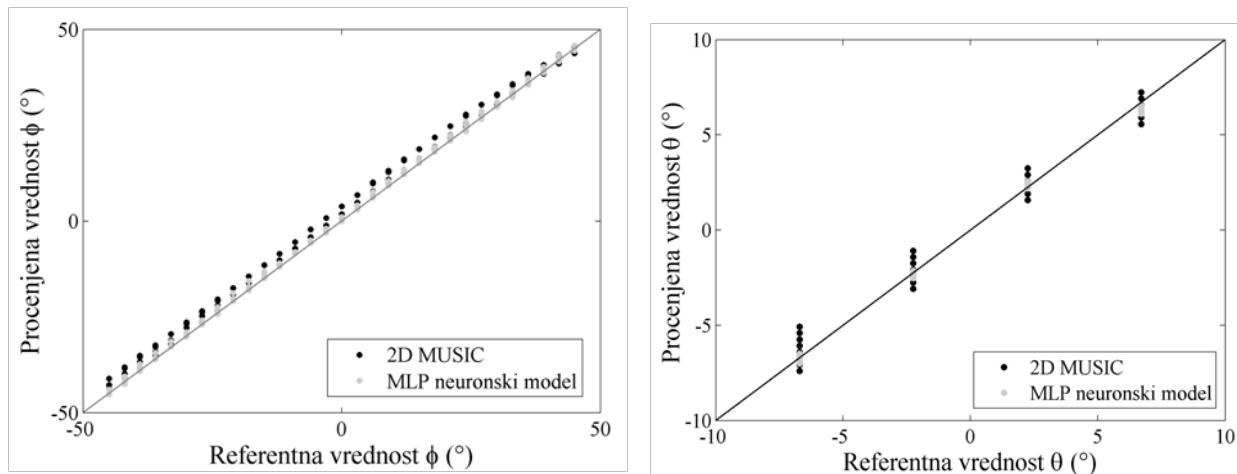
Tabela 6.1 *Test statistika MLP neuronskih mreža za procenu pravaca u azimutu i elevaciji*

MLP_az				MLP_el			
Neuronska mreža	WCE (%)	ACE (%)	r	Neuronska mreža	WCE (%)	ACE (%)	R
MLP_az-20-12	2.9848	0.8458	0.9997	MLP_el-16-12	6.3149	1.6078	0.9987
MLP_az-25-15	3.0561	0.8725	0.9997	MLP_el-21-17	6.4592	1.7025	0.9985
MLP_az-25-25	3.5554	0.9700	0.9997	MLP_el-12-10	7.3799	1.8137	0.9984
MLP_az-22-18	3.8451	0.8244	0.9997	MLP_el-22-18	7.1875	1.8197	0.9983
MLP_az-36-16	4.0394	0.8831	0.9997	MLP_el-40-18	8.1340	1.8481	0.9983
MLP_az-19-17	5.3236	1.0067	0.9996	MLP_el-20-12	8.0346	1.8645	0.9982

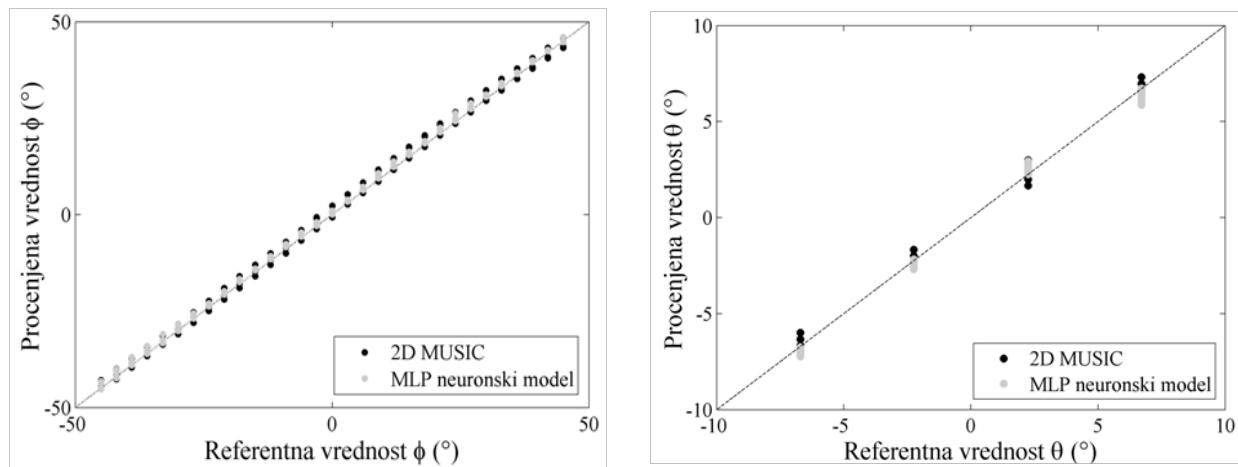
Tabela 6.2 *Prosečna greška u određivanju pravca signala predajne antene korišćenjem MLP neuronskog modela i 2D MUSIC algoritma*

f (GHz)	MLP neuronski model		2D MUSIC	
	$\Phi_{\text{prosečna_greška}}$ (°)	$\theta_{\text{prosečna_greška}}$ (°)	$\Phi_{\text{prosečna_greška}}$ (°)	$\theta_{\text{prosečna_greška}}$ (°)
2.4112	0.7319	0.1942	3.7116	2.5406
2.4220	0.7019	0.1897	3.1604	2.2316
2.4304	0.7526	0.2149	2.2304	1.1860
2.4400	0.8274	0.2470	1.5511	1.0840
2.4508	0.8424	0.2301	1.7275	0.9740
2.4604	0.7536	0.2145	1.8697	1.6289
2.4700	0.7186	0.2200	2.1597	2.6233

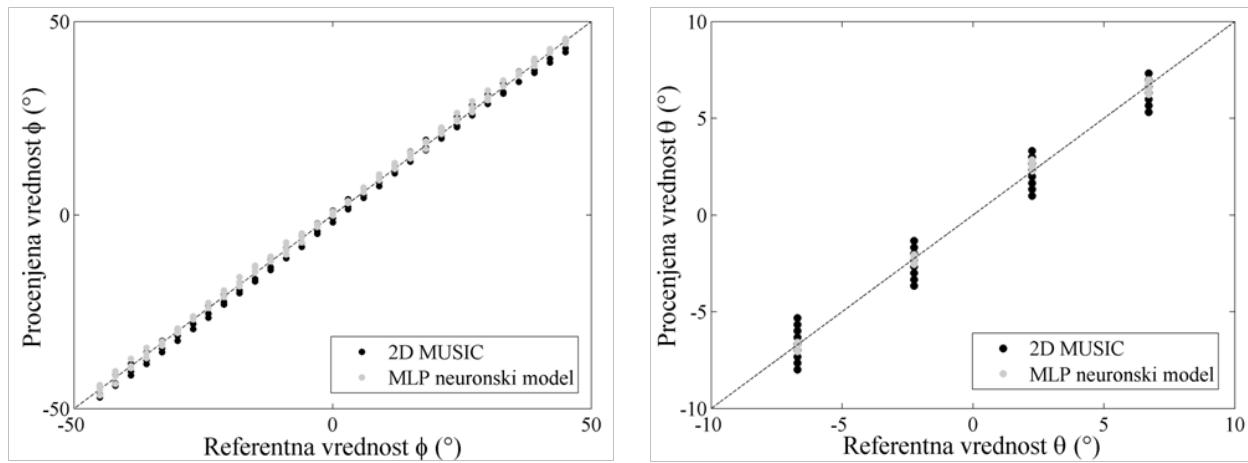
Može se zapaziti da neuronski model daje bolje rezultate u proceni elevacionih uglova, posebno na graničnim frekvencijama radnog opsega. Dobri rezultati neuronskog modela posledica su njegove sposobnosti da pri proceni pravaca uzme u obzir realne uslove merenja kao što su nesavršenosti merne opreme i prisustvo sistemskih grešaka. Samim tim, logično je očekivati dobro slaganje odziva neuronskog modela i referentnih vrednosti sa “već poznatim” mernim sistemom (Tabela 6.2).



Slika 6.8 Dijagrami rasejanja MLP neuronskog modela i 2D MUSIC algoritma na test frekvenciji $f=2.4220 \text{ GHz}$



Slika 6.9 Dijagrami rasejanja MLP neuronskog modela i 2D MUSIC algoritma na test frekvenciji $f=2.4400 \text{ GHz}$

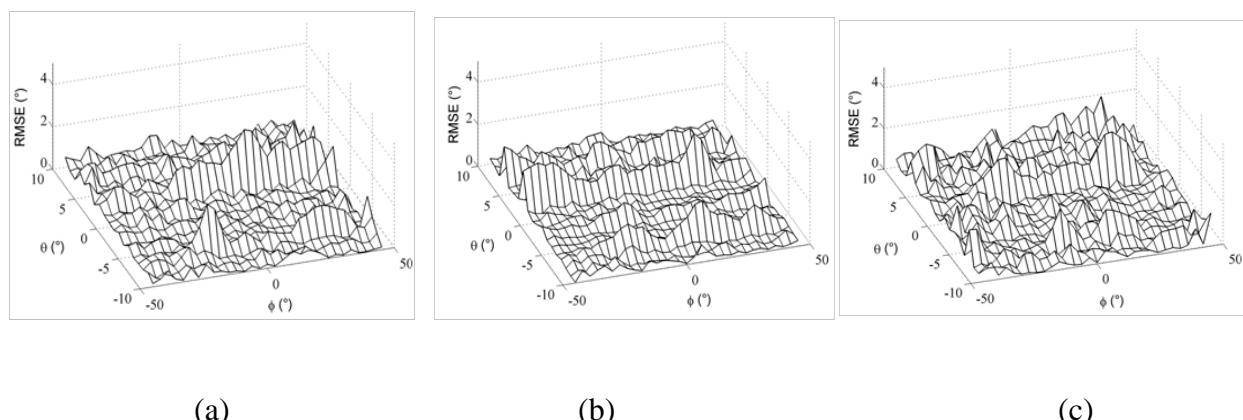


Slika 6.10 Dijagrami rasejanja MLP neuronskog modela i 2D MUSIC algoritma na test frekvenciji $f=2.4700 \text{ GHz}$

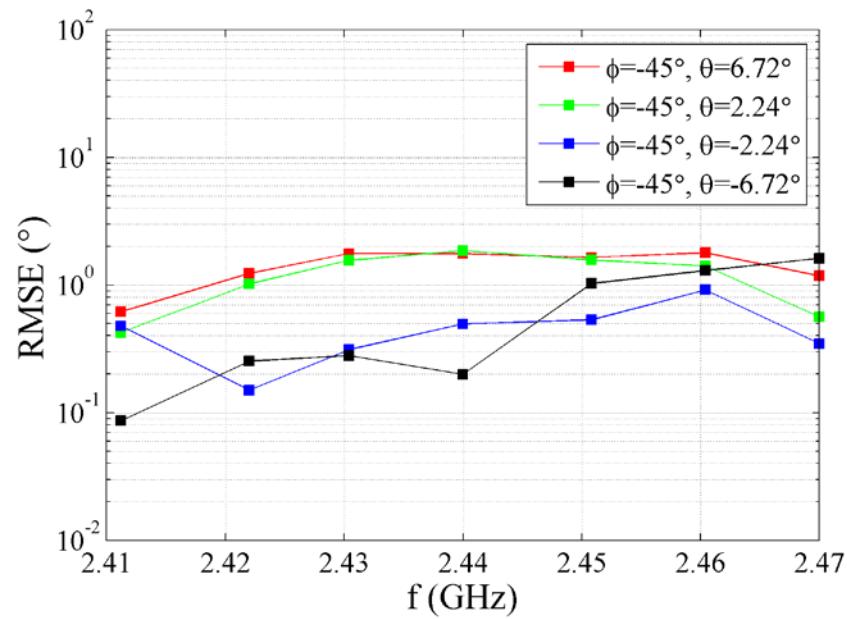
Na Slici 6.11, prikazan je koren srednje kvadratne greške (RMSE, *Root Mean Square Error*) procenjenih pravaca za nekoliko frekvencijskih tačaka i za sve ugaone pozicije EM izvora iz skupa za obuku i testiranje neuronskog modela. Vrednosti RMSE su izračunate primenom sledećeg izraza:

$$RMSE = \sqrt{E\{(\varphi_{ref} - \varphi_{proc})^2 + (\theta_{ref} - \theta_{proc})^2\}} \quad (6.1)$$

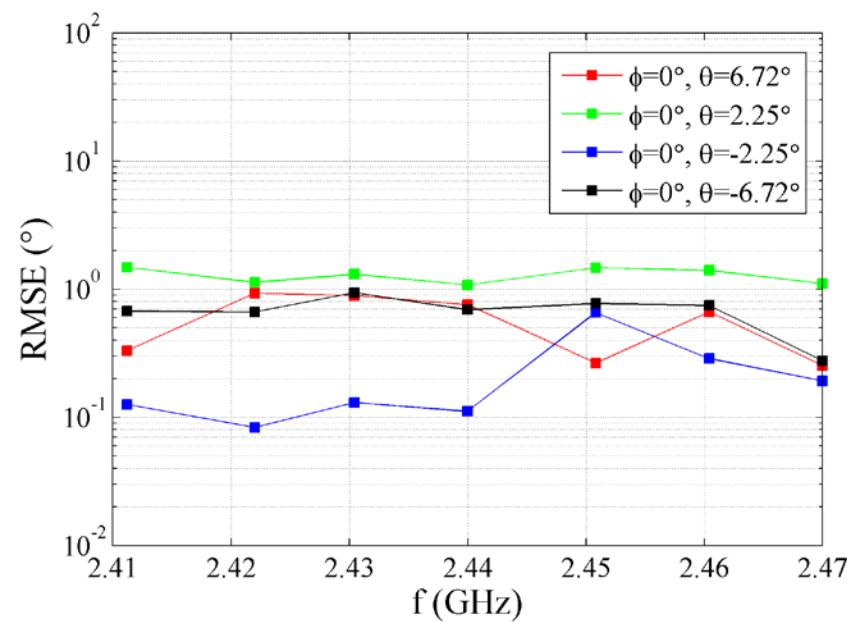
gde je φ_{ref} referentni ugao u azimutu dolaznog EM signala, φ_{proc} je procenjeni ugao u azimutu, θ_{ref} označava referentni ugao u elevaciji dok je θ_{proc} procenjeni ugao u elevaciji. Kao što je prikazano na Slici 6.11, neuronski model ima slične performanse u okviru celokupnog frekvencijskog opsega, gde u najgorem slučaju vrednost RMSE ne prelazi 2° . Greške u proceni pravaca su uglavnom posledica malih odstupanja prilikom postavljanja antena jedne naspram druge, za različite ugaone pozicije u anehoičnoj komori. Takođe, frekvencijska zavisnost RMSE greške u proceni pravca EM signala za tri pozicije u azimutu $\varphi_1 = -45^\circ$, $\varphi_2 = 0^\circ$ i $\varphi_3 = 45^\circ$, i četiri elevaciona ugla za svaku poziciju u azimutu, $\theta_1 = -6.72^\circ$, $\theta_2 = -2.24^\circ$, $\theta_3 = 2.24^\circ$ i $\theta_4 = 6.72^\circ$, ilustrovana je na Slici 6.12. Može se zaključiti da je vrednost RMSE za sve test pozicije u opsegu $[0.01^\circ, 2^\circ]$.



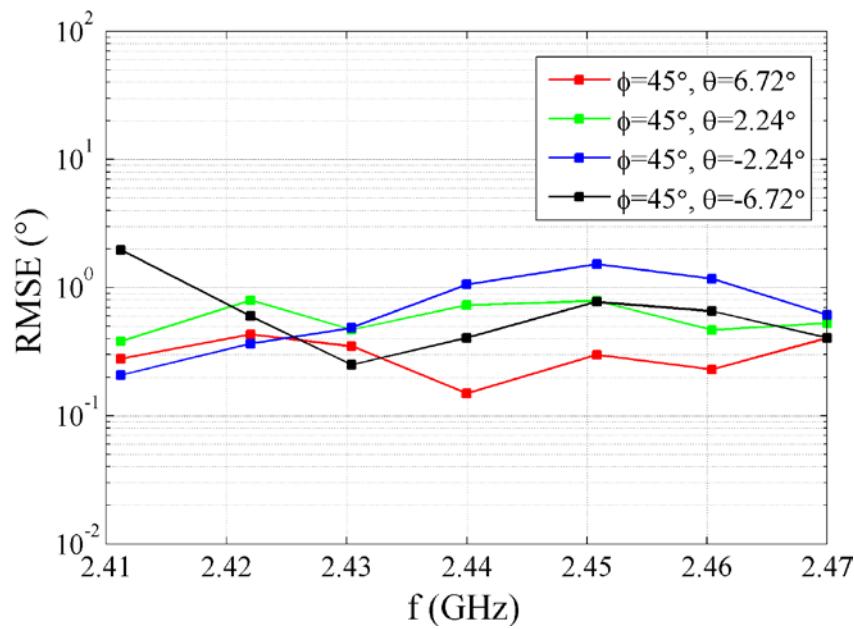
Slika 6.11 Koren srednje kvadratne greške (RMSE) neuronskog modela za
(a) $f=2.4100 \text{ GHz}$, (b) $f=2.4400 \text{ GHz}$ i (c) $f=2.4700 \text{ GHz}$



(a)



(b)



(c)

Slika 6.12 *Frekvencijska zavisnost RMSE procenjenih uglova u azimutu i elevaciji za više pozicija predajne antene (a) $\varphi=-45^\circ$, (b) $\varphi=0^\circ$, (c) $\varphi=45^\circ$*

Najveća prednost neuronskog modela u odnosu na konvencionalni 2D MUSIC algoritam je njegova efikasnost u proceni pravaca. Primera radi, izvršićemo poređenje efikasnosti predloženog neuronskog modela i 2D MUSIC algoritma, implementiranih u MATLAB-u 7.10, na računaru konfiguracije Intel(R) Core(TM)2 Quad CPU 2.33 GHz, sa 8 GB RAM memorije. Referentna ugaona pozicija EM izvora koju je potrebno proceniti je $(\varphi, \theta) = (36^\circ, 8.92^\circ)$. Korak pretrage spektra kod 2D MUSIC algoritma je podešen na 0.25° . Izmereno vreme odziva neuronskog modela je 20 ms, dok je standardnom 2D MUSIC algoritmu potrebno 17.8 s za pretragu spektra i pronalaženje maksimuma.

Druga značajna prednost neuronskog modela je njegova sposobnost da uči na osnovu prikazanih podataka, tako on može uzeti u obzir sve geometrijske nesavršenosti u izradi antenskog niza. Pored toga, model je u stanju da eliminiše refleksije u kablovima i konektorima i ne zahteva dodatnu kalibraciju antenskog niza kako bi se minimizovali efekti međusobne elektromagnetne sprege između antenskih elemenata.

7 Kaskadni neuronski model za određivanje pravca EM signala

Uslovi okruženja i fizičke karakteristike antenskog niza mogu uticati na pogoršanje performansi algoritama za procenu pravaca EM signala. Kao što je već rečeno u prethodnom poglavlju, nesavršenosti izrade antenskog niza, direktivnost antenskih elemenata i međusobna elektromagnetna sprega u najvećoj meri doprinose greškama u proceni pravaca. Međutim, postoji mogućnost uključivanja ovih efekata u procesu postprocesiranja kako bi se rezultati koji potiču od čisto simulacionog modela (ili algoritma) isfiltrirali i greške u proceni svele na minimum.

Tehnike za smanjenje greške u proceni ugaonih pozicija EM izvora kao što je kompenzacija elektromagnetne sprege između antenskih elemenata i druge procedure za postprocesiranje podataka su privukli najveću pažnju istraživača. U literaturi je dat metod za kompenzaciju elektromagnetne sprege između elemenata za niz koji radi u prijemnom režimu, [79]. Performanse ovog metoda su eksperimentalno verifikovane na primeru procene pravaca dva koherentna EM izvora. Metod za poboljšanje performansi algoritama za procenu pravaca EM signala razdvajanjem (*decoupling*) napona na terminalima, prikazan je u [86]. Ovaj metod je evaluiran numeričkom metodom podrazumevajući linearni antenski niz, visok odnos signal/šum i veliki broj uzoraka signala. Međutim, ovaj metod nije verifikovan eksperimentalnim rezultatima.

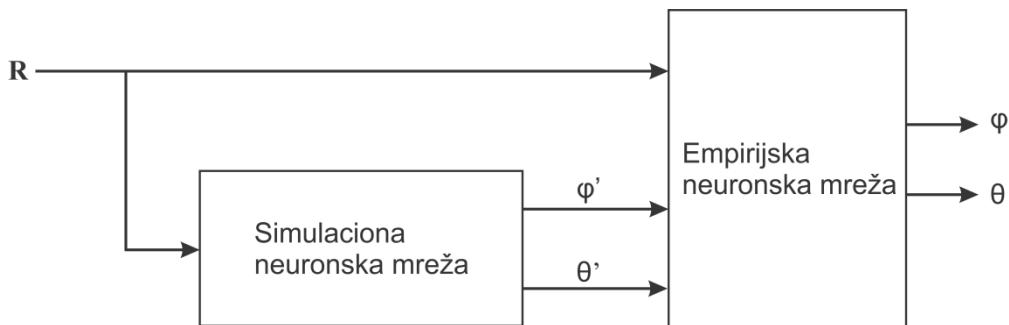
U nekim realnim situacijama, formiranje velikog skupa merenih podataka za obuku empirijskih neuronskih modela može biti teško izvodljivo, zbog ograničenja u vremenu i korišćenju same opreme. Sa druge strane, razvoj optimalnog neuronskog modela zasnovanog na simuliranom EM izvoru zahteva simulacione parametre koji detaljno opisuju okruženje za prostiranje EM talasa kao i karakteristiku zračenja antenskog niza. Neki od ovih efekata se ne mogu jasno matematički formulisati za primenu u simulatorima. Da bi se ovo izbeglo, moguće je merene podatke na drugi način uključiti u neuronski model za poboljšanje tačnosti procene pravca. Dovoljno je iskoristiti manju količinu merenih podataka za “kalibraciju” neuronskog modela obučenog korišćenjem simuliranih EM izvora [87]. U ovom slučaju se formira manja empirijska mreža čija je uloga da kalibriše podatke koji dolaze od simulacionog neuronskog modela. Naime, koristi se karakteristika neuronskih mreža da implementiraju znanje o okruženju u svoju strukturu, modifikovanjem parametara mreža.

7.1 Osnovni koncept

U ovom poglavlju je predložen model za poboljšanje tačnosti procene pravca EM signala. Model se sastoji od dve kaskadno-povezane neuronske mreže koje modeluju zavisnost između pozicija EM izvora i prostorne kovarijansne matrice, Slika 7.1.

Prva mreža u modelu je obučena na osnovu simuliranog EM izvora. Ulaz u simulacionu neuronsku mrežu su elementi kovarijansne matrice dok izlaz mreže predstavlja približnu informaciju o pravcima i razmatra se kao *a priori* znanje za drugu mrežu u modelu. Empirijska mreža je ključna za ostvarivanje preciznije procene pravaca. Ona za ulaze ima elemente kovarijansne matrice i izlaze prve mreže. Njeni izlazi predstavljaju konačne rezultate procene pravaca.

Za razvoj neuronskog modela odabране su RBF neuronske mreže zbog njihove odlične sposobnosti aproksimacije kao i zbog brzine konvergencije koja je bolja nego kod MLP mreža. Predloženi neuronski model ima potencijala da kao jedan adaptivan i efikasan sistem bude primjenjen za procenu pravca EM signala u realnom vremenu.



Slika 7.1 *Neuronski model za poboljšanje tačnosti procene pravca EM signala*

7.2 Rezultati

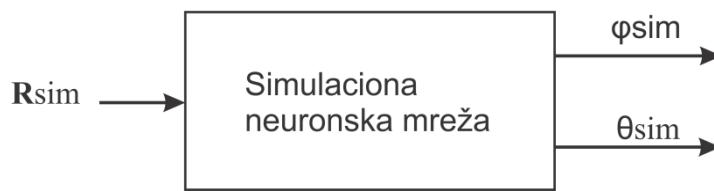
Za obuku simulacione neuronske mreže podaci su generisani u MATLAB-u. U simulacijama se podrazumeva jedan EM izvor signala i 4×4 pravougaoni antenski niz na prijemu. Rastojanje između susednih elemenata antenskog niza jednako je polovini talasne dužine incidentnih talasa. EM izvor se postavlja na različite pozicije u posmatranom prostoru na osnovu čega se izračunavaju odgovarajuće prostorne kovarijansne matrice.

Sa druge strane, empirijska mreža se obučava podacima iz eksperimenata izvedenih u

anehoičnoj komori. Procena pravaca u ovom slučaju nije izvršena u realnom vremenu, već su izmereni naponi na antenskim elementima sačuvani, a potom rezultati obrađeni *offline* u MATLAB-u.

a) Simulaciona neuronska mreža

Za obuku i testiranje performansi simulacionog neuronskog modela koriste se parametri simulacija prikazani u Tabeli 7.1. Sektor koji se razmatra za formiranje odgovarajućih skupova podataka definisan je sa $(\phi_1, \phi_P) = (-45^\circ, 45^\circ)$ i $(\theta_1, \theta_Q) = (-10^\circ, 10^\circ)$. Sektor se sempluje korakom $\Delta\phi_{tr} = \Delta\theta_{tr} = 1^\circ$ za skup za obuku mreže i $\Delta\phi_{te} = \Delta\theta_{te} = 2.33^\circ$ za skup za testiranje mreže. Polarizacija talasa EM izvora je vertikalna [88].



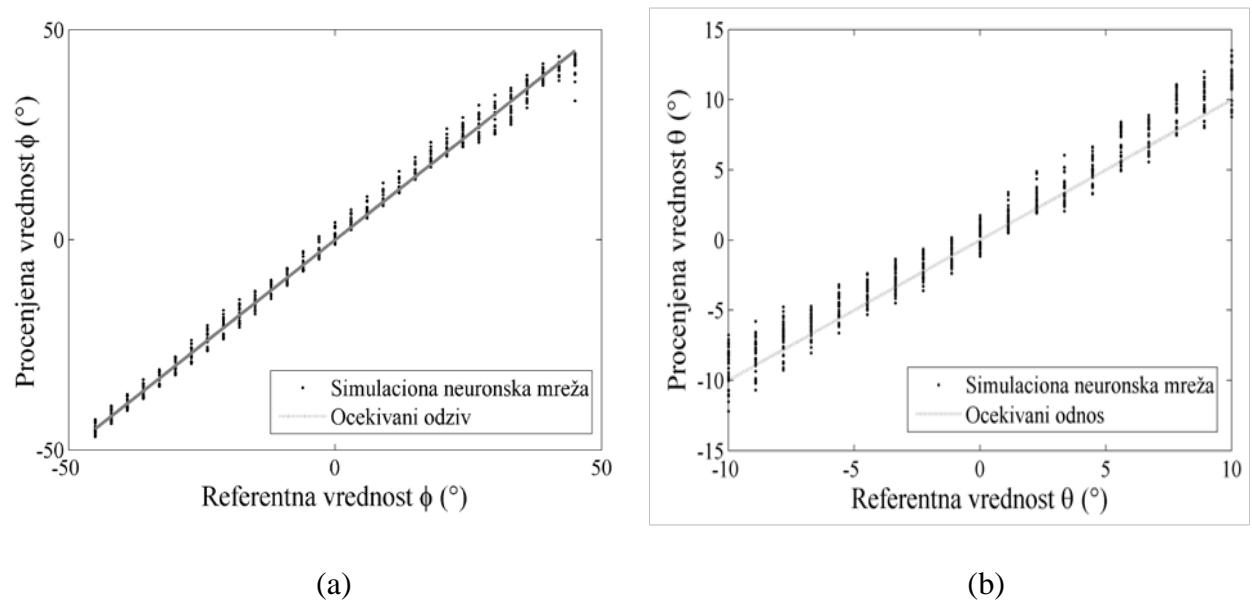
Slika 7.2 Razvoj neuronske mreže zasnovane na simuliranom EM izvoru

Korišćenjem ovih podataka i OLS algoritma za obuku (Poglavlje 3), razvija se više neuronskih modela. RBF mreža sa najboljim rezultatima na test skupu izdvaja se za formiranje kaskadnog neuronskog modela. Optimalna RBF mreža sadrži 31 neuron u ulaznom sloju, 2 neurona u izlaznom i 1384 neurona u skrivenom sloju. Statistika neuronske mreže na podacima iz test skupa je WCE=5.36%, ACE=1.05% i $r=0.9990$.

U daljem postupku, izvršena je procena performansi simulacione neuronske mreže dovođenjem na ulaze mreže merenih podataka. Eksperimenti su izvršeni u opsegu uglova u azimutu od -45° do 45° sa korakom 3° , i elevaciji od -10° do 10° , za 19 pozicija ($0^\circ, \pm 1.12^\circ, \pm 2.25^\circ, \pm 3.36^\circ, \pm 4.48^\circ, \pm 5.6^\circ, \pm 6.71^\circ, \pm 7.81^\circ, \pm 8.92^\circ, \pm 10^\circ$). Na Slici 7.3, prikazan je odziv simulacione mreže za merene podatke. Statistički parametri mreže u ovom slučaju iznose WCE=25.36%, ACE=5.16% i $r=0.9868$.

Tabela 7.1 Parametri simulacija za razvoj simulacione neuronske mreže

Parametri simulacija	Vrednosti
Broj antenskih elemenata	$M=4$ $N=4$
Broj uzoraka	$N_{snap}=5$
Rastojanje između susednih elemenata	$d=\lambda/2$
Odnos signal/šum	$SNR=10 \text{ dB}$
Opseg uglova u azimutu	$\varphi=(-45^\circ - 45^\circ)$
Opseg uglova u elevaciji	$\theta=(-10^\circ - 10^\circ)$



Slika 7.3 Dijagrami rasejanja simulacione neuronske mreže za merene rezultate na ulazu
(a) procjenjeni pravci u azimutu, (b) procjenjeni pravci u elevaciji

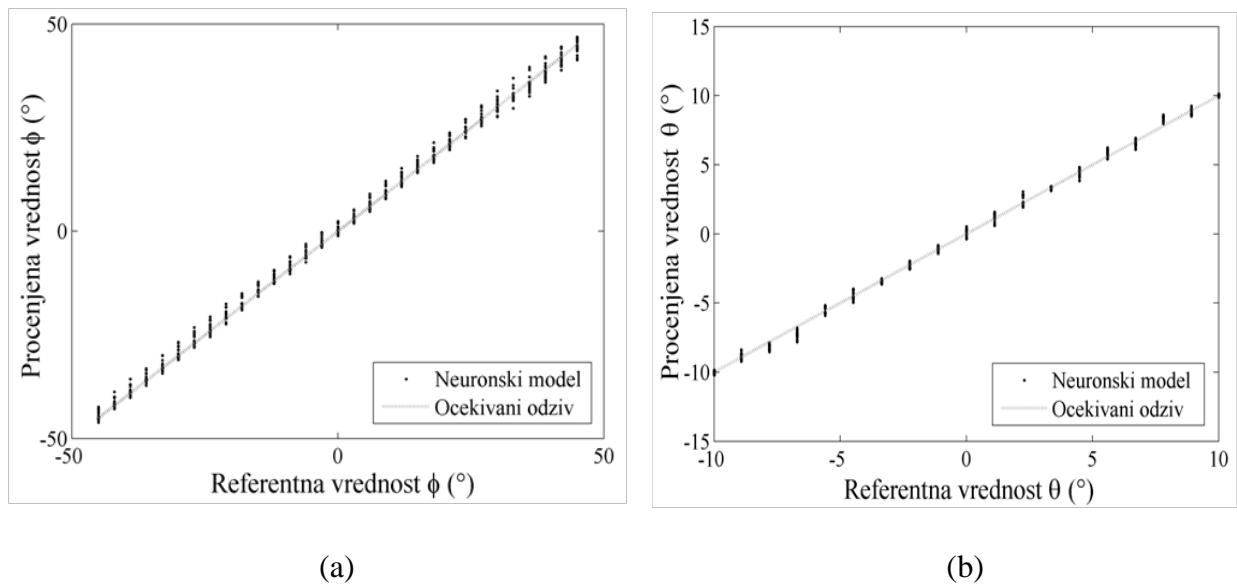
b) Empirijska neuronska mreža

Empirijska mreža je obučena merenim podacima za 31 poziciju EM izvora u azimutu od -45° do 45° sa korakom 3° , i 4 pozicije u elevaciji, -10° , -3.36° , 3.36° i 10° , respektivno. Preostali mereni podaci su iskorišćeni za procenu generalizacionih sposobnosti neuronske mreže. RBF empirijska mreža je obučena primenom iste procedure kao kod simulacione mreže. Optimalna mreža sadrži 33 neurona u ulaznom sloju, 57 neurona u skrivenom sloju i 2

neurona u izlaznom sloju. Mreža ima sledeću test statistiku: WCE=5.77 %, ACE=1.45%, $r=0.9985$.

c) Performanse kaskadnog neuronskog modela

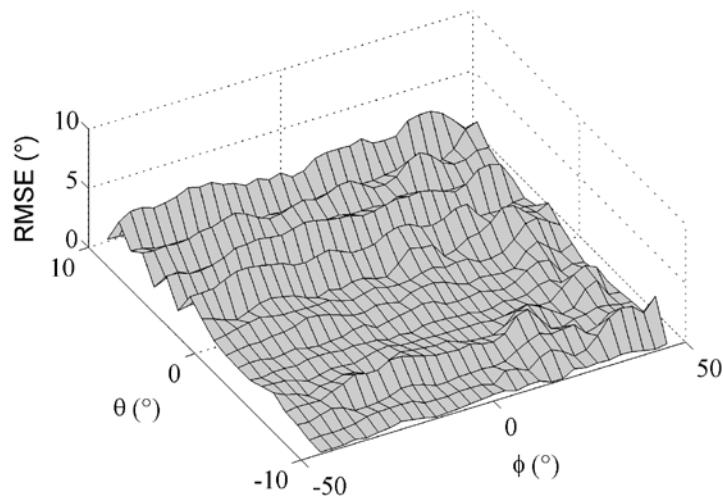
Dijagrami rasejanja kaskadnog neuronskog modela su prikazani na Slici 7.4, za sve uglove u azimutu i elevaciji (uključujući i podatke za obuku). Neuronski model demonstrira dobre generalizacione sposobnosti i daje korektan odziv čak i za ulazne podatke koji nisu korišćeni u procesu obuke. Poređenjem ovih grafika i grafika prikazanih na Slici 7.3, može se zapaziti da kaskadni model u velikoj meri poboljšava tačnost procenjenih pravaca u odnosu na simulacionu neuronsku mrežu. Koren srednje kvadratne greške (RMSE) neuronskog modela prikazan je na Slici 7.5 [88].



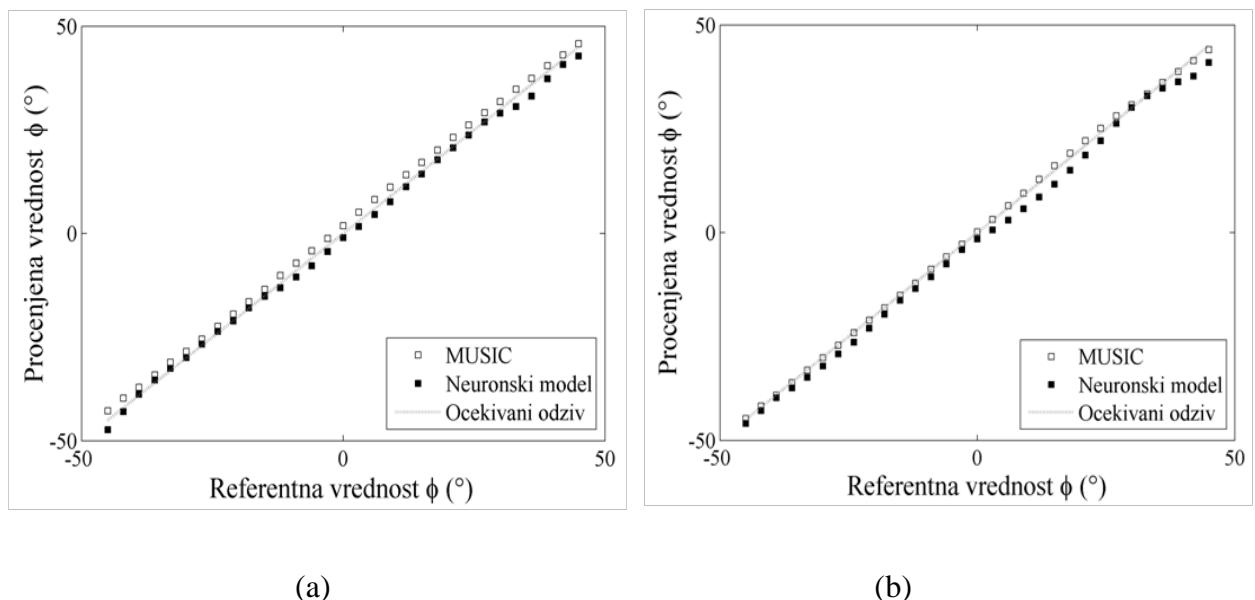
Slika 7.4 *Dijagrami rasejanja kaskadnog neuronskog modela za merene rezultate na ulazu
(a) procenjeni pravci u azimutu, (b) procenjeni pravci u elevaciji*

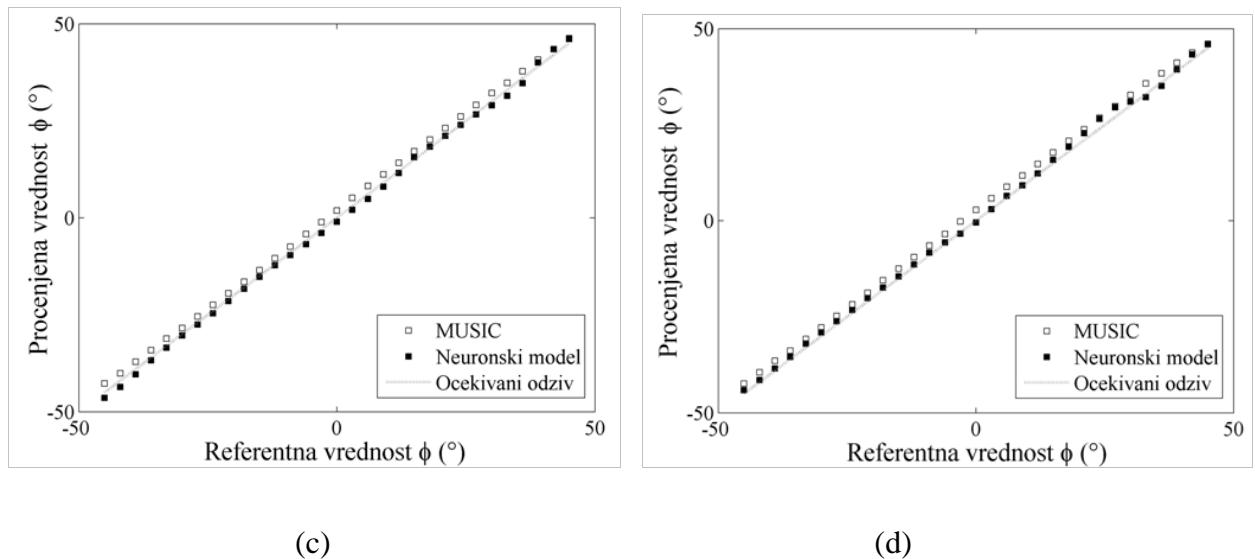
Performanse kaskadnog neuronskog modela se dalje porede sa rezultatima 2D MUSIC algoritma na istom skupu merenih podataka. Na Slikama 7.6 i 7.7, prikazani su rezultati neuronskog modela, 2D MUSIC algoritma kao i očekivani rezultati. Može se zaključiti da su procenjeni pravci pomoću neuronskog modela približno iste tačnosti kao i rezultati standardnog algoritma. Na Slici 7.6 su dati rezultati za 31 ugao u azimutu i 4 ugla u elevaciji. Zapaža se dobro slaganje odziva neuronskog modela sa procenjenim pravcima 2D MUSIC algoritma i referentnim vrednostima. Na Slici 7.7 je prikazan suprotan scenario – za 4 fiksne pozicije u azimutu porede se performanse kaskadnog neuronskog modela i 2D

MUSIC algoritma za 19 elevaciona ugla, od kojih su 4 korišćena u procesu obuke modela. Kao što se može videti, neuronski model daje korektan odziv u celokupnom sektoru i u nekim tačkama nadmašuje standardan algoritam za procenu pravaca.

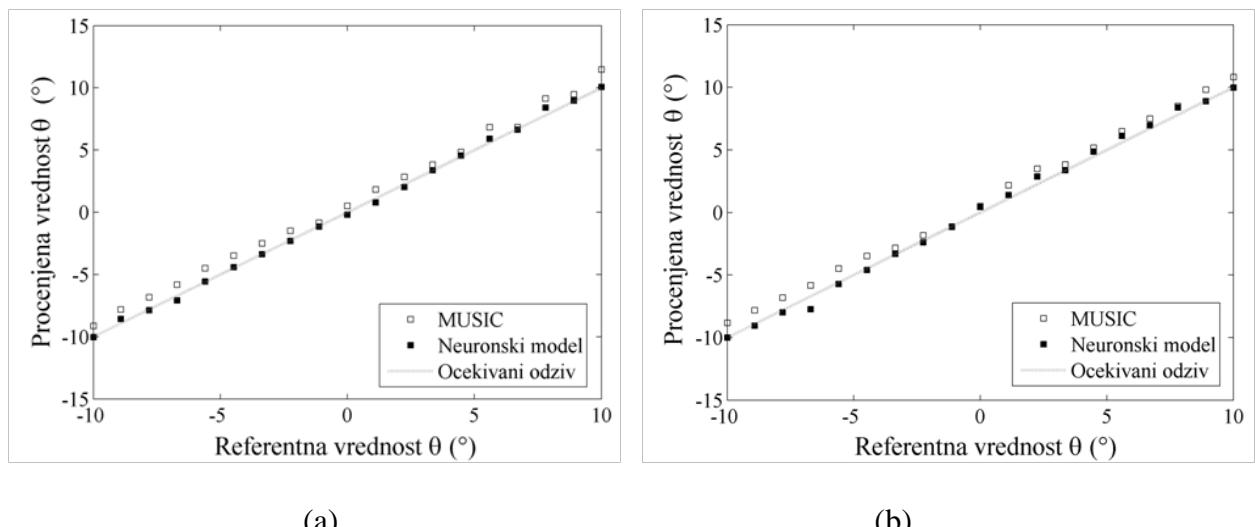


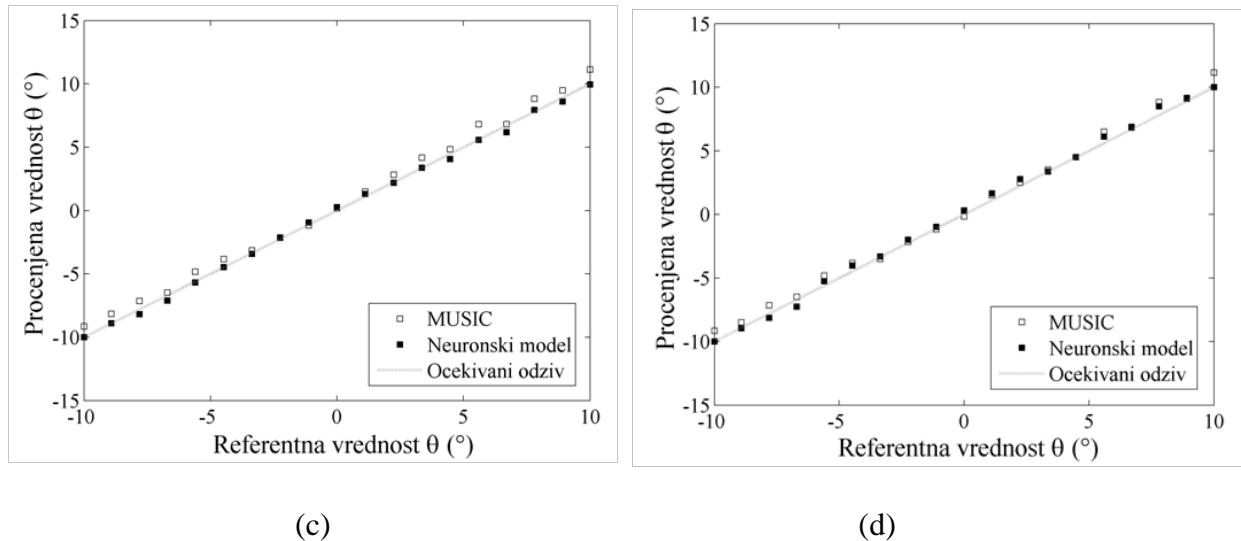
Slika 7.5 RMSE greška kaskadnog neuronskog modela za različite uglove u azimutu i elevaciji





Slika 7.6 Dijagrami rasejanja predloženog neuronskog modela za različite vrednosti uglova u azimutu i 4 fiksna ugla u elevaciji (a) $\theta = -7.81^\circ$, (b) $\theta = 7.81^\circ$, (c) $\theta = -2.25^\circ$, (d) $\theta = 2.25^\circ$





Slika 7.7 *Dijagrami rasejanja predloženog neuronskog modela za različite vrednosti uglova u elevaciji i 4 fiksna ugla u azimutu (a) $\varphi = -33^{\circ}$, (b) $\varphi = 33^{\circ}$, (c) $\varphi = -9^{\circ}$, (d) $\varphi = 9^{\circ}$*

Predloženi kaskadni neuronski model zahteva malu količinu merenih podataka za obuku što doprinosi uštedama u vremenu i opremi. Može se zaključiti da je tačnost dobijenih rezultata nešto slabija od rezultata čisto empirijskog modela [84]. S obzirom da je mala količina merenih podataka potrebna za razvoj neuronskog modela, on se može lako ponovo obučiti. U slučaju promenjenih uslova okruženja, ažuriraju se samo parametri manje empirijske mreže, što predstavlja lak zadatak i može se obaviti veoma efikasno.

8 Razvoj neuronskih modela za procenu pravaca koherentnih signala

Procena pravaca dolaska korelisanih EM signala je neophodna u realnim situacijama, usled prostiranja signala po višestrukim putanjama. Performanse standardnih algoritama se jako pogoršavaju kada je potrebno odrediti pravce ovih signala zbog čega se zahteva dodatna obrada primljenih signala na antenskim elementima u cilju njihove dekorelacije.

Prilikom praktične implementacije algoritama, javljaju se dva zahteva koje je potrebno ispuniti u cilju efikasne i precizne procene pravaca:

- upotreba antenskih nizova sa što manjim brojem elemenata,
- primena metoda koji ne koristi pretragu spektra signala u azimutu i elevaciji.

Za procenu pravaca nekorelisanih signala, metodi zasnovani na određivanju podprostora signala i šuma [6], [7], koriste svojstvo da je rang komponente signala nesingularne prostorne kovarijansne matrice jednak broju EM izvora. U ovom slučaju se podprostori signala i šuma dobijaju dekompozicijom kovarijansne matrice. Ovu tehniku je, međutim, nemoguće primeniti za procenu pravaca koherentnih signala. Najpoznatija tehnika koja se primenjuje za dekorelaciju koherentnih signala je tzv. *spatial smoothing* pretprocesiranje (SSP, *Spatial Smoothing Preprocessing*) [64]. Ova tehnika zahteva da se u okviru postojećeg antenskog niza formira određeni broj podnizova, koji se međusobno preklapaju. Njihov broj mora biti jednak ili veći od broja koherentnih signala. Za svaki podniz, posebno se izračunava prostorna kovarijansna matrica i na kraju vrši njihovo usrednjavanje. SSP metoda ima za posledicu smanjenje efektivne aperture antenskog niza, a samim tim i rezolucije procenjenih uglova u azimutu i elevaciji. Ovaj nedostatak SSP metode je posebno izražen u slučaju procene pravaca blisko postavljenih koherentnih EM izvora. Procena pravaca koherentnih signala može biti u određenoj meri poboljšana primenom modifikovanih SSP metoda [65]-[66], ili uvođenjem novih tehnika za obradu podataka uključujući i metode za kompenzaciju efekata elektromagnetne sprege između antenskih elemenata [77]-[79], [89]-[92].

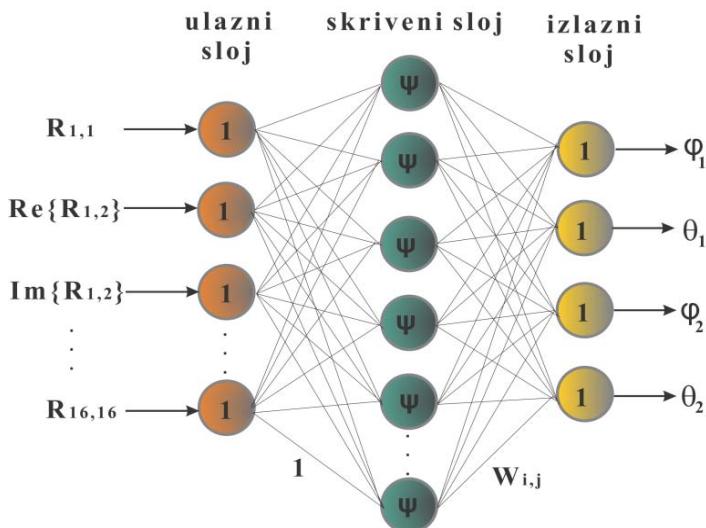
U ovom poglavlju su za procenu pravaca korelisanih ili potpuno koherentnih signala predloženi modeli zasnovani na neuronskim mrežama. Posebna pažnja je posvećena efikasnoj detekciji blisko postavljenih EM izvora signala.

8.1 Obuka jedne neuronske mreže za procenu pravaca koherentnih signala

Procena pravaca EM signala primenom jedne neuronske mreže zasniva se na simulaciji dva koherentna EM izvora na istom elevacionom, ali na različitim azimutnim uglovima i rastojanjima. Posmatrani prostor obuhvata sektor širine 90° $[-45^\circ, 45^\circ]$, u azimutnoj u elevacionoj ravni. Performanse obučenog neuronskog modela su ocenjene pomoću test podataka koji nisu korišćeni u procesu obuke mreže.

8.1.1 Osnovni koncept

Predloženi model RBF neuronske mreže za procenu pravaca koherentnih signala prikazan je na Slici 8.1. Prepostavlja se da je na prijemnoj strani pravougaoni antenski niz konfiguracije 4×4 , sa rastojanjem između antenskih elemenata jednakim polovini talasne dužine incidentnih talasa. Ulazi u mrežu su elementi prostorne kovarijansne matrice, organizovani u obliku vektora (Poglavlje 4).



Slika 8.1 *RBF neuronska mreža za procenu pravaca koherentnih signala u azimutu i elevaciji*

S obzirom da se radi o korelisanim signalima, nije dovoljno koristiti samo prvu vrstu prostorne kovarijansne matrice već je potrebno uzeti sve elemente iznad glavne dijagonale (uključujući i dijagonalu). Neuronska mreža vrši nelinearna izračunavanja i daje na svom izlazu ugaone pozicije dva koherentna izvora signala u azimutu i elevaciji.

8.1.2 Numerički rezultati

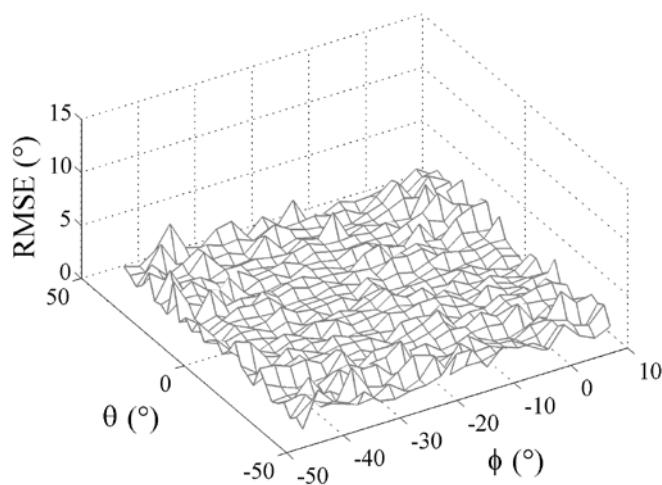
Podaci za obuku mreže su sakupljeni za nekoliko pozicija koherentnih izvora u azimutu i elevaciji. Posmatrani prostor obuhvata sektor od -45° do 45° , u azimutu i elevaciji. Podrazumeva se da su oba izvora pozicionirana na istoj elevaciji, ali na različitim međusobnim rastojanjima u azimutnoj ravni od 2° , 5° , 10° , 20° , 30° , 50° , 60° i 90° . Rezolucija uzorka za obuku mreže iznosi 2° u azimutu, i 5° u elevaciji. Na drugoj strani, test skup je formiran pretpostavljajući rastojanje između izvora od 3° , 17° , 35° , 55° i 75° , sa korakom od 2.7° u azimutu i 3° u elevaciji. Svi uzorci u skupovima za obuku i testiranje sadrže beli *Gaussov* šum pri čemu je odnos signal/šum jednak 15 dB. Prostorna kovarijansna matrica je određena na osnovu 5 uzorka (*snapshota*) primljenih signala.

Prvi korak u razvoju neuronske mreže za procenu pravaca koherentnih signala je primena jednostavne procedure za obradu prostorne kovarijanske matrice, odnosno njenog transformisanja u normalizovani vektor kao što je opisano u Poglavlju 4. Imajući u vidu da je 4×4 pravougaoni antenski niz pretpostavljen na prijemnoj strani sledi da je broj neurona u ulaznom sloju neuronske mreže jednak 256. S obzirom da je potrebno proceniti pravce iz kojih dolaze signali dva koherentna izvora neuronska mreža će imati 4 izlaza, Slika 8.1. Nakon obuke više neuronskih modela korišćenjem funkcija implementiranih u MATLAB-u, izdvaja se mreža sa najboljom test statistikom. U ovom slučaju, optimalna RBFNN konfiguracija sadrži 733 neurona u skrivenom sloju i ima korelacioni koeficijent od 0.9976.

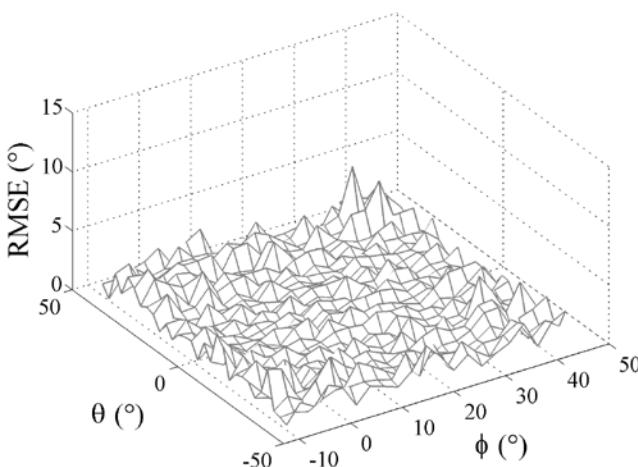
RMSE (*Root Mean Squared Error*) greška rezultata koje daje neuronska mreža za test podatke je prikazana na Slikama 8.2 i 8.3 za rastojanje između dva koherentna izvora od 35° . Greška je izračunata primenom sledećeg izraza:

$$RMSE = \sqrt{E\{(\varphi_{ref} - \varphi_{est})^2 + (\theta_{ref} - \theta_{est})^2\}}. \quad (8.1)$$

Imajući u vidu da je samo jedna RBF neuronska mreža iskorišćena za procenu uglova u azimutu i elevaciji dva koherentna izvora signala, može se zaključiti da je greška prikazana na Slikama 8.2 i 8.3 ima prihvatljive vrednosti. Takođe se može zapaziti da neuronska mreža ima slične performanse za sve incidentne uglove koherentnih signala.



Slika 8.2 RMSE greška procene pravca prvog koherentnog izvora za rastojanje između dva izvora od 35°



Slika 8.3 RMSE greška procene pravca drugog koherentnog izvora za rastojanje između dva izvora od 35°

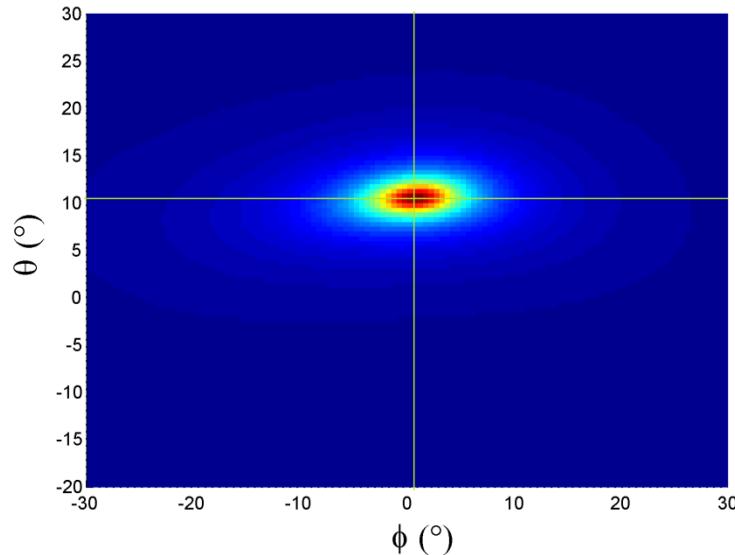
Tabela 8.1 Rezultati RBF mreže

Referentne pozicije koherentnih izvora (°)		Procenjeni pravci pomoću RBF mreže (°)	
(ϕ_1, θ_1)	(ϕ_2, θ_2)	$(\phi_{1\text{est}}, \theta_{1\text{est}})$	$(\phi_{2\text{est}}, \theta_{2\text{est}})$
(-10, 10)	(10, 10)	(-9.37, 9.78)	(-9.57, 9.78)
(-14, -17)	(14, -17)	(-15.23, -16.51)	(14.43, -16.51)
(-21, 26)	(21, 26)	(-22.51, 25.69)	(22.75, 25.69)
(-30, -35)	(30, -35)	(-30.84, -35.55)	(30.60, -35.55)

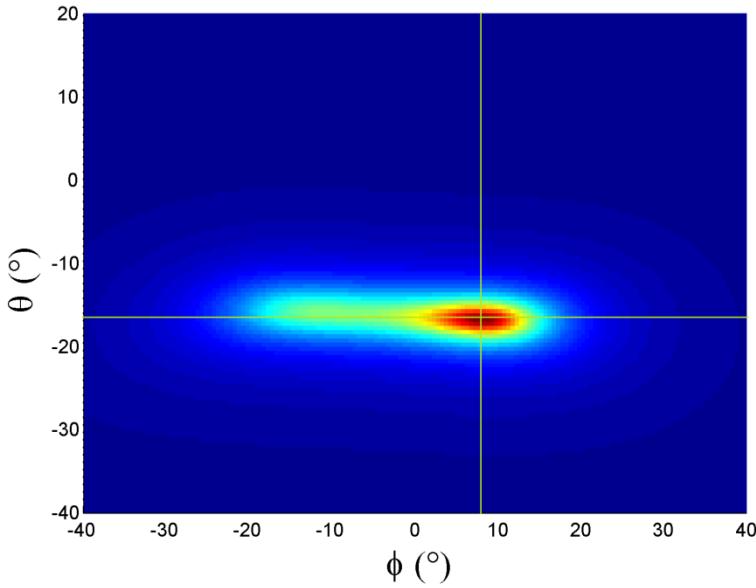
Tabela 8.2 *Rezultati MUSIC algoritma sa SSP metodom*

Referentne pozicije koherentnih izvora ($^{\circ}$)		Procenjeni pravci pomoću MUSIC algoritma sa SSP metodom ($^{\circ}$)	
(ϕ_1, θ_1)	(ϕ_2, θ_2)	$(\phi_{1\text{est}}, \theta_{1\text{est}})$	$(\phi_{2\text{est}}, \theta_{2\text{est}})$,
(-10, 10)	(10, 10)	(1, 10.5)	(1, 10.5)
(-14, -17)	(14, -17)	(8, -16.5)	(8, -16.5)
(-21, 26)	(21, 26)	(-18.5, 25)	(19.5, 26)
(-30, -35)	(30, -35)	(-31, -34.5)	(-30, -35)

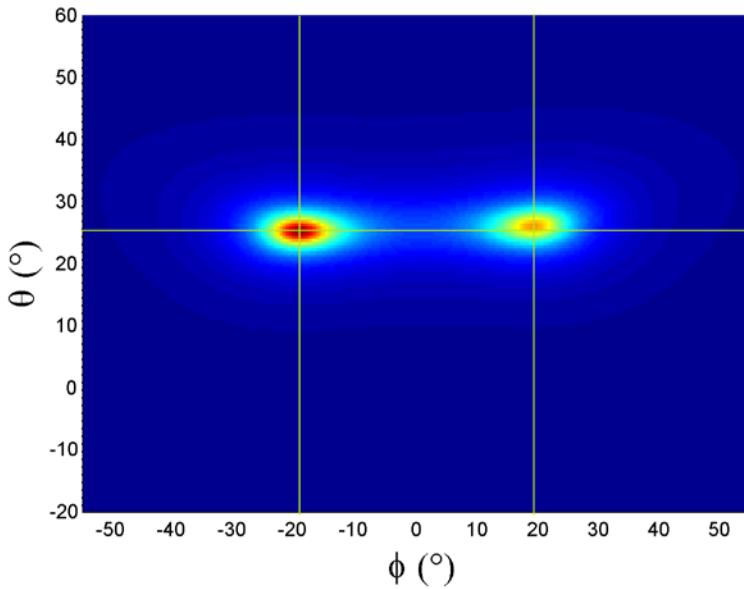
U Tabelama 8.1 i 8.2, prikazani su rezultati RBFNN mreže i MUSIC algoritma sa SSP metodom za nekoliko pozicija koherentnih izvora. Na osnovu ovih rezultata, može se zaključiti da neuronski model daje tačne rezultate u širokom opsegu uglova u azimutu i elevaciji. Takođe, prve dve vrste u Tabeli 8.2 ukazuju na nemogućnost MUSIC algoritma sa SSP metodom da razdvoji i detektuje dva blisko postavljena koherentna izvora [93]-[94].



Slika 8.4 *Spektar MUSIC algoritma sa SSP metodom za dva koherentna izvora
pozicionirana na $(-10^{\circ}, 10^{\circ})$ i $(10^{\circ}, 10^{\circ})$*



Slika 8.5 Spektar MUSIC algoritma sa SSP metodom za dva koherentna izvora pozicionirana na $(-14^\circ, -17^\circ)$ i $(14^\circ, -17^\circ)$



Slika 8.6 Spektar MUSIC algoritma sa SSP metodom za dva koherentna izvora pozicionirana na $(-21^\circ, 26^\circ)$ i $(21^\circ, 26^\circ)$

Rezultati prikazani na Slici 8.4 i Slici 8.5 su posledica smanjene efektivne aperture antenskog niza nakon što je na originalnu prostornu kovarijansnu matricu primenjena procedura za dekorrelaciju signala (SSP). U slučaju niže vrednosti odnosa signal/šum rezultati mogu biti dodatno pogoršani. Slika 8.6 demonstrira dobre rezultate MUSIC algoritma za dva koherentna izvora međusobno razdvojena 42° . Sa druge strane, RBFNN mreža detektuje koherentne izvore nezavisno od rastojanja između njih. Ova osobina neuronske mreže

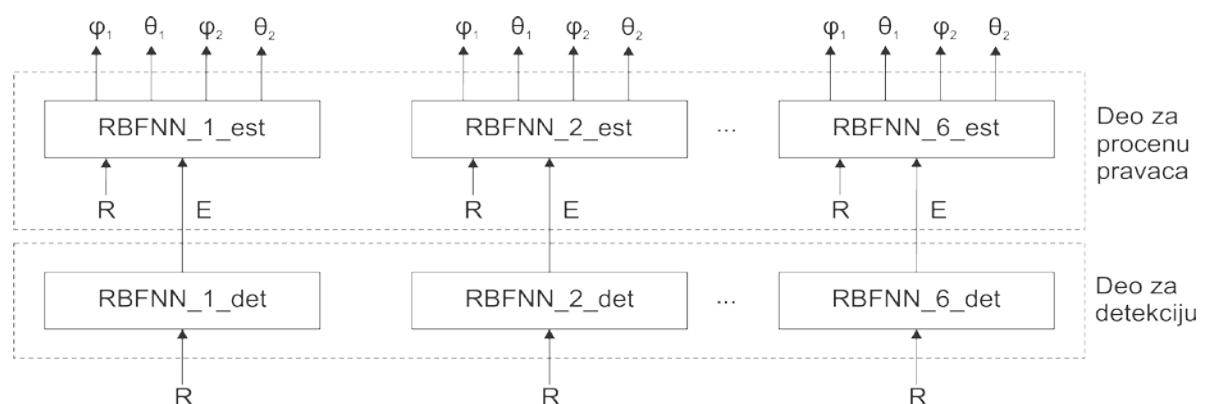
predstavlja njenu glavnu prednost u odnosu na konvencionalni MUSIC algoritam sa SSP metodom. Rezultati simulacija pokazuju sposobnost neuronske mreže da ostvari precizniju procenu pravaca koherentnih signala u odnosu na MUSIC algoritam.

8.2 Razvoj sektorizacionog modela

U cilju poboljšanja tačnosti procene pravaca koherentnih signala u azimutu i elevaciji, kao i proširenja posmatranog prostora, predložen je razvoj kompleksnijeg metoda zasnovanog na manjim RBF neuronskim mrežama. Predloženi pristup omogućava efikasnu obuku neuronskog modela kao i preciznu procenu pravaca signala. Eksperimentalna verifikacija neuronskog modela izvršena je u anehoičnoj komori.

8.2.1 Osnovni koncept

Predloženi neuronski model se sastoji iz dva dela, za detekciju prisustva koherentnih EM izvora signala i procenu pravaca, Slika 8.7. Detekcija se vrši u elevacionoj ravni i doprinosi većoj tačnosti određenih uglova u azimutu i elevaciji. Naime, celokupni posmatrani prostor je podeljen na šest sektora u elevaciji, od kojih je svaki širok 20° u elevaciji i 120° u azimutu. Svakom sektoru je pridružena po jedna RBFNN mreža (RBFNN, *Radial Basis Function Neural Network*) za detekciju izvora i procenu njihovih pravaca. Glavni cilj predloženog modela je da se nakon brze detekcije prisustva izvora signala u sektoru precizno odrede pravci iz kojih dolaze njihovi signali u tako podeljenom, užem prostoru.



Slika 8.7 Šema neuronskog modela za procenu pravaca dva koherentna EM signala

Samo će RBFNN mreža u detekcionom delu koja na svom izlazu daje 1, aktivirati odgovarajuću RBFNN mrežu u delu za procenu pravaca, dok će mreže za procenu pravaca u preostalim sektorima biti neaktivne.

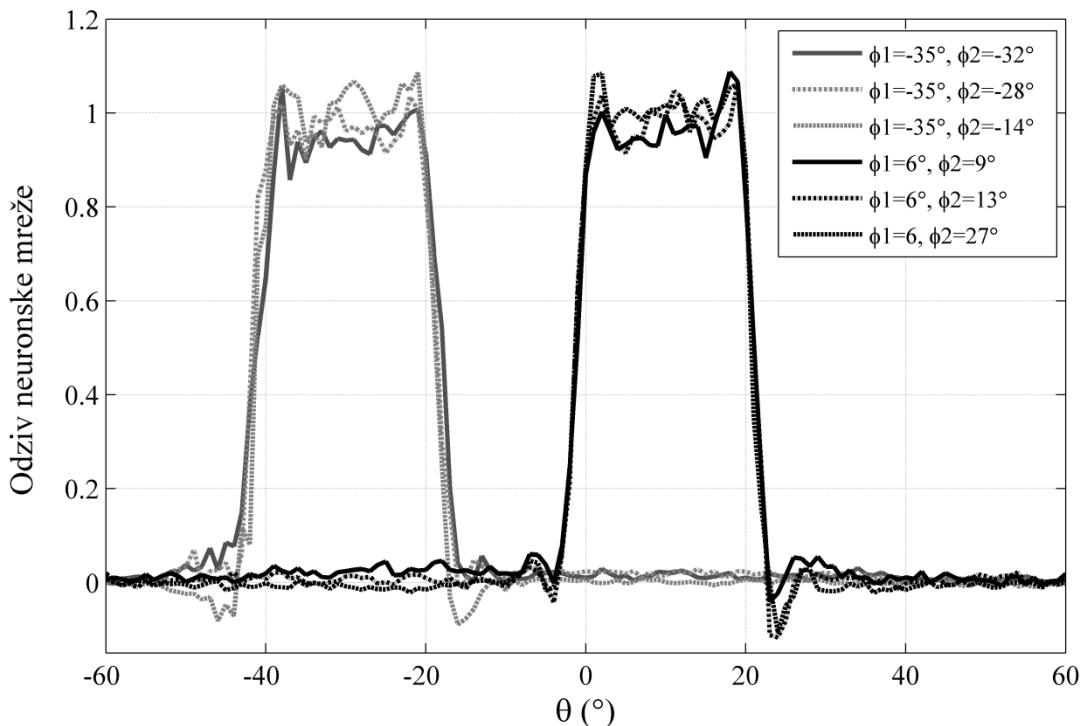
8.2.2 Razvoj neuronskog modela

RBFNN mreže u delu za detekciju prisustva koherentnih EM izvora imaju ulogu klasifikatora. Broj ulaza u jednu neuronsku mrežu zavisi od dimenzija prostorne kovarijansne matrice. U slučaju 4×4 pravougaonog antenskog niza i dva koherentna izvora signala, potrebno je za detekciju i procenu pravaca signala koristiti deo kovarijansne matrice iznad glavne dijagonale (uključujući i samu dijagonalu). Primenom procedure za obradu prostorne kovarijansne matrice, dobija se da je broj ulaza u jednu RBFNN mrežu jednak 256. U idealnom slučaju, izlaz jedne RBFNN mreže u delu za detekciju biće 0 ukoliko su izvori signala van posmatranog sektora, odnosno, 1 za slučaj da su izvori prisutni u samom sektoru. RBFNN mreža koja na svom izlazu daje 1, aktiviraće odgovarajuću RBFNN mrežu u delu za procenu pravaca, Slika 8.7 (*E, Enable*). Međutim, s obzirom da RBFNN mreže ne daju izlaze u obliku celih brojeva (0 ili 1), prag odluke za određivanje odgovarajućeg sektora je postavljen na 0.5. Sa ciljem da se obezbedi sigurna detekcija dva izvora signala potrebno je da postoji malo preklapanje između dva susedna sektora.

RBFNN mreže u delu za detekciju su obučene sa prepostavkom da je odnos signal/šum pristiglih signala jednak 15 dB. Izbor uzoraka za obuku je izvršen na sledeći način: rastojanje između izvora signala je redom 5° , 15° , 30° , 45° i 60° , korak u azimutu 7.5° i korak u elevaciji 2.5° . Neuronske mreže su obučene upotrebom OLS (*Orthogonal Least Square*) algoritma, opisanim u Poglavlju 3. Generalizacione sposobnosti neuronskih mreža su proverene na osnovu testa uzoraka koji nisu korišćeni u procesu obuke mreže, a to su rastojanja između izvora signala od 3° , 10° , 20° , 40° i 50° , korak u azimutu od 3° i korak u elevaciji od 3° . Statistika testiranja neuronskih mreža za svih šest sektora data je u Tabeli 8.3. Na osnovu ovih rezultata može se zaključiti da mreže imaju dobre performanse u određivanju odgovarajućeg sektora. Odzivi RBFNN mreža koje odgovaraju drugom i četvrtom sektoru ilustrovani su na Slici 8.8, u zavisnosti od ugla u elevaciji. Može se zaključiti da mreže u detekcionom delu daju slične odzive za različite uglove u azimutu i rastojanja između dva izvora.

Tabela 8.3 *Statistika testiranja neuronskih mreža u delu za detekciju signala*

Neuronska mreža	WCE (%)	ACE (%)	r
RBFNN_1_det	15.07	4.05	0.9893
RBFNN_2_det	13.37	3.79	0.9860
RBFNN_3_det	12.73	3.61	0.9869
RBFNN_4_det	12.00	3.46	0.9878
RBFNN_5_det	14.16	3.86	0.9867
RBFNN_6_det	17.67	5.09	0.9868

Slika 8.8 *Odziv mreže RBFNN_2_det (sive linije) i RBFNN_4_det (crne linije) u funkciji ugla u elevaciji*

RBFNN mreže u delu za procenu pravaca se obučavaju korišćenjem preciznijih podataka koji uključuju: rastojanja između izvora signala od $2^\circ, 5^\circ, 10^\circ, 20^\circ, 30^\circ, 40^\circ, 50^\circ$ i 60° , korak u azimutu od 1.5° i korak u elevaciji od 1.5° . Generalizacione sposobnosti obučenih neuronskih modela su ocenjene na osnovu test skupa, koji je potpuno nezavisan od skupa za obuku. U ovom slučaju, rastojanje između izvora signala uzima vrednosti po sledećem redosledu: $3^\circ, 17^\circ, 35^\circ, 55^\circ$, korak u azimutu je 2.7° i korak u elevaciji je 2.7° . U

Tabeli 8.4, prikazana je statistika testiranja šest neuronskih mreža u delu za procenu pravaca. Prosečne greške procene pravaca za oba izvora signala date su u Tabeli 8.5. Može se zapaziti da su performanse mreža koje pripadaju različitim sektorima slične, osim za par mreža koje su pridružene krajnjim sektorima. Specifična situacija se javlja kada su izvori signala pozicionirani na granici između dva sektora. U tom slučaju će oba sektora detektovati njihovo prisustvo i proceniti pravce dolaska signala. S obzirom da susedni sektori imaju slične greške u proceni pravaca, mogu se odabratи rezultati bilo kog od njih. RBFNN mreže u delu za procenu pravaca u proseku sadrže od 50 do 200 neurona u skrivenom sloju, dok parametar *spread* (standardna devijacija) varira između 6 i 12.

Procenjeno vreme za obuku celokupnog neuronskog modela je oko 3.15 časa (Intel(R) Core(TM)2 Quad CPU računar sa 8 GB RAM memorije).

Tabela 8.4 *Statistika testiranja neuronskih mreža u delu za procenu pravaca EM signala*

Neuronska mreža	WCE (%)	ACE (%)	<i>r</i>
RBFNN_1_est	7.66	0.96	0.9988
RBFNN_2_est	4.61	0.71	0.9994
RBFNN_3_est	4.60	0.71	0.9994
RBFNN_4_est	3.91	0.73	0.9994
RBFNN_5_est	4.69	0.89	0.9991
RBFNN_6_est	6.60	0.99	0.9988

Tabela 8.5 *Prosečna greška u proceni pravaca pojedinih neuronskih mreža*

Neuronska mreža	$\varphi_{1_pros_greška}$	$\theta_{1_pros_greška}$	$\varphi_{2_pros_greška}$	$\theta_{2_pros_greška}$
RBFNN_1_est	1.4243°	0.1407°	1.3879°	0.1407°
RBFNN_2_est	1.0460°	0.0983°	1.0385°	0.0983°
RBFNN_3_est	1.0913°	0.0937°	1.0714°	0.0937°
RBFNN_4_est	1.1204°	0.0889°	1.1173°	0.9878°
RBFNN_5_est	1.2269°	0.1257°	1.3118°	0.1257°
RBFNN_6_est	1.5173°	0.1335°	1.5035°	0.1335°

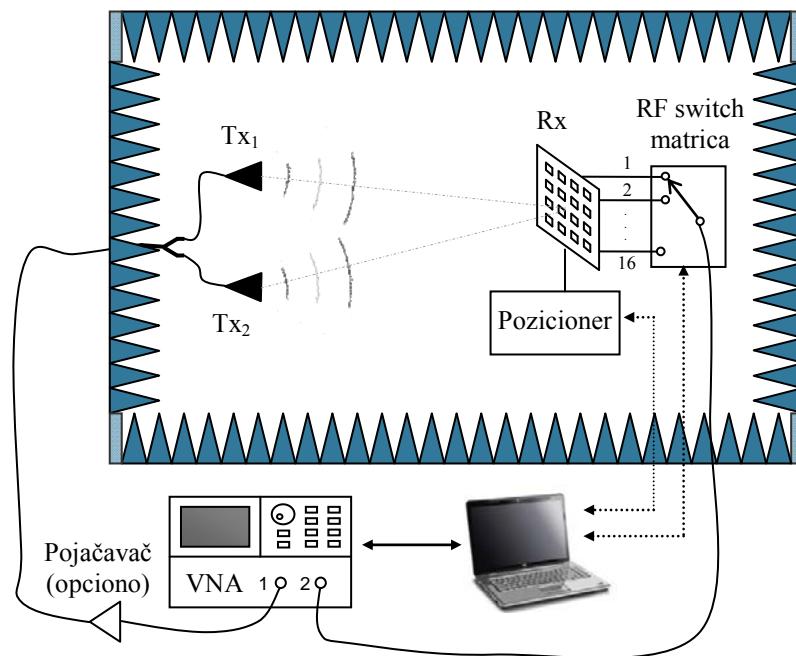
8.2.3 Postavka mernog sistema

Kako bi demonstrirali primenljivost razvijenog neuronskog modela u praksi, izvršena su eksperimentalna merenja u anehoičnoj komori, Slika 8.9. Na jednoj strani anehoične komore, montirane su dve predajne antene sa skoro identičnim električnim karakteristikama, Slika 8.10. Predajne antene su levak antene (model br. A6100) koje podržavaju linearnu i kružnu polarizaciju elektromagnetskih talasa i rade u frekvencijskom opsegu od 2.18 do 20 GHz. Pojačanje ovih antena je 7 dBi na 2.44 GHz. Antene se napajaju pomoću vektorskog analizatora mreže preko 3-dB Wilkinsonovog delitelja snage. Na prijemnoj strani je pozicioniran 4×4 pravougaoni antenski niz, Slika 8.11. Niz se sastoji od *microstrip patch* antenskih elemenata sa kaoksijalnim napajanjem. Dimenzije antenskih elemenata su optimizovane tako da su povratni gubici (S_{11} parametar) minimalni na rezonantnoj frekvenciji od 2.44 GHz i imaju vrednost -35 dB (Poglavlje 6). Izmereno pojačanje jednog izolovanog antenskog elementa iznosi 6.7 dBi. Elementi antenskog niza su raspoređeni tako da je rastojanje između centara dva susedna elementa jednako polovini talasne dužine incidentnih elektromagnetskih talasa. Svaki element niza je povezan sa po jednim ulazom RF switch matrice koaksijalnim kablom. U poređenju sa drugim metodima napajanja, kao što je npr. napajanje preko *microstrip* linija, kaoksijalno napajanje doprinosi smanjenju međusobne elektromagnetne sprege između antenskih elemenata.

Procedura merenja pravaca dolaska koherentnih EM signala je u suštini zasnovana na klasičnoj tehnici koja koristi vektorski analizator mreže. S obzirom da su signali predajnih levak antena unutar anehoične komore deterministički, može se iskoristiti ekvivalentnost između operatora matematičkog očekivanja u vremenskom domenu ($E\{\cdot\}$) i operatora množenja u frekvencijskom domenu, kao što je opisano u literaturi [95]. Predajne antene su povezane na jedan port vektorskog analizatora mreže dok se primljeni signali preko RF switch matrice vode na drugi port analizatora mreže. Elementi antenskog niza se aktiviraju (*switchuju*) sekvensijano, tako da je u jednom trenutku aktivan samo jedan element dok se preostali ponašaju kao parazitski elementi. Amplitude i faze napona generisanih na antenskim elementima se mere pomoću VNA. Merenja se ponavljaju po 5 puta za svaki merni scenario nakon čega se usrednjena vrednost ovih 5 merenja koristi za procenu pravaca dolaska koherentnih signala.

Za automatizaciju procesa merenja i akviziciju podataka, razvijen je softver za kontrolu vektorskog analizatora mreže i antenskog tornja u anehoičnoj komori iz MATLAB-a. Antenski toranj ima mogućnost rotacije u azimutu, sa korakom od 1° . Za merenje različitih

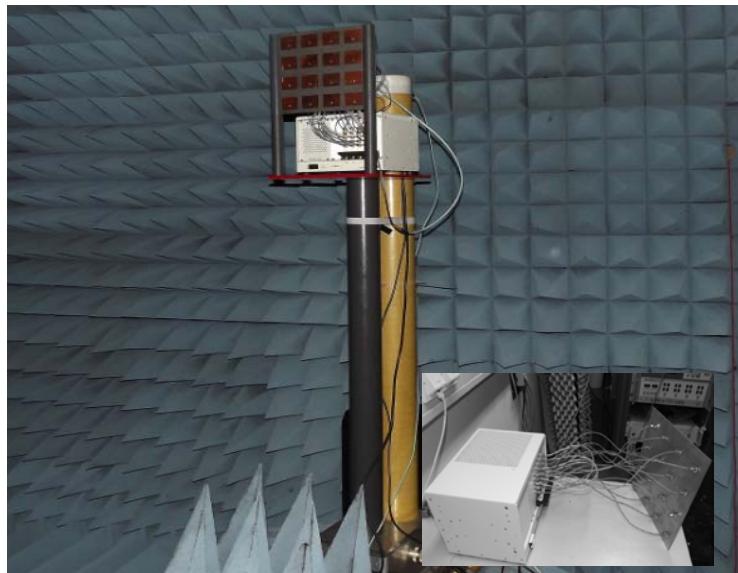
uglova u elevaciji neophodno je promeniti visine predajnih antena. Kalibracija sistema se obavlja pomoću referentnih antena sa poznatim karakteristikama zračenja.



Slika 8.9 Ilustracija mernog sistema u anehoičnoj komori



Slika 8.10 Dve predajne levak antene u anehoičnoj komori



Slika 8.11 *Prijemni antenski niz na antenskom tornju*

8.2.4 Eksperimentalna verifikacija neuronskog modela

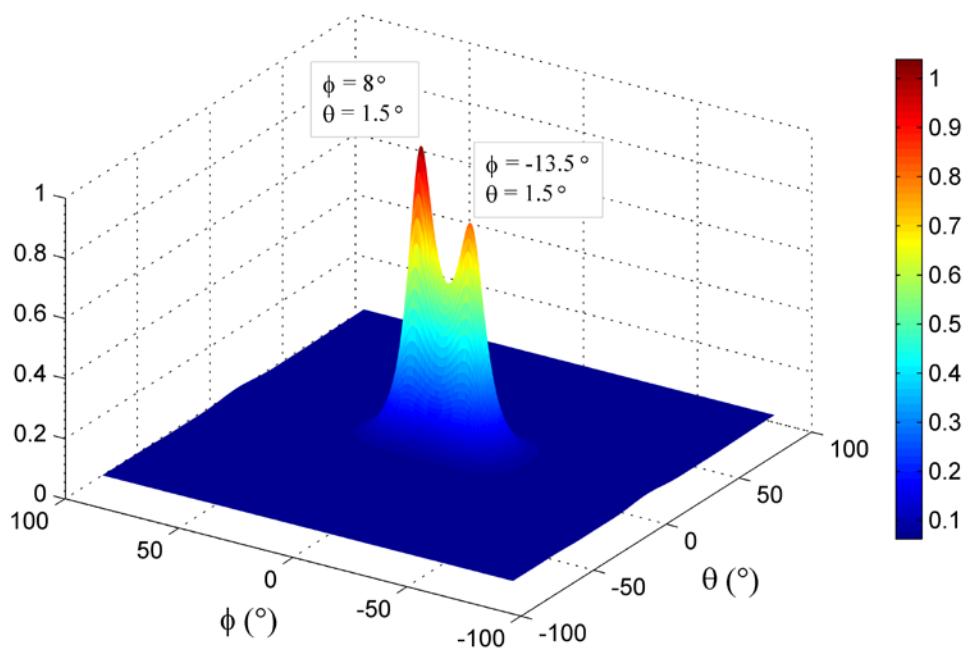
Eksperimentalni rezultati su obezbeđeni za dva sektora u elevaciji (treći i četvrti sektor), za određeni broj uglova u azimutu i rastojanja između predajnih antena od 1 m, 1.5 m i 2 m. Rastojanje između predajnih antena na jednoj strani i prijemnog antenskog niza na drugoj, iznosi $R=5$ m. Ugao u elevaciji je jednak nuli, kada je visina predajnih antena izjednačena sa visinom antenskog niza na antenskom tornju, za $H=1.9$ m. U toku merenja, izvršena je promena visine predajnih antena na 1.9 m, 1.75 m i 1.60 m, što odgovara elevacionim uglovima od 0° , -1.7° i -3.4° , respektivno. Mereni rezultati su iskorišćeni za procenu prostornih kovarijansnih matrica za određeni broj pozicija predajnih antena. Koristeći ove podatke testirani su neuronski model i MUSIC algoritam sa SSP metodom.

MUSIC algoritam sa SSP metodom koristi usrednjenu kovarijansnu matricu dobijenu od kovarijansnih matrica četiri 3×3 podniza. Na Slici 8.12 može se videti da algoritam ispravno detektuje dva koherentna signala kada su predajne antene razdvojene 2 m (odnosno 22.6°). Ukoliko se rastojanje između predajnih antena smanji na 1.5 m (17.0°), spektar MUSIC algoritma ne pokazuje jasno postojanje dva razdvojena EM izvora. Na Slici 8.13 se može videti da je površina maksimuma u spektru veoma velika tako da je procena pravaca dva koherentna signala u ovom slučaju neuspšena. Na Slikama 8.14 ili 8.15, pokazano je da MUSIC algoritam umesto dva koherentna izvora prikazuje postojanje samo jednog i to na poziciji koja ne odgovara ni jednoj od dve predajne antene.

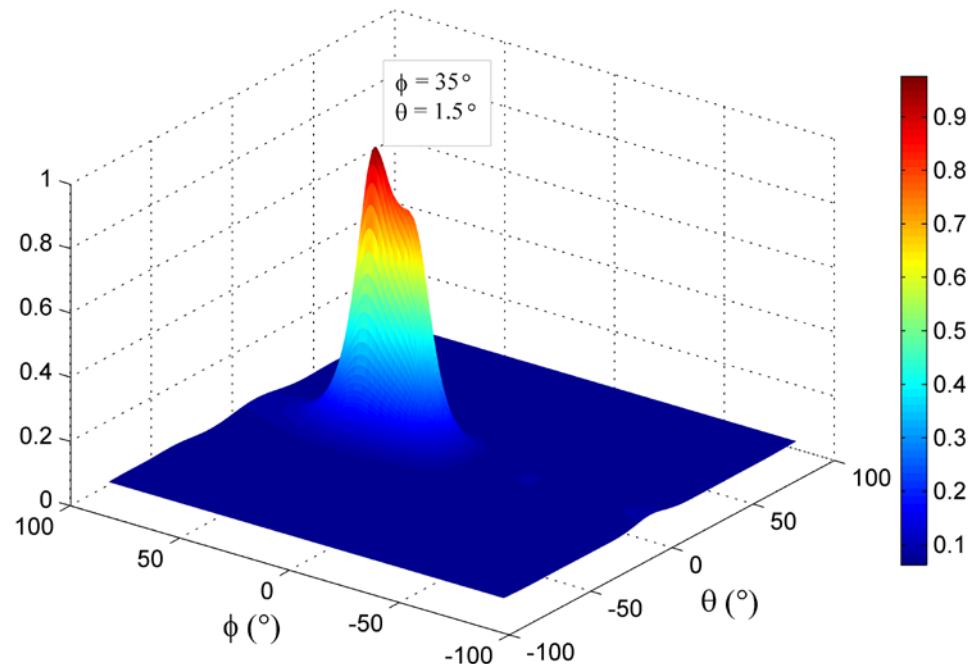
Sa druge strane, eksperimentalni rezultati demonstriraju mogućnost neuronskog modela da prevaziđe problem sa kojima se součava MUSIC algoritam sa SSP metodom. U Tabeli 8.6, prikazani su rezultati neuronskog modela naporedo sa procenjim pravcima koje daje MUSIC algoritam sa SSP metodom. Za rastojanje između predajnih antena od 2 m, može se videti da su rezultati neuronskog modela precizniji od rezultata MUSIC algoritma. U drugim scenarijima, neuronski model demonstrira bolje performanse od MUSIC algoritma pošto ima sposobnost da detektuje prisustvo oba koherentna EM izvora. U slučaju kada su antene razdvojene 1 m (11.4°) i postavljene na visinu koja je niža od prijemnog antenskog niza, neuronski model procenjuje ugaone pozicije izvora sa dobrom tačnošću, Tabela 8.6. U poređenju sa rezultatima simulacija, prikazanim u Tabeli 8.5, greška u proceni pravaca neuronskog modela je povećana (do 3.5° za uglove u azimutu koji se nalaze blizu granica sektora), usled efekata međusobne sprege između antenskih elemenata ili manjih odstupanja od referentnih ugaonih pozicija prilikom montiranja predajnih antena u anehoičnoj komori.

Na Slici 8.16, prikazana je zavisnost RMSE (*Root Mean Squared Error*) greške od rastojanja između predajnih antena. RMSE greška je izračunata na osnovu 21 merne tačke za sva tri rastojanja između predajnih antena. Može se zaključiti da greška procene pravaca kod neuronskog modela polako opada sa povećanjem rastojanja između antena. Tačnost neuronskog modela može biti dodatno povećana uključivanjem nekih merenih rezultata u proces njegove obuke.

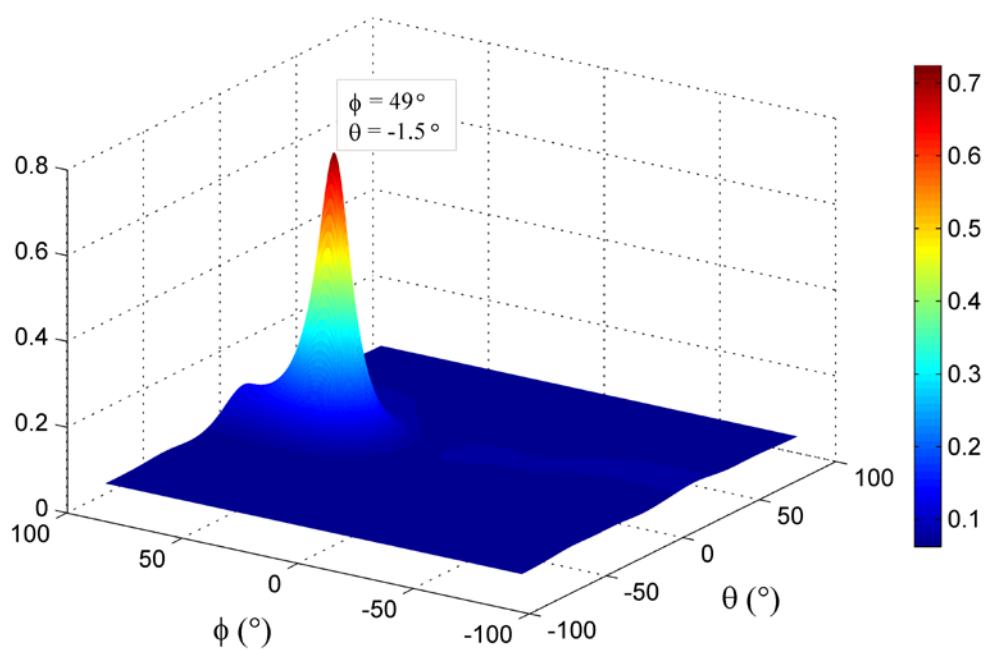
Za razliku od MUSIC algoritma čije su performanse jako zavisne od strukture prostorne kovarijansne matrice, neuronski model vrši njenu obradu na potpuno drugačiji način. Iz razloga što ne zahteva određivanje sopstvenih vrednosti koje odgovaraju signalu i šumu, neuronski model nije pogoden narušenom strukturom kovarijansne matrice i uvek će dati ugaone pozicije dva EM izvora. Paralelnom obradom prostorne kovarijansne matrice postiže se efikasnost i izbegava potreba za dekorelacijom signala na ulazu neuronskog modela. Ova karakteristika predloženog modela, kao i njegova sposobnost da rezultate obezbedi u delu sekunde kvalificuju ga kao moćan alat za preciznu procenu pravaca blisko postavljenih koherentnih izvora signala u realnom vremenu [96].



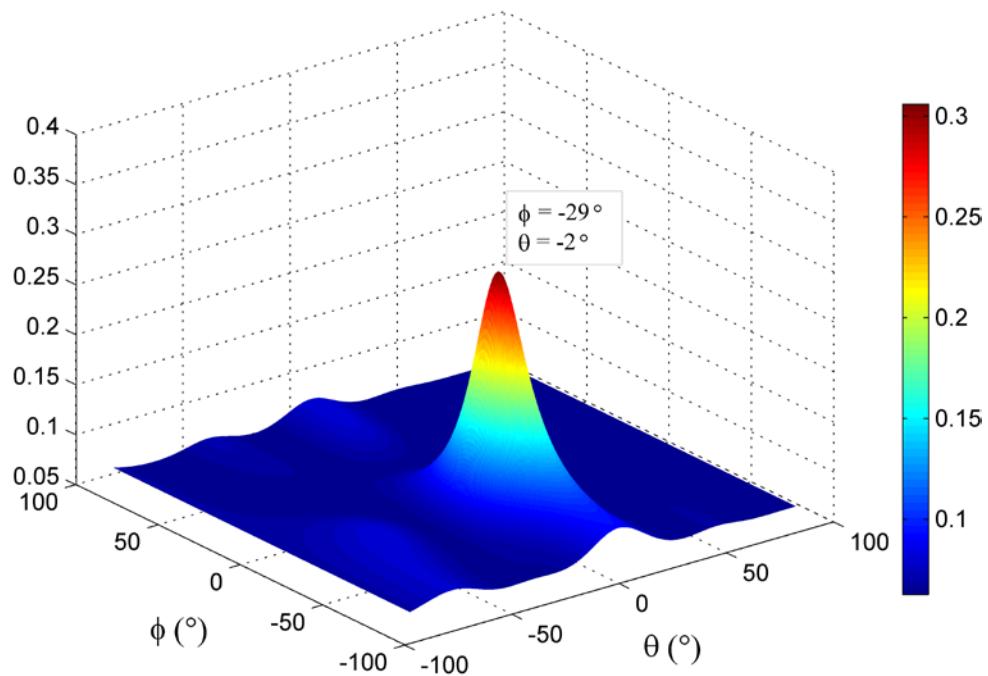
Slika 8.12 Spektar MUSIC algoritma za dva koherentna izvora čije su ugaone koordinate $(\varphi_1, \theta_1)=(-12.6^\circ, 0^\circ)$, $(\varphi_2, \theta_2)=(10^\circ, 0^\circ)$



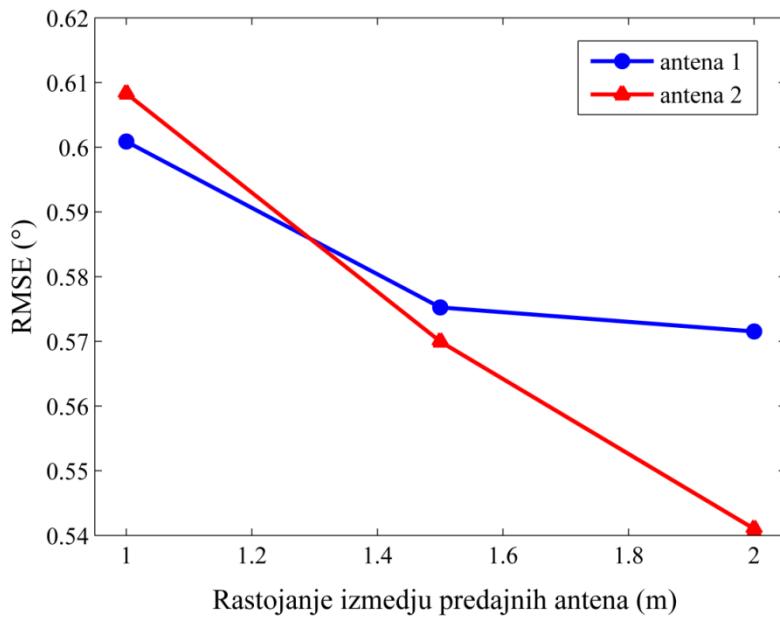
Slika 8.13 Spektar MUSIC algoritma za dva koherentna izvora čije su ugaone koordinate $(\varphi_1, \theta_1)=(21^\circ, 0^\circ)$, $(\varphi_2, \theta_2)=(38^\circ, 0^\circ)$



Slika 8.14 Spektar MUSIC algoritma za dva koherentna izvora čije su ugaone koordinate
 $(\varphi_1, \theta_1) = (33.6^\circ, -1.7^\circ)$, $(\varphi_2, \theta_2) = (45^\circ, -1.7^\circ)$



Slika 8.15 Spektar MUSIC algoritma za dva koherentna izvora čije su ugaone koordinate
 $(\varphi_1, \theta_1) = (-35^\circ, -3.4^\circ)$, $(\varphi_2, \theta_2) = (-23.6^\circ, -3.4^\circ)$



Slika 8.16 RMSE greška procene pravaca koherentnih EM signala u funkciji rastojanja između dve predajne antene

Tabela 8.6 Procenjeni uglovi u azimutu i elevaciji za četiri merna scenarija u anehoičnoj komori

Referentni pravci EM signala		Broj detektovanih izvora		Procenjeni pravci primenom MUSIC algoritma sa SSP metodom		Procenjeni pravci primenom neuronskog modela	
(φ_1, θ_1)	(φ_2, θ_2)	MUSIC algoritam sa SSP metodom	Neuronski model	$(\varphi_{1\text{est}}, \theta_{1\text{est}})$	$(\varphi_{2\text{est}}, \theta_{2\text{est}})$	$(\varphi_{1\text{est}}, \theta_{1\text{est}})$	$(\varphi_{2\text{est}}, \theta_{2\text{est}})$
$(-12.6^\circ, 0^\circ)$	$(10^\circ, 0^\circ)$	2	2	$(-13.5^\circ, 1.5^\circ)$	$(8^\circ, 1.5^\circ)$	$(-11.2^\circ, 0.1^\circ)$	$(9.4^\circ, 0.1^\circ)$
$(21^\circ, 0^\circ)$	$(38^\circ, 0^\circ)$	1	2	Nije detektovan	$(35^\circ, 1.5^\circ)$	$(20.7^\circ, 0.2^\circ)$	$(40.6^\circ, 0.2^\circ)$
$(33.6^\circ, -1.7^\circ)$	$(45^\circ, -1.7^\circ)$	1	2	Nije detektovan	$(49^\circ, -1.5^\circ)$	$(32.9^\circ, -2^\circ)$	$(47^\circ, -2^\circ)$
$(-35^\circ, -3.4^\circ)$	$(-23.6^\circ, -3.4^\circ)$	1	2	Nije detektovan	$(-29^\circ, -2^\circ)$	$(-38.0^\circ, -3.6^\circ)$	$(-20.7^\circ, -3.6^\circ)$

9 Procena pravaca EM signala različitih karakteristika

Performanse tehnika za procenu pravaca EM signala zavise od nekoliko parametara. Može se reći da ne postoji jedinstven algoritam koji se bez modifikacija i dodatnih procedura može primeniti u različitim situacijama u praksi. Performanse algoritama za procenu pravaca u velikoj meri zavise od:

- konfiguracije antenskog niza [97],
- broja izvora signala,
- odnosa signal/šum,
- korelacije između signala,
- vrste signala (uskopojasni, širokopojasni, deterministički, stohastički, radarski i drugi) [98]-[102], [105].

Takođe, algoritmi koji su primenljivi na procenu pravaca signala u azimutu nisu uvek primenljivi (čak ni sa modifikacijama) na procenu pravaca u azimutu i elevaciji.

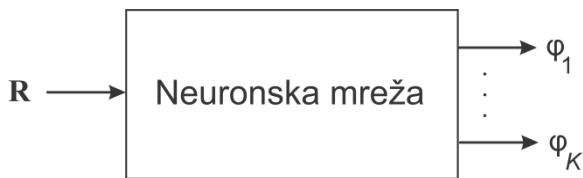
Iz navedenih razloga, u ovom delu će biti razmotrene performanse neuronskih modela u zavisnosti od nekih od nabrojanih parametara. Radi jednostavnosti prikaza razmatra se procena pravaca samo u azimutnoj ravni.

9.1 Uticaj odnosa signal/šum na performanse neuronskih modela

Osnovna ideja je primena neuronskih modela u proceni pravaca uskopojasnih signala, u prisustvu signala šuma. Model podataka koji se koristi za obuku i testiranje mreže je baziran na kružnom antenskom nizu i omogućava procenu pravaca podjednake tačnosti u celokupnom azimutu. Biće dokazana sposobnost neuronske mreže da odredi pravce dolaska signala čak i kada oni sadrže signal šuma. Procena pravaca je odradena u slučaju kada je broj signala unapred poznat, tako da nije potrebna dodatna obrada podataka kako bi se dobole vrednosti uglova u azimutu [98]-[99].

9.1.1 Osnovni koncept

Koncept neuronskog modela za procenu pravaca EM signala prikazan je na Slici 9.1. Ulaz u neuronsku mrežu je prostorna kovarijansna matrica primljenih signala na antenskom nizu, \mathbf{R} , a izlazi su procenjeni uglovi u azimutu. Broj neurona u ulaznom sloju mreže je određen dimenzijama matrice \mathbf{R} . U skladu sa procedurom za njeno preprocesiranje (Poglavlje 4), za antenski niz od N elemenata matrica \mathbf{R} je dimenzija $N \times N$, što znači da je broj ulaza u mrežu jednak N^2 .



Slika 9.1 Koncept neuronskog modela

Da bi se postigle zahtevane performanse, broj neurona u skrivenom sloju neuronske mreže mora biti veći ili jednak broju neurona u ulaznom sloju. Broj izlaza mreže je određen brojem izvora čije je pravce potrebno odrediti. Procena pravaca je izvršena primenom RBF neuronskih mreža. Različiti neuronski modeli su obučeni da odrede ugaone pozicije u azimutu različitog broja signala ($K=2, 3$), bez prisutnog signala šuma. Performanse RBF modela su ocenjene u okruženju sa prisutnim šumom za različite vrednosti odnosa SNR.

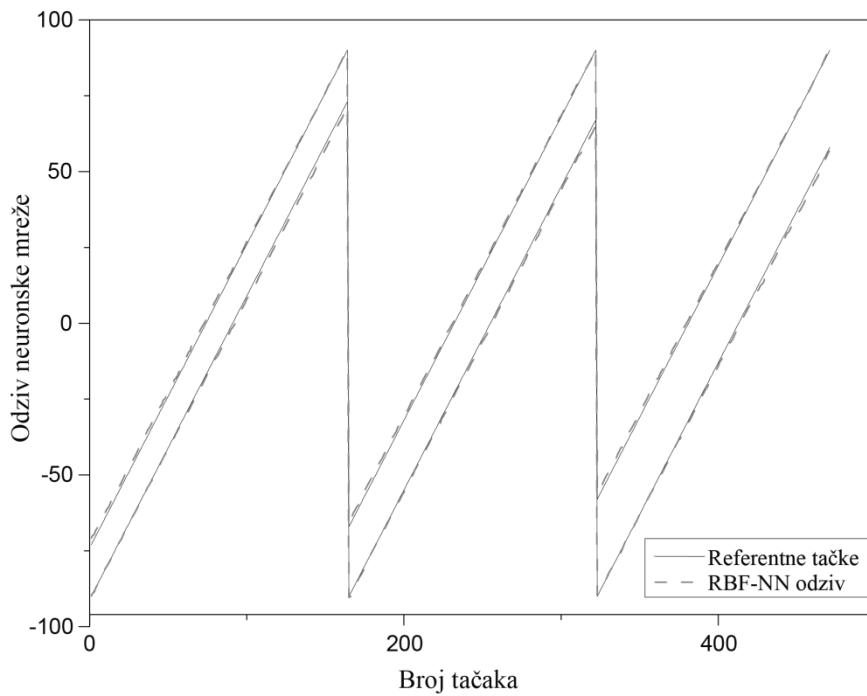
9.1.2 Numerički rezultati

Podaci za obuku i testiranje neuronske mreže su generisani za slučaj kružnog antenskog niza od 16 elemenata. Rastojanje između susednih elemenata jednako je polovini talasne dužine incidentnih EM talasa. Najpre se prati kretanje dva izvora signala u opsegu uglova u azimutu od -90° do 90° . Izvori se kreću sa korakom od 1° , na različitim međusobnim rastojanjima od $2^\circ, 3^\circ, 5^\circ, 10^\circ, 15^\circ, 20^\circ, 30^\circ, 40^\circ, 50^\circ$ i 60° , respektivno. Takođe je prepostavljen idealan slučaj kada primljeni signali na antenskim elementima ne sadrže signal šuma. RBF mreža za procenu pravaca dolaska EM signal obučena je primenom MATLAB ugrađenih funkcija. Kao kriterijum za obuku, uzeto je da srednje kvadratna greška (MSE, Mean Square Error) bude manja od 10^{-5} . Broj neurona u skrivenom sloju mreže je

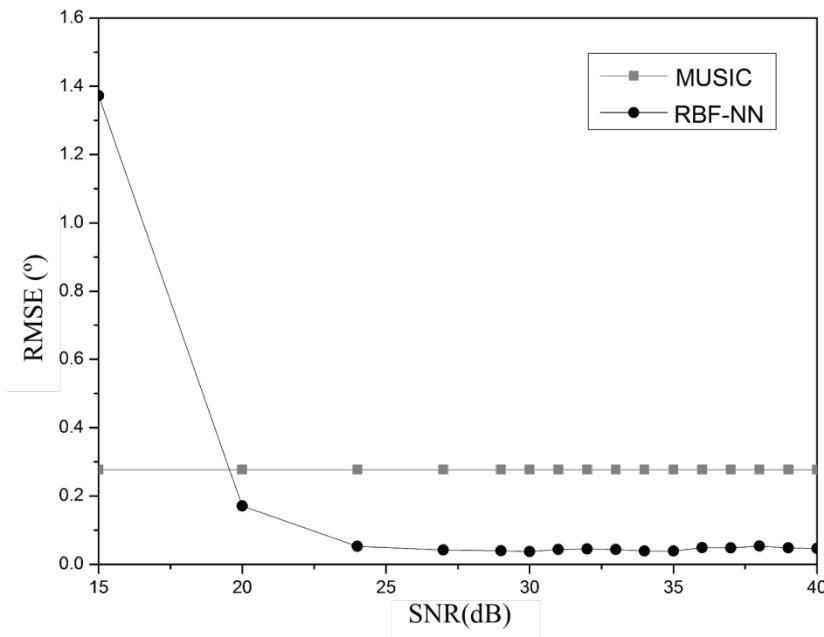
poznat tek na kraju procesa obuke neuronske mreže i najčešće je jednak ili veći od broja ulaznih neurona [103].

RBF mreža je zatim testirana za rastojanja koja nisu uključena u proces obuke mreže. Takođe, pretpostavljen je da primljeni signali sadrže beli *Gaussov* šum. Rezultati testiranja za dva izvora signala koja se kreću u opsegu $[-90^\circ, 90^\circ]$ i razdvojena 17° , 23° i 32° , respektivno, prikazani su na Slici 9.2. Može se zaključiti da postoji dobro slaganje između odziva RBF mreže i referentnih vrednosti. Nakon toga, izvršene su dodatne simulacije radi poređenja performansi neuronskog modela i standardnog MUSIC algoritma. Na ovaj način su dobijeni rezultati za različite vrednosti SNR-a. S obzirom da je neuronski model obučen podacima koji nisu obuhvatili signal šuma, na osnovu ovih simulacija izvršena je provera njegove tolerancije na šum odnosno, do kog nivoa SNR-a će ovako formirani model davati dobre rezultate. Na osnovu Slike 9.3 se može zaključiti da se performanse neuronskog modela naglo pogoršavaju za vrednosti SNR manje od 20 dB, iako za 15 dB neuronska mreža još uvek daje prihvatljive rezultate sa greškom (*RMSE, Root Mean Squared Error*) od oko 1.4° . Za vrednosti SNR veće od 20 dB performanse neuronske mreže nadmašuju MUSIC algoritam.

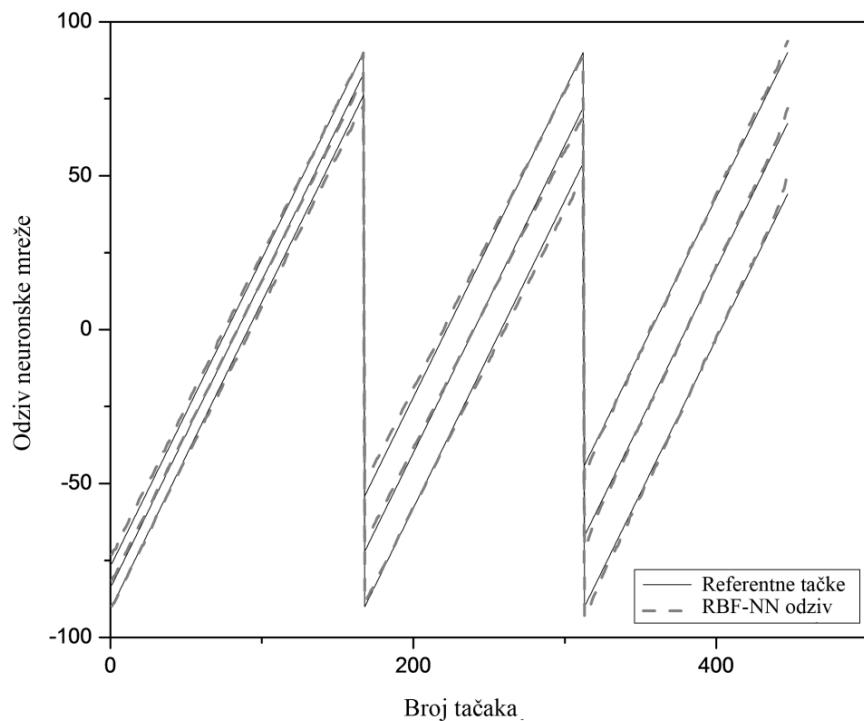
Sledeći korak predstavlja razvoj RBF neuronske mreže čija je uloga da simulira kretanje tri izvora signala u istom opsegu uglova u azimutu. Rastojanje između korisnika je uzeto na isti način kao i za slučaj dva izvora signala. Broj neurona u skrivenom sloju kao i kriterijum za obuku (MSE greška) su određeni kao u prethodnom slučaju. Odziv odgovarajuće RBF mreže je prikazan na Slici 9.4 za rastojanja između izvora od 17° , 23° i 32° . Na osnovu ovih rezultata, može se zaključiti da neuronski model vrši uspešnu predikciju pozicija tri izvora signala. Na Slici 9.5, dato je poređenje sa MUSIC algoritmom gde se može uočiti da performanse neuronskog modela rastu sa porastom vrednosti SNR-a i približavaju se vrednostima MUSIC algoritma [104].



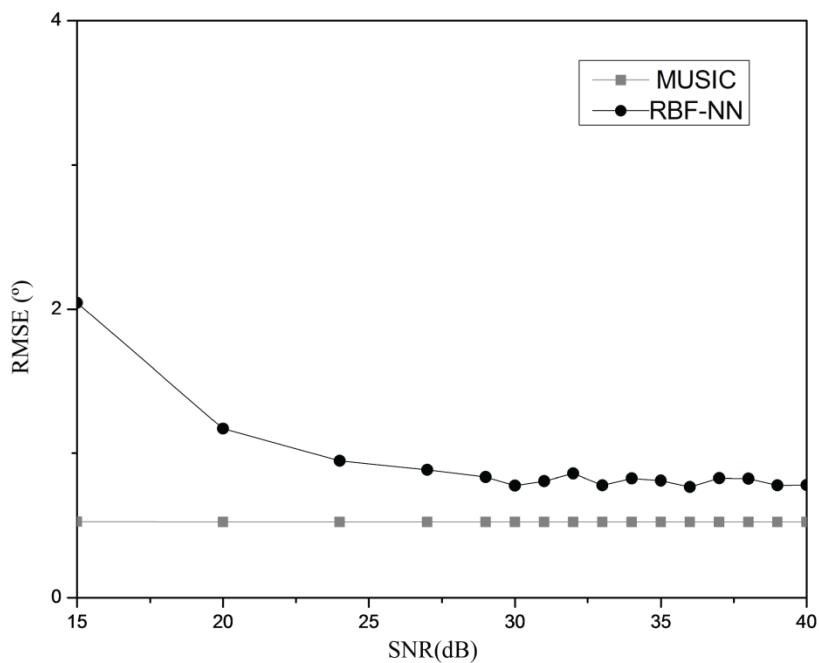
Slika 9.2 *Rezultati simulacije RBF neuronske mreže za dva korisnika međusobno razdvojena 17° , 23° i 32° , SNR=15 dB*



Slika 9.3 *Performanse RBF neuronske mreže i MUSIC algoritma u zavisnosti od odnosa signal/šum, u slučaju praćenja dva korisnika*



Slika 9.4 *Rezultati simulacije RBF neuronske mreže za tri korisnika međusobno razdvojena 17° , 23° i 32° , SNR=15 dB*



Slika 9.5 *Performanse RBF neuronske mreže i MUSIC algoritma u zavisnosti od odnosa signal/šum, u slučaju praćenja tri korisnika*

9.1.2 Zaključak

U ovom delu Poglavlja 9, razmotrena je primena RBF neuronskih mreža u proceni pravaca dva i tri nekorelisana signala u opsegu [-90°-90°]. Performanse razvijenih neuronskih modela su ocnjene na osnovu podataka za testiranje koji uključuju pozicije izvora i rastojanja između njih, koji nisu bili deo skupa za obuku. Rezultati su upoređeni sa MUSIC algoritmom i postignuto je dobro slaganje za veće vrednosti odnosa signal/šum. Na osnovu ovih rezultata i dodatnih simulacija došlo se do zaključka da neuronska mreža daje dobre rezultate u slučajevima kada SNR vrednosti odstupaju ± 5 dB od SNR-a koji je korišćen u procesu obuke neuronskih modela. Kao i kod ostalih algoritama za procenu pravaca, SNR takođe igra važnu ulogu u preciznosti dobijenih rezultata pomoću neuronskih mreža. Međutim, ovaj problem se može lako prevazići uključivanjem različitih vrednosti SNR-a u procesu obuke.

9.2 Uticaj korelacije signala na performanse neuronskih modela

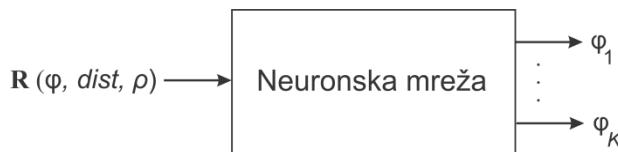
U praktičnim situacijama se često zahteva procena pravaca koreliranih signala. Usled prostiranja RF signala po višestrukim putanjama prijemni antenski niz sakuplja, pored direktnih signala EM izvora, i njihove delimično zakasnele komponente. Detekcija koreliranih signala predstavlja poseban problem jer performanse mnogih standardnih algoritama naglo opadaju kada je potrebno detektovati ovakav tip signala [6], [7]. Njihove modifikacije prevazilaze ovaj problem, primenom procedura za dekorelaciju signala što za posledicu može imati smanjenu rezoluciju procenjenih pravaca. Iz navedenog razloga, razmatra se primena neuronskih mreža za rešavanje ovog problema.

9.2.1 Osnovni koncept

U ovom delu su razmotrene performanse neuronskih mreža u detekciji koreliranih signala. Sa ciljem da se pokrije celokupan prostor u azimutu, upotrebljena je kružna konfiguracija antenskog niza na prijemu. Posebni neuronski modeli su obučeni za detekciju dva i tri izvora signala nakon čega su njihove performanse analizirane u zavisnosti od

rastojanja između izvora signala i stepena korelacije. Biće pokazano da primena neuronskih mreža u detekciji korelisanih signala ne narušava rezoluciju procenjenih pravaca u azimutu.

Razmotrićemo obuku neuronskih modela za slučaj detekcije dva i tri korelirana signala, redom, pri čemu se menjaju njihove pozicije u azimutu ($\varphi = [\varphi_1, \dots, \varphi_K]$), međusobna rastojanja ($dist$) i stepen korelacije (ρ), Slika 9.6. Cilj je da formirani modeli postignu tri nivoa generalizacije. Imajući u vidu da je broj izlaza neuronskih mreža fiksan, odvojene konfiguracije su razvijene za detekciju različitog broja izvora signala primenom ugrađenih MATLAB funkcija [73]. U oba slučaja, ulaz u mrežu je prostorna kovarijansna matrica \mathbf{R} , odnosno njen gornji trougaoni deo, organizovan u obliku vektora. Izlaz mreže su procenjene pozicije korelisanih signala u azimutu.



Slika 9.6 *Neuronska mreža za detekciju korelisanih signala*

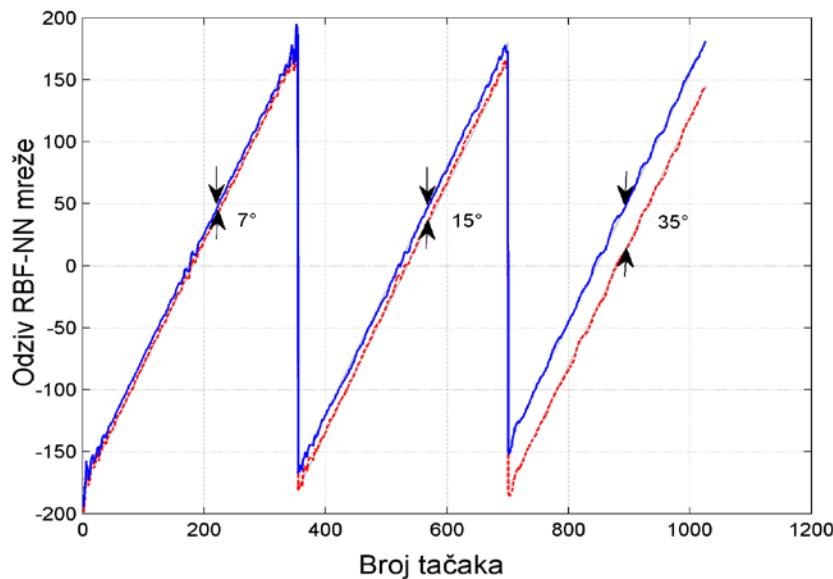
9.2.2 Numerički rezultati

Za prikupljanje podataka za obuku i testiranje neuronskih modela, pretpostavljeno je da se na prijemu nalazi kružni antenski niz sastavljen od 10 antenskih elemenata. Signali čije je pravce potrebno odrediti imaju vrednost SNR-a jednaku 20 dB. Za procenu kovarijanske matrice se koristi ukupno 1024 uzorka (*snapshota*) signala. Korelacija između signala varira od 0 do 1.

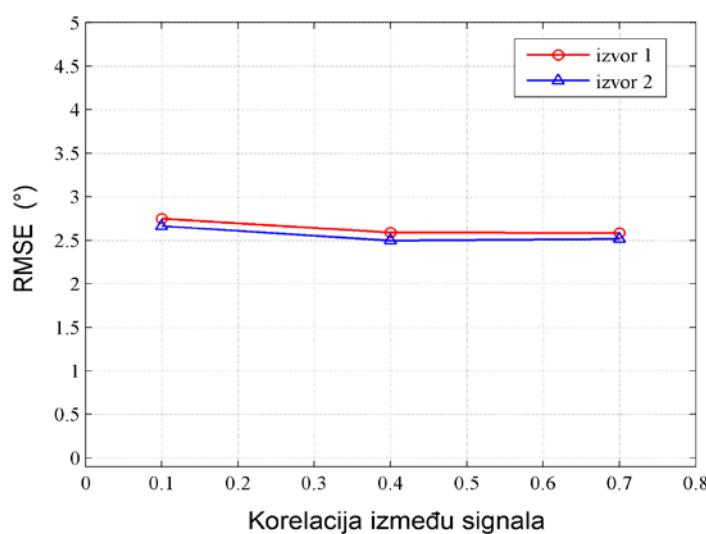
A. Detekcija dva korelirana izvora

Pretpostavićemo da su dva korelirana izvora signala pozicionirana na različitim uglovima u azimutu u opsegu uglova od -180° do 180° . Međusobna rastojanja između izvora se menjaju tako da uzimaju redom vrednosti: $2^\circ, 5^\circ, 10^\circ, 20^\circ, 30^\circ, 40^\circ, 50^\circ, 60^\circ, 70^\circ, 80^\circ, 90^\circ, 100^\circ, 110^\circ$ i 120° . Početne pozicije dva izvora signala su -180° i $-180^\circ + dist$, gde $dist$ označava rastojanje. Izvori se zatim kreću prema azimutnom uglu od 180° , sa korakom od 1° . Korelacija između signala je definisana kroz korelacioni koeficijent i uzima vrednosti 0, 0.5 i 1, respektivno. Za ocenu performansi obučenog neuronskog modela koristi se test set koji

podrazumeva rastojanje između izvora od 3° , 15° , 35° , 55° , 75° i 95° , sa korakom od 1° u opsegu $[-180^\circ - 180^\circ]$. Korelacioni koeficijent ima sledeće vrednosti 0.1, 0.4 i 0.7, respektivno. Prema tome, skup za obuku sadrži ukupno 6420 uzoraka dok je skupom za testiranje obuhvaćeno 3090 uzoraka. Sledеći proceduru za obuku RBF mreže, primenom funkcije implementirane u MATLAB-u, obučeno je više neuronskih modela pri čemu je najbolji među njima odabran za dalju analizu. U ovom slučaju, izdvojen je neuronski model sa korelacionim koeficijentom od 0.999, prosečnom greškom od 0.58% i 498 neurona u skrivenom sloju.



Slika 9.7 *Rezultati RBF-NN modela za detekciju dva izvora signala (-- izvor 1, - izvor 2), $\rho=1$*



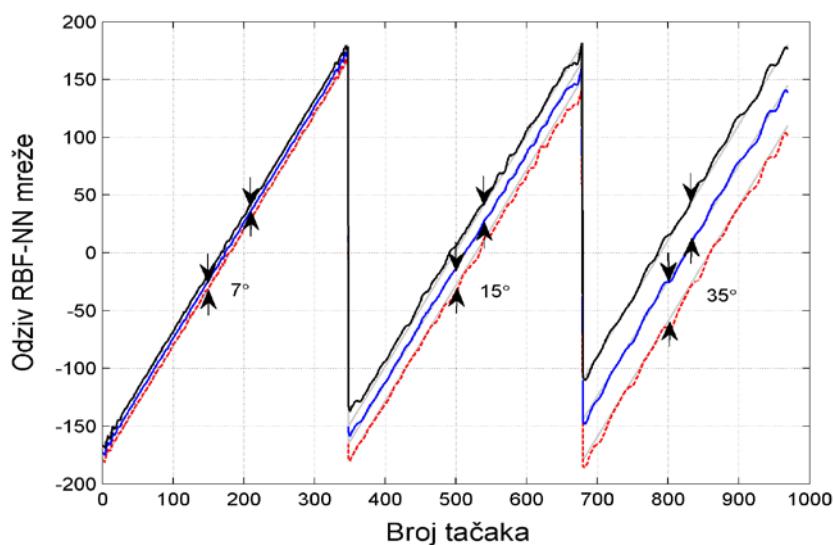
Slika 9.8 *RMSE greška u zavisnosti od stepena korelacije*

Odziv neuronskog modela za test podatke je prikazan na Slici 9.7, u slučaju korelacije između signala $\rho=1$ i rastojanja od 7° , 15° i 35° , redom. Može se zaključiti da neuronski model ima dobre generalizacione sposobnosti pri čemu razdvaja dva korelisana izvora signala čak i za mala rastojanja među njima (7°). Slika 9.8 ilustruje RMSE grešku u zavisnosti od stepena korelacije za tri test vrednosti koreacionog keoficijenta. Kao što se može videti, neuronski model daje skoro uniforman odziv za sve vrednosti koreacionog koeficijenta.

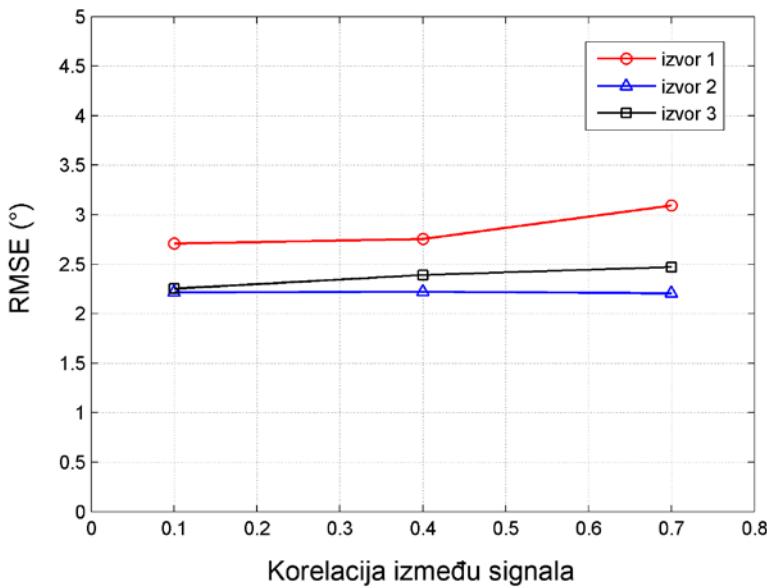
B. Detekcija tri korelisana izvora

Razmotrićemo slučaj detekcije tri korelisana signala u opsegu uglova u azimutu od -180° do 180° . Za formiranje skupa za obuku neuronskog modela obuhvaćena su sledeća rastojanja između korelisanih izvora signala: 2° , 5° , 10° , 20° , 30° , 40° , 50° , 60° , 70° , 80° , 90° , 100° , 110° i 120° . Na početku su izvori pozicionirani na azimutnim uglovima od -180° , $-180^\circ+dist$ i $-180^\circ+2\cdot dist$ (gde $dist$ označava rastojanje) a zatim se pomeraju prema 180° sa korakom od 1° . Korelacioni koeficijent između signala se menja tako da su signali najpre nekorelisani ($\rho=0$), zatim slabo korelisani ($\rho=0.5$) i na kraju potpuno koherentni ($\rho=1$).

Skup za testiranje je formiran za rastojanja između izvora od 12° , 23° , 32° , 64° i 96° , redom. Vrednosti korelacije su 0.1 , 0.4 i 0.7 . Samim tim mreža je obučena na osnovu 10440 uzoraka i testirana sa ukupno 4053 uzoraka. Nakon završene obuke analizirana je test statistika različitih neuronskih modela. Najbolji među njima ima korelacioni koeficijent 0.9993, prosečnu grešku na test uzorcima od 0.7% i 958 neurona u skrivenom sloju.



Slika 9.9 Rezultati RBF-NN mreže za detekciju tri izvora signala (— izvor 1, - izvor 2, - izvor 3), $\rho=1$



Slika 9.10 RMSE greška u zavisnosti od stepena korelacije

Na Slici 9.9, ilustrovan je odziv RBF mreže za tri rastojanja između izvora signala i korelacioni koeficijent jednak jedinici. Može se zaključiti da odziv mreže sasvim dobro prati kretanje tri izvora u opsegu -180° do 180° . RMSE greška procenjenih pravaca u azimutu je prikazana na Slici 9.10 za svaki korelisani izvor posebno. Najtačnije je procenjena pozicija drugog izvora i ona je skoro nezavisna od stepena korelacije. Greška u proceni pravaca prvog i trećeg izvora je nešto više izražena i blago raste kako korelacija između signala postaje jača. Takođe, može se zapaziti da neuronski model adekvatno razdvaja tri izvora na malom međusobnom rastojanju (7°). Na primer, MUSIC algoritam ima problem da razdvoji blisko postavljene izvore signala čak i kada su oni nekorelisani. U slučaju korelisanih signala se ovaj problem se dodatno pogoršava zbog smanjene aperture antenskog niza, što se može videti u [96].

Tabela 9.1 Rezultati RBF neuronskih mreža za test pozicije izvora signala

Referentni uglovi u azimutu ($^\circ$)			Procenjeni uglovi u azimutu ($^\circ$)		
$\varphi_1 = -10$	$\varphi_2 = 5$		$\varphi_{1\text{est}} = -8.48$	$\varphi_{2\text{est}} = 2.25$	
$\varphi_1 = -40$	$\varphi_2 = -5$		$\varphi_{1\text{est}} = -41.47$	$\varphi_{2\text{est}} = -2.32$	
$\varphi_1 = -2$	$\varphi_2 = 10$	$\varphi_3 = 22$	$\varphi_{1\text{est}} = -4.97$	$\varphi_{2\text{est}} = 9.09$	$\varphi_{3\text{est}} = 23.16$
$\varphi_1 = -2$	$\varphi_2 = 10$	$\varphi_3 = 22$	$\varphi_{1\text{est}} = -3.82$	$\varphi_{2\text{est}} = 9.64$	$\varphi_{3\text{est}} = 23.05$

9.2.3 Zaključak

Neuronske mreže su upotrebljene kao alat za ekstrakciju informacija iz prostorne kovarijansne matrice o pravcima dolaska koreliranih EM signala. Pokazano je da neuronske mreže daju dobre rezultate za različito pozicionirane i korelirane signale. Pored toga, neuronske mreže uspešno detektuju i razdvajaju blisko postavljene izvore. Tačnost rezultata se može dalje poboljšati korišćenjem manjeg koraka prilikom uzimanja uzoraka za formiranje skupa za obuku.

9.3 Neuronski model za detekciju MIMO OFDM radarskih signala

U ovom delu, izvršeno je istraživanje o primeni neuronskih mreža u proceni pravaca MIMO (*Multiple-Input Multiple-Output*) OFDM radarskih signala. OFDM radar i komunikacioni sistem (*RadCom*) predloženi u [105], prošireni su na MIMO konfiguraciju za lokalizaciju objekata u azimutu. Naime, pored ekstrakcije podataka o rastojanju i *Doppler*-u, MIMO OFDM sistemu je pridodata funkcija određivanja pravaca objekata. U ovu svrhu su razmatrani popularni metodi zasnovani na određivanju podprostora kao što je MUSIC, međutim, oni su se usled kompleksnih izračunavanja pokazali vremenski neefikasnim [106]. Kada se tome doda i kašnjenje usled obrade radarskog signala, dolazi se do zaključka da MUSIC i njemu slični algoritmi nisu pogodni za primenu u realnom vremenu. Iz tog razloga, razvijeni su neuronski modeli koji prevazilaze ograničenja standardnih algoritama za procenu pravaca. Poseban akcenat je stavljen na detekciju bliskih objekata čija je razvojenost manja od 5° .

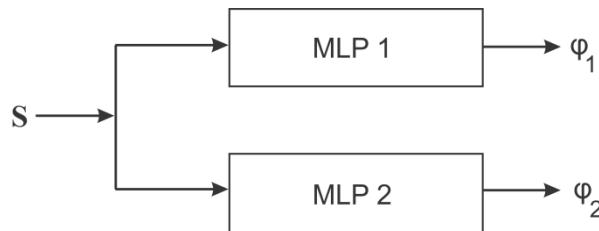
9.3.1 Osnovni koncept

U slučaju MIMO sistema predajna antena se sastoji od N_t antena dok je broj antena prijemnika jednak N_r . Rastojanje između antena prijemnika je $d_r = \lambda/2$, dok su antene predajnika postavljene u intervalima $d_t = N_r d_r$, što predstavlja maksimalno rastojanje pri kom ne dolazi do stvaranja neželjenih bočnih listova pri skeniranju uglova u azimutu do 180° . Na prijemnoj strani, obrada primljenih signala uključuje transformaciju $N_t \times N_r$ elemenata u

ekvivalentan $1 \times P$ "pseudo" prijemni niz, gde je $P=N_tN_r$ [107]-[109]. U ovom slučaju, upotrebljava se 4×4 antenska konfiguracija [111].

Iako se tehnike zasnovane na obradi podataka pomoću više antena mogu direktno primeniti na primljene signale u osnovnom opsegu, u slučaju OFDM radarskih signala se neuronske mreže primenjuju na obrađene radarske profile (*radar range profiles*), $h_i(k)$ gde je $i=1, 2, \dots, P$ i $k=1, 2, \dots, N$ (N označava broj podnosioca). Na ovaj način se količina podataka koju je potrebno obraditi svodi na minimum. Sa "pseudo" prijemnom antenom od P elemenata, izlazi svih elemenata se organizuju u obliku vektora $\mathbf{h}(k) = [h_1(k) \ h_2(k) \ \dots \ h_P(k)]$ na osnovu kog se generiše se kovarijansna matrica \mathbf{S} koja predstavlja ulaz u neuronski model.

Razmotrićemo slučaj detekcije dva objekta u opsegu uglova u azimutu od $[-20^\circ, 20^\circ]$. Procena pravaca objekata od kojih pristižu reflektovani signali vrši se pomoću dve odvojene MLP mreže, radi postizanja bolje tačnosti, Slika 9.11.



Slika 9.11 *Neuronski model za određivanje pozicija objekata u azimutu*

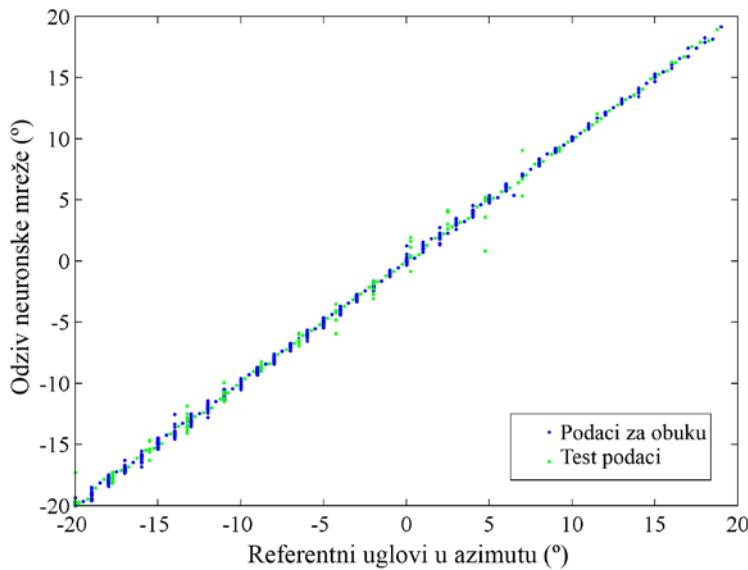
Ulaz u neuronski model je prostorna kovarijansna matrica izlaza prijemnog antenskog niza. Izlazi modela su ugaone pozicije objekata u azimutu. Broj neurona u ulaznom sloju obe MLP mreže zavisi od dimenzionalnosti kovarijansne matrice \mathbf{S} . S obzirom da je \mathbf{S} kvadratna matrica dimenzija $N_tN_r \times N_tN_r$ kao i da se njena prva vrsta može iskoristiti za ekstrakciju neophodnih informacija o pravcima u azimutu, broj neurona MLP mreža u ulaznom sloju je $2(N_tN_r)-1$. Broj izlaza modela je jednak broju objekata čije je pravce potrebno odrediti.

9.3.2 Numerički rezultati

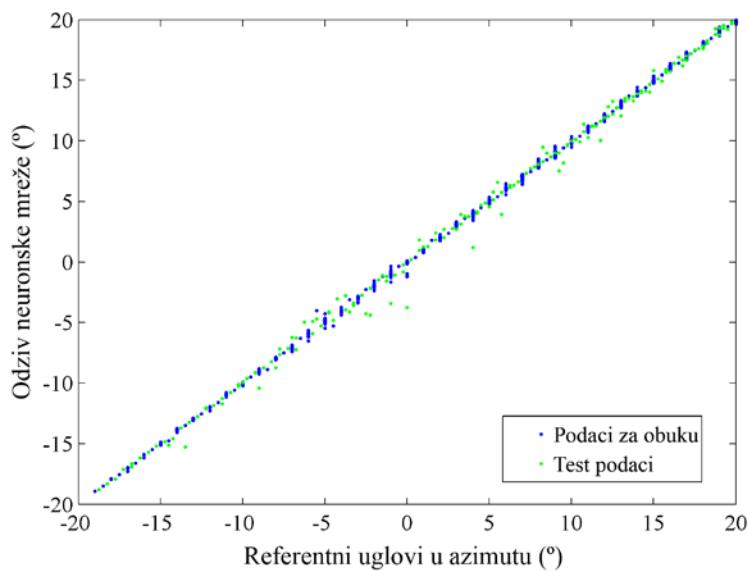
Skup za obuku se sastoji od ukupno 859 uzoraka koja se odnose na kretanje dva objekta u opsegu od $[-20^\circ, 20^\circ]$ sa korakom od 1° . Minimalno rastojanje između dva objekta

je 1° . Za svaku poziciju je određena prostorna kovarijansna matrica i organizovana u vektor. Broj neurona u ulaznom sloju MLP mreža je 31 i svaka od njih ima po jedan izlaz koji odgovara po jednom objektu. Broj neurona u dva skrivena sloja MLP mreža se određuje u procesu obuke neuronskih mreža. Na ovaj način je primenom LM (*Levenberg-Marquardt*) algoritma razvijeno više neuronskih mreža, nakon čega su odabrani modeli sa najboljim rezultatima na test skupu. Za prvi objekat, MLP mreža sadrži po 16 neurona u oba skrivena sloja, dok za drugi objekat odgovarajuća MLP mreža sadrži po 20 neurona u skrivenim slojevima. Korelacioni koeficijent na skupu za obuku neuronskog modela sa Slike 9.11 iznosi 0.9998. Generalizacione sposobnosti mreže ilustrovane su na Slikama 9.12 i 9.13, gde su prikazani rezultati neuronskog modela na skupu za obuku (plave tačke) i rezultati na test skupu od 177 uzoraka su slučajno odabrani u posmatranom opsegu (zelene tačke). Može se zaključiti da neuronski model daje korektne odzive u određivanju pravaca u azimutu oba objekata. Nešto veća odstupanja postoje u jako malom broju tačaka u blizini azimutnog ugla jednakog 0° , zbog čega se moraju uraditi dodatna istraživanja kako bi se ova odstupanja smanjila [111].

Primenom neuronskih mreža umesto MUSIC algoritma mogu se ostvariti značajne uštede u vremenu i računarskim resursima s obzirom da se ne vrši pretraga spektra po svim uglovima u azimutu. Pored efikasnosti u proceni pozicija objekata u azimutu, druga važna prednost neuronskog modela je njegova sposobnost da detektuje i razdvoji blisko postavljene objekte, na rastojanju manjem od 5° , Tabela 9.2 [106], [111].



Slika 9.12 Dijagram rasejanja MLP mreže za prvi objekat



Slika 9.13 Dijagram rasejanja MLP mreže za drugi objekat

Tabela 9.2 Referentni i procenjeni uglovi u azimutu

φ_{1_ref}	φ_{2_ref}	φ_{1_est}	φ_{2_est}
-19.75	-18.75	-19.7753	-18.6650
-16.50	-15.25	-16.3959	-15.1467
-12.50	-11.25	-12.4216	-11.2221
-8.50	-9.75	-8.3342	-9.5410
-7.50	-6.50	-7.3659	-6.2713
-5.50	4.00	-5.3294	-3.8061
-3.75	-2.50	-3.6145	-2.8915
-2.75	-1.75	-2.6932	-1.5639
-1.00	0.00	-1.1083	-0.1665
-1.50	0.00	-1.4522	-0.1965
0.00	1.50	0.0017	1.5650
1.50	3.00	1.6626	2.8694
4.75	5.50	4.6651	5.3939
5.50	6.50	5.3147	6.3561
8.80	9.75	8.5948	9.6799
10.25	11.50	10.3578	11.5950
12.50	13.50	12.5774	13.6257
15.25	16.50	15.0697	16.4561
17.50	18.50	17.5140	18.4333
18.50	20.00	18.4313	19.8891

9.3.3 Zaključak

Za procenu ugaonih pozicija dva objekta u azimutu može se uspešno primeniti neuronski model zasnovan na 4×4 MIMO OFDM radarskoj konfiguraciji. Na osnovu izvršenog poređenja rezultata neuronskog modela i MUSIC algoritma za istu postavku sistema kao u literaturi [106], došlo se do zaključka da neuronski model daje bolju procenu uglova u azimutu uz kraće vreme obrade i manje računarske resurse. Samim tim, predloženi model je pogodan za primenu sa MIMO OFDM radarem za lokalizaciju objekata u realnom vremenu.

10 Zaključak

Neuronski modeli su predloženi kao alternativno rešenje za procenu pravaca dolaska EM signala sa ciljem da se prevaziđu pojedina ograničenja standardnih algoritama i omogući povećanje performansi bežičnih komunikacionih sistema. Zahvaljujući veoma brzom prostiranju signala kroz neuronske modele, detekcija signala se ostvaruje za svega nekoliko milisekundi. Do sada dobijeni rezultati demonstriraju efikasnost neuronskih mreža u proceni pravaca različitih vrsta EM signala u azimutu i elevaciji.

Mogućnost primene neuronskih mreža u realnom vremenu je njihova glavna prednost u odnosu na ostale algoritme. U zavisnosti od uslova obuke mreža, njihov odziv može po preciznosti nadmašiti rezultate superrezolucijskih algoritama. S obzirom da performanse neuronskih mreža nisu toliko zavisne od strukture kovarijansne matrice, one mogu detektovati EM signale čak i kada je njihov broj veći od broja elemenata antenskog niza. Pored toga, karakteristike okruženja se mogu uključiti u proces obuke i na taj način poboljšati tačnost rezultata.

Rezultati koji predstavljaju originalni naučni doprinos disertacije odnose se na:

- razvoj sektorizacionog modela zasnovanog na kombinaciji MLP i RBF neuronskih mreža za procenu pravaca signala u azimutu i elevaciji sa visokom rezolucijom. Kod ovih modela, posmatrani prostor je podeljen na sektore u azimutu. Sektorizacioni model se sastoji od dva dela, pri čemu se u prvom vrši detekcija izvora signala (određivanje sektora), a u drugom se određuje ugao u azimutu i elevaciji, odnosno, pravac iz kog signal dolazi.
- razvoj empirijskih neuronskih modela za procenu pravaca dolaska EM signala u azimutu i elevaciji. Dat je opis korišćene opreme i mernog postupka za dobijanje podataka za obuku i testiranje neuronskih modela na jednoj frekvenciji, i u određenom frekvencijskom opsegu.
- razvoj kaskadnog neuronskog modela za procenu pravaca signala u azimutu i elevaciji. Najpre je razvijen osnovni neuronski model korišćenjem podataka za obuku koji su dobijeni simulacijama. U sledećem koraku je obučen empirijski neuronski model čija je uloga da koriguje izlazne vrednosti simulacionog neuronskog modela i približi ih željenim vrednostima. Testiranje kaskadnog modela je izvršeno merenim

podacima. Na ovaj način je kaskadnim modelom omogućena ispravna detekcija izvora signala u realnim uslovima.

- primenu RBF neuronskih mreža u proceni pravaca signala u azimutu, u slučaju kružnog antenskog niza. Pokazano je da je neuronski model, obučen podacima bez prisutnog belog šuma, u stanju da precizno proceni pravce iz kojih dolaze korisnički signali i u slučaju kada oni sadrže šum.
- primenu RBF neuronskih mreža u proceni pravaca koreliranih signala u azimutu. Detekcija koreliranih signala predstavlja veliki problem za većinu algoritama koji vrše određivanje ugaonih pozicija EM izvora i često rezultuje nedovoljno preciznom ili pogrešnom detekcijom izvora. Odgovarajućim odabirom uzorka i metoda za obuku, razvijen je neuronski model za preciznu procenu pravaca dolaska EM signala.
- razvoj neuronskih modela, zasnovanih na MIMO OFDM konfiguraciji, za efikasnu detekciju radarskih ciljeva u azimutu.

Za razvoj neuronskih modela korišćen je softver napisan u programskom paketu MATLAB. Podaci za obuku i testiranje neuronskih modela su obezbeđeni simulacijama i eksperimentalnim putem, odnosno, merenjem primljenih signala uz pomoć realizovanog pravougaonog antenskog niza. Svi dobijeni rezultati su upoređeni sa referentnim (očekivanim) rezultatima, kao i rezultatima MUSIC algoritma. Veći broj neuronskih modela je testiran merenim vrednostima, dobijenim merenjima primljenih signala na 4×4 pravougaonom antenskom nizu.

10.1 Pravci budućih istraživanja

Pravci budućih istraživanja u ovoj oblasti su:

- istraživanje mogućnosti primene neuronskih mreža u proceni pravaca većeg broja izvora signala. U ovom slučaju, neophodno je razviti novi model signala gde će se antenski niz sastojati od dva, odnosno tri, linearne antenske niza ($1L$ *shape array*, $2L$ *shape array*),
- razvoj hijerarhijskog neuronskog modela koji bi u prvom koraku vršio procenu pravaca, a u drugom *beamforming*, odnosno oblikovanje karakteristike zračenja antenskog niza kako bi se glavni list i bočni listovi zračenja usmerili prema željenim korisnicima a nule prema interferentnim signalima,

- razvoj neuronskih modela koji bi prilikom procene pravaca uzeli u obzir prostiranje signala po višestrukim putanjama.

Literatura

- [1] A. F. Molisch, *Wireless Communications (Second Edition)*, John Wiley & Sons, UK, 2010.
- [2] B. Allen, M. Ghavami, *Adaptive Array Systems: Fundamentals and Applications*, John Wiley & Sons, UK, 2005.
- [3] J. Foutz, A. Spanias, M. K. Banavar, *Narrowband Direction of Arrival Estimation for Antenna Arrays*, Morgan & Claypool Publishers, USA, 2008.
- [4] B. D. Van Veen, K. M. Buckley, “Beamforming: A Versatile Approach to Spatial Filtering,” *IEEE ASSP Magazine*, Vol. 5, 1988, pp. 4-24.
- [5] B. Ottersten, M. Viberg, T. Kailath, “Analysis of subspace fitting and ML techniques for parameter-estimation from sensor array data,” *IEEE Trans. on Signal Processing*, Vol. 40, No. 3, 1992, pp. 590-600.
- [6] R. Schmidt, “Multiple emitter location and signal parameter estimation,” *IEEE Trans. on Antennas and Propagation*, Vol. 34, No. 3, 1986, pp. 276–280.
- [7] R. Roy, T. Kailath, “ESPRIT-estimation of signal parameters via rotational invariance techniques,” *IEEE Trans. on Acoustics, Speech and Signal Processing*, Vol. 37, 1989, pp. 984–995.
- [8] B. D. Rao, K. V. S. Hari, “Performance analysis of root-MUSIC,” *IEEE Trans. on Acoustics, Speech and Signal Processing*, Vol. 37, No. 12, 1989, pp. 1939–1949.
- [9] S. U. Pillai, B. H. Kwon, “Forward/backward spatial smoothing techniques for coherent signal identification,” *IEEE Trans. on Acoustics, Speech and Signal Processing*, Vol. 37, 1989, pp. 8–15.
- [10] B. Ottersten, M. Viberg, T. Kailath, “Performance analysis of the total least squares ESPRIT algorithm,” *IEEE Trans. on Signal Processing*, Vol. 39, No. 5, 1991, pp. 1122-1134.
- [11] C. P. Mathews, M. D. Zoltowski, “Eigenstructure techniques for 2-D angle estimation with uniform circular arrays,” *IEEE Trans. on Signal Processing*, Vol. 42, No. 9, 1994, pp. 2395–2407.
- [12] A. Ferreol, E. Boyer, P. Larzabal, “Low cost algorithm for some bearing estimation methods in presence of separable nuisance parameters,” *Electronics Letters*, Vol. 40, 2004, pp. 966-967.

- [13] Y. S. Hou, J. Yong, L. J. Zhang, "Low cost algorithm for azimuth-elevation joint estimation," *9th International Conference on Signal Processing, ICSP*, Beijing, China, 2008, pp. 92-95.
- [14] N. Tayem, H. M. Kwon, "L-shaped 2-dimensional arrival angle estimation with propagator method," *IEEE Trans. on Antennas and Propagation*, Vol. 53, 2005, pp. 1622-1630.
- [15] L. Gan, J.-F. Gu, P. Wei, "Estimation of 2-D DOA for noncircular sources using simultaneous SVD technique," *IEEE Antennas and Wireless Propagation Letters*, Vol. 7, 2008, pp. 385-388.
- [16] M. Lin, L.-L. Cao, J. Ouyang, W. Shi, K. An, "DOA estimation using virtual array technique for noncircular signals," *Wireless Communications & Signal Processing (WCSP), 2012 International Conference on*, Huangshan, China, 2012, pp. 1-5.
- [17] P. Yang, F. Yang, Z.-P. Nie, "DOA estimation with sub-array divided technique and interpolated esprit algorithm on a cylindrical conformal array antenna," *Progress In Electromagnetics Research-PIER*, Vol. 103, 2010, pp. 201-216.
- [18] H. Seunghyeon, T. K. Sarkar, "Interpolation technique for direction of arrival (DOA) estimation using a transformation matrix through singular value decomposition," *Antennas and Propagation Society International Symposium, 2005 IEEE*, Vol. 4A, Washington, DC, 2005, pp. 130–133.
- [19] H. Seunghyeon, T. K. Sarkar, "Direction of arrival (DOA) estimation using a transformation matrix through singular value decomposition," *Wireless Communications and Applied Computational Electromagnetics, 2005. IEEE/ACES International Conference on*, 2005, pp. 353 – 356.
- [20] M. Donelli, F. Viani, P. Rocca, A. Massa, "An Innovative Multiresolution Approach for DOA Estimation Based on a Support Vector Classification," *Antennas and Propagation, IEEE Transactions on*, Vol. 57, No. 8, 2009, pp. 2279–2292.
- [21] X. Xu, Z. Ye, "Two-dimensional direction of arrival estimation by exploiting the symmetric configuration of uniform rectangular array," *IET Radar Sonar & Navigation*, Vol. 6, No. 5, 2012, pp. 307-313.
- [22] J. Chen, W. Shuxun, L. Lin, "Two-Dimensional DOA Estimation of Coherent Signals Based on 2D Unitary ESPRIT Method," *Signal Processing, 2006 8th International Conference on*, Vol. 1, Beijing, China, 2006.
- [23] Q. J. Zhang, K. C. Gupta, *Neural networks for RF and microwave design*, Artech House, Boston, MA, 2000.

- [24] A. H. El Zooghby, C. G. Christodoulou, M. Georgopoulos, “A neural network-based smart antenna for multiple source tracking,” *IEEE Trans. on Antennas and Propagation*, Vol. 48, 2000, pp. 768-776.
- [25] S. Çaylar, K. Leblebicioğlu, G. Dural, “A new neural network approach to the target tracking problem with smart structure,” *Proc. of IEEE AP-S International Symposium and USNC/URCI meeting*, Albuquerque, USA, 2006, pp. 1121-1124.
- [26] M. Wang, S. Yang, S. Wu, F. Luo, “A RBFNN approach for DOA estimation of ultra wideband antenna array,” *Neurocomputing-Elsevier*, Vol. 71, 2008, pp. 631–640.
- [27] H. He, T. Li, T. Yang, L. He, “Direction of Arrival (DOA) Estimation Algorithm Based on the Radial Basis Function Neural Networks,” *Advances in Intelligent and Soft Computing*, Vol. 128, 2011, pp. 389-394.
- [28] M. Sarevska, B. Milovanović, Z. Stanković, “Alternative Signal Detection for Neural Network Based Smart Antenna,” *NEUREL*, Belgrade, Serbia, 2004, pp. 85–89.
- [29] A. H. El Zooghby, C. G. Christodoulou, M. Georgopoulos, “Performance of radial basis function networks for direction of arrival estimation with antenna arrays,” *IEEE Trans. on Antennas and Propagation*, Vol. 45, 1997, pp. 1611–1617.
- [30] Z. Le, “Research on Direction of Arrival Estimation Algorithm in Smart Antenna,” *PhD dissertation*, South China University of Technology, Guangzhou, China, 2010.
- [31] Y. Zhang, Z. Gong, Y. Sun, “DOA Estimation in Smart Antenna Based on General Regression Neural Network,” *Journal of Military Communications Technology*, Vol. 28, 2007, pp. 23-25.
- [32] M. Sarevska, B. Milovanović, Z. Stanković, “Reliability of the Hidden Layer in Neural Network Smart Antenna”, *WSEAS Transaction on Communications*, Vol. 4, 2005, pp. 556-563.
- [33] N. Jorge, G. Fonseca, M. Coudyser, J.-J. Laurin, J.-J. Brault, “On the design of a compact neural network-based DOA estimation system,” *IEEE Trans. on Antennas and Propagation*, Vol. 58, 2010, pp. 357-366.
- [34] T. Matsumoto, Y. Kuwahara, “2D DOA estimation using beam steering antenna by the switched parasitic elements and RBF neural network,” *Electronics and Communications in Japan (Part I)*, Vol. 89, 2006, pp. 22-31.
- [35] Y. Kuwahara, T. Matsumoto, “Experiments on direction finder using RBF neural network with post-processing,” *Electronics Letters*, Vol. 41, 2005, pp. 602-603.
- [36] G. Ofek, J. Tabrikian, M. Aladjem, “A modular neural network for direction-of-arrival estimation of two sources,” *Neurocomputing*, Vol. 74, 2011, pp. 3092–3102.

- [37] L. C. Godara, *Smart Antennas*, CRC Press, FL, 2004.
- [38] J. C. Liberti, T. S. Rappaport, *Smart Antennas for Wireless Communications*, Prentice Hall, New Jersey, USA, 1999.
- [39] J. H. Winters, “Smart Antenna for Wireless Systems”, *IEEE Personal Communications*, Vol. 5, No. 1, 1998, pp. 23–27.
- [40] P. Lehne, M. Pettresen, “An Overview of Smart Antenna Technology for Mobile Communications Systems,” *IEEE Communications Surveys*, Vol.2, No.4, 1999.
- [41] R. J. Mailloux, *Phased array antenna handbook*, Artech House, Boston, MA, 1994.
- [42] C. A. Balanis, *Antenna theory: Analysis and Design (Second edition)*, John Wiley & Sons, Inc., New York, USA, 1997.
- [43] W. L. Stutzman, G. A. Thiele, *Antenna Theory and Design*, John Wiley & Sons, Inc., New York, USA, 1998.
- [44] V. Rabinovich, N. Alexandrov, *Antenna Arrays and Automotive Applications*, Springer Science & Business Media, New York, USA, 2013.
- [45] R. J. Mailloux, *Phased Array Antenna Handbook*, Artech House, Boston, MA, 1994.
- [46] H. L. Van Trees, *Detection, Estimation, and Modulation Theory, Optimum Array Processing (Part IV)*, John Wiley & Sons, Inc., New York, 2002.
- [47] F. I. Tseng, D. K. Cheng, “Optimum scannable planar arrays with an invariant sidelobe level”, *Proceedings of the IEEE*, Vol. 56, No. 11, 1968, pp. 1771–1778.
- [48] R. L. Haupt, D. H. Werner, *Genetic Algorithms in Electromagnetics*, Wiley-IEEE Press, New Jersey, USA, 2007.
- [49] A. Massa, M. Donelli, F. G. B. De Natale, S. Caorsi, A. Lommi, “Planar antenna array control with genetic algorithms and adaptive array theory,” *IEEE Trans. on Antennas and Propagation*, Vol. 52, No. 11, 2004, pp. 2919–2924.
- [50] J. Robinson, Y. Rahmat-Samii, “Particle swarm optimization in electromagnetics,” *IEEE Trans. on Antennas and Propagation*, Vol. 52, No. 2, 2004, pp. 397-407.
- [51] W. C. Weng, F. Yang, A. Elsherbeni, *Electromagnetics and Antenna Optimization Using Taguchi's Method*, Morgan & Claypool, San Rafael, CA, 2007.
- [52] M. T. Hagan, H. B. Demuth, M. H. Beale, *Neural Network Design*, PWS Publishing Company, Boston, MA, 1996.
- [53] S. Haykin, *Neural Networks*, Prentice Hall, Inc., New Jersey, USA, 1999.
- [54] S. E. Fahlman, C. Labiere, “The Cascade-Correlation Learning Architecture,” *Advances in Neural Information Processing Systems*, Vol. 2, 1990, pp. 524-532.

- [55] A. Weibel, T. Hanazawa, G. Hinton, K. Lang, “Phoneme recognition using time-delay neural networks,” *IEEE Trans. on Acoustics, Speech and Signal Processing*, Vol. 37, 1989, pp. 328-339.
- [56] Y. Le Cun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, L. D. Jackel, “Back-Propagation Applied to Handwritten Zippcode Recognition,” *Neural Computation*, 1990.
- [57] W. H. Press, S. A. Teukolsky, W. T. Vetterling, B. P. Flannery, *Numerical Recipes in C: the art of scientific computing*, Cambridge University Press, New York, USA, 1988.
- [58] D. S. Broomhead, D. Lowe, “Multivariable Functional Interpolation and Adaptive Networks,” *Complex Systems*, Vol. 2, No. 3, 1988, pp. 321-355.
- [59] S. Chen, C. F. N. Cowan, P. M. Grant, “Orthogonal Least Squares Algorithm for Radial Basis Function Networks,” *IEEE Transactions on Neural Networks*, Vol. 2, No. 2, 1991, pp. 302-309.
- [60] R. O. Duda, P. E. Hart, *Pattern Classification and Scene Analysis*, John Wiley & Sons, New York, USA, 1973.
- [61] Y. Cheng, “Mean shift, mode seeking, and clustering,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 17, No. 8, 1995, pp. 790-799.
- [62] D. G. Lowe, “Adaptive radial basis function nonlinearities, and the problem of generalization,” *1st International Conference on Artificial Neural Networks*, London, UK, 1989, pp. 171–175.
- [63] T. J. Sejnowski, C. R. Rosenberg, “Parallel Networks that Learn to Pronounce English Text,” *Complex Systems*, Vol. 1, 1987, pp. 145-168.
- [64] T. J. Shan, M. Wax, T. Kailath, “On spatial smoothing for estimation of coherent signals,” *IEEE Trans. on Acoustics, Speech and Signal Processing*, Vol. 33, 1985, pp. 806–811.
- [65] S. U. Pillai, B. H. Kwon, “Forward/backward spatial smoothing techniques for coherent signal identification,” *IEEE Trans. on Acoustics, Speech and Signal Processing*, Vol. 37, 1989, pp. 8–15.
- [66] H. Yi, X. Zhou, “On 2-D Forward-Backward Spatial Smoothing for Azimuth and Elevation Estimation of Coherent Signals,” *Antennas and Propagation Society International Symposium, 2005 IEEE*, Vol. 2B, 2005, pp. 80-83.
- [67] C. G. Christodoulou, M. Georgopoulos, *Application of neural networks in electromagnetics*, Artech House, December 2000.

- [68] P. B. Ober, E. F. Deprettere, A. J. van der Veen, "Efficient Methods to Compute Azimuth and Elevation in High-Resolution DOA Estimation," *International Conference on Acoustics, Speech, and Signal Processing (ICASSP-91)*, Toronto, Canada, Vol. 5, 1991, pp. 3349-3352.
- [69] A. J. van der Veen, P. B. Ober, E. F. Deprettere, "Azimuth and elevation computation in high resolution DOA estimation," *IEEE Trans. on Signal Processing*, Vol. 40, No. 7, 1992, pp. 1828–1832.
- [70] M. D. Zoltowski, M. Haardt, C. P. Mathews, "Closed-form 2-D angle estimation with rectangular arrays in element space or beamspace via unitary ESPRIT," *IEEE Trans. on Signal Processing*, Vol. 44, No. 1, 1996, pp. 316–328.
- [71] Y. Wu, G. Liao, H. C. So, "A fast algorithm for 2-D direction-of-arrival estimation," *Signal Processing*, Vol. 83, No. 8, 2003, pp. 1827–1831.
- [72] C. Hongguang, L. Biao, S. Zhenkang, "Efficient network training method for two-dimension DOA estimation," *Computer and Information Technology CIT '04*, 2004, pp. 1028–1032.
- [73] H. Demuth, M. Beale, *Neural network toolbox*, The Mathworks, Inc., MA, USA, 1998.
- [74] M. Agatonovic, Z. Stankovic, N. Doncov, L. Sit, B. Milovanovic, T. Zwick, "Application of artificial neural networks for efficient high-resolution 2D DOA estimation," *Radioengineering*, Vol. 21, 2012, pp. 1178-1186.
- [75] M. Agatonovic, Z. Stankovic, B. Milovanovic, "High Resolution Two-Dimensional DOA Estimation Using Artificial Neural Networks," *Conference Publications of the 6th European Conference on Antennas and Propagation (EUCAP 2012)*, Prague, Czech Republic, 2012, pp. 1-5.
- [76] I. J. Gupta, A. A. Ksinski, "Effect of mutual coupling on the performance of adaptive arrays," *IEEE Trans. on Antennas and Propagation*, Vol. 31, No. 5, 1983, pp. 785-791.
- [77] H. T. Hui, "Improved compensation for the mutual coupling effect in a dipole array for direction finding," *IEEE Trans. on Antennas and Propagation*, Vol. 51, No. 9, 2003, pp 2498-2503.
- [78] H. T. Hui, H. P. Low, T. T. Zhang, Y. L. Lu, "Receiving mutual impedance between two normal mode helical antennas (NMHAs)," *IEEE Antennas and Propagation Magazine*, Vol. 48, No. 4, 2006, pp. 92-96.

- [79] H.-S. Lui, C. H. Niow, H. T. Hui, "Improved DOA Estimations Using the Receiving Mutual Impedances for Mutual Coupling Compensation: An Experimental Study," *IEEE Trans. on Wireless Communications*, Vol. 10, No. 7, 2011, pp: 2228-2233.
- [80] N. Jorge, G. Fonseca, M. Coudyser, J.-J. Laurin, J.-J. Brault, "On the design of a compact neural network-based DOA estimation system," *IEEE Trans. on Antennas and Propagation*, Vol. 58, 2010, pp. 357-366.
- [81] T. Matsumoto, Y. Kuwahara, "2D DOA estimation using beam steering antenna by the switched parasitic elements and RBF neural network," *Electronics and Communications in Japan (Part I: Communications)*, Vol. 89, 2006, pp. 22-31.
- [82] Y. Kuwahara, T. Matsumoto, "Experiments on direction finder using RBF neural network with post-processing," *Electronics Letters*, Vol. 41, 2005, pp. 602-603.
- [83] <http://www.ni.com/dataacquisition/nidaqmx.htm>.
- [84] M. Agatonovic, Z. Stankovic, I. Milovanovic, N. Doncov, L. Sit, T. Zwick, B. Milovanovic, "Efficient neural network approach for 2D DOA estimation based on antenna array measurements," *Progress in Electromagnetic Research – PIER*, Vol. 137, 2013, pp. 741-758.
- [85] M. Agatonović, Z. Stanković, B. Milovanović, N. Dončov, L. Sit, T. Zwick, "Measurement Site and Procedures for Experimental 2D DOA Estimation," *ICEST 2012*, Veliko Tarnovo, Bulgaria, June 2012, pp. 311-314.
- [86] N. Parhizgar, A. Alighanbari, M. A. Masnadi-Shirazi, A. Sheikhi, "A modified decoupling scheme for receiving antenna arrays with application to DOA estimation," *International Journal of RF and Microwave Computer - Aided Engineering*, Vol. 23, 2013, pp. 246-259.
- [87] M. Agatonovic, Z. Stankovic, "Hybrid ANN Model for Accurate 2D DOA Estimation of a Radiating Source," *TELSIKS 2013*, Niš, Serbia, October, 2013, pp. 370-373.
- [88] M. Stoilković, Z. Stanković, B. Milovanović, "A cascade-connected neural model for improved 2D DOA estimation of an EM signal," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*. (rad pod recenzijom)
- [89] K. R. Dandekar, H. Ling, G. Xu, "Experimental study of mutual coupling compensation in smart antenna application," *IEEE Trans. on Wireless Communications*, Vol. 1, No. 3, 2002, pp. 480-487.
- [90] C. K. E. Lau, R. S. Adve, T. K. Sarkar, "Minimum norm mutual coupling compensation with applications in direction of arrival estimation," *IEEE Trans. on Antennas and Propagation*, Vol. 52, No. 8, August 2004, pp. 2034-2040.

- [91] S. Yang, Z. Nie, "Mutual coupling compensation in time modulated linear array antenna arrays," *IEEE Trans. on Antennas and Propagation*, Vol. 53, 2005, pp. 4182-4185.
- [92] R. Goossens, H. Rogier, "A hybrid UCA-RARE/Root-MUSIC approach for 2-D direction of arrival estimation in uniform circular arrays in the presence of mutual coupling," *IEEE Trans. on Antennas and Propagation*, Vol. 43, No. 3, 2007, pp. 841-849.
- [93] M. Agatonovic, Z. Stankovic, B. Milovanovic, I. Milovanovic, N. Doncov, "2D DOA Estimation of Two Coherent Sources based on RBF Neural Networks," *ICEST 2013*, Ohrid, Macedonia, June 26-29, 2013, pp. 429-432.
- [94] M. Agatonović, Z. Stanković, I. Milovanović, N. Dončov, B. Milovanović, "Neural Network Model for 2D DOA Estimation of Two Coherent Sources," *International Journal of Reasoning-based Intelligent Systems (IJRIS)*, Vol. 6, No. 2, 2014. (prihvaćen za publikovanje)
- [95] D. K. Cheng, *Field and Wave Electromagnetics*, Addison-Wesley Publishing Company, Inc., 1983, pp. 331-332.
- [96] M. Stoilković, Z. Stanković, I. Milovanović, N. Dončov, B. Milovanović, T. Zwick, "Experimental verification of an ANN based model for 2D DOA estimation of closely spaced coherent sources," *Microwave and Optical Technology Letters*, Vol. 56, No. 11, 2014, pp. 2558-2562.
- [97] M. Hajian, C. Coman, L. P. Ligthart, "Comparison of circular, Uniform- and non Uniform Y-Shaped Array Antenna for DOA estimation using MUSIC Algorithm", *Proceedings of the 9th European Conference on Wireless Technology*, Manchester, UK, September 2006.
- [98] M. Sarevska, B. Milovanovic, Z. Stankovic, "Alternative signal detection for neural network-based smart antenna," *NEUREL'04*, Belgrade, Serbia, September 2004.
- [99] M. Sarevska, B. Milovanovic, Z. Stankovic, "Antenna array system modeling using RBF neural network," *Proc. of the 6th International Symposium Nikola Tesla*, Belgrade, Serbia, October 2006.
- [100] Z. Stankovic, N. Dončov, B. Milovanovic, J. Russer, I. Milovanovic M. Agatonovic, "Neural Networks Based DOA Estimation of Multiple Stochastic Narrow-Band EM Sources," *TELSIKS 2013*, Niš, Serbia, 16.-19. October, 2013, pp. 526-529.

- [101] Z. Stanković, N. Dončov, I. Milovanović, B. Milovanović, M. Stoilković," DOA Estimation of Stochastic EM Signals," *ICEST 2014*, Niš, Serbia, June 25-27, 2014, pp. 347-350.
- [102] Z. Stanković, N. Dončov, J. Russer, I. Milovanović, M. Agatonović, "Neural Networks Based DOA Estimation of Multiple Stochastic Narrow-Band EM Sources," *Microwave Review*, Vol. 19, No. 2, December 2013, pp. 44-49.
- [103] M. Agatonović, Z. Stanković, B. Milovanović, N. Dončov, "DOA estimation based on radial basis neural networks as uniform circular antenna array processor," *TELSIKS 2011*, Vol. 2, Nis, Serbia, October 2011, pp. 544 – 547.
- [104] M. Stoilković, Z. Stanković, N. Dončov, B. Milovanović, "ANN Models for DOA Estimation of Correlated Signals using Circular Antenna Array," *ICEST 2014*, Niš, Serbia, June 25-27, 2014, pp. 343-346.
- [105] C. Sturm, T. Zwick, W. Wiesbeck, "An OFDM System Concept for Joint Radar and Communications Operations," *Vehicular Technology Conference, 2009. VTC Spring 2009. IEEE 69th*, Barcelona, Spain, April 2009, pp. 1–5.
- [106] Y. L. Sit, C. Sturm, J. Baier, T. Zwick, "Direction of Arrival Estimation using the MUSIC algorithm for a MIMO OFDM Radar," *Radar Conference, 2011 IEEE*, Atlanta, USA, May 2012, pp. 226-229.
- [107] K. Schuler, "Intelligente Antennensysteme für Kraftfahrzeug- Nahbereichs-Radar-Sensorik," *PhD dissertation*, Institut für Hochfrequenztechnik und Elektrotechnik, Universität Karlsruhe (TH), November 2007.
- [108] M. Braun, C. Sturm, A. Niethammer, F. Jondral, "Parametrization of Joint OFDM-based Radar and Communication Systems for Vehicular Applications," *Personal, Indoor and Mobile Radio Communications, 2009 IEEE 20th International Symposium*, September 2009, pp. 3020-3024.
- [109] C. Sturm, M. Braun, T. Zwick, W. Wiesbeck, "A Multiple Target Doppler Estimation Algorithm for OFDM based Intelligent Radar Systems," *Proceedings 7th European Radar Conference*, Paris, France, September 2010, pp. 73-76.
- [110] M. Takeda, T. Terada, R. Kohno, "Spread spectrum joint communication and ranging system using interference cancellation between a roadside and a vehicle," *IEEE 48th Vehicular Technology Conference*, Vol. 3, May 1998, pp. 1935-1939.
- [111] L. Sit, M. Agatonović, T. Zwick, "Neural Network based Direction of Arrival Estimation for a MIMO OFDM Radar," *EuRAD 2012*, Amsterdam, Netherlands, October 2012, pp. 298–301.

Biografija autora

Marija Stoilković (devojačko prezime: Agatonović) je rođena 12.01.1982. godine u Prokuplju. Osnovnu školu „Miloje Zakić“ i gimnaziju „Radoš Jovanović-Selja“ završila je u Kuršumliji. Elektronski fakultet u Nišu upisala je školske 2001/2002 godine, na smeru Telekomunikacije. Diplomirala je 03.10.2006. godine sa prosečnom ocenom u toku studija 9.35 (devet i 35/100) i ocenom 10 (deset) na diplomskom ispitu, čime je stekla zvanje diplomirani inženjer elektrotehnike za telekomunikacije. Diplomski rad pod nazivom „Mobilni sistemi četvrte generacije“ radila je na Katedri za telekomunikacije pod mentorstvom prof. dr Vere Marković. Bila je član tima Elektronskog fakulteta koji je na Elektrijadi 2006 u Ohridu osvojio treće mesto u oblasti Telekomunikacija.

Doktorske studije na Elektronskom fakultetu u Nišu upisala je školske 2007/2008 godine. Položila je sve ispite predviđene planom i programom Doktorskih studija sa prosečnom ocenom 10 (deset). Po upisu doktorskih studija, angažovana je u Laboratoriji za mikrotalasnu tehniku i satelitsku televiziju Elektronskog fakulteta u Nišu, kao istraživač stipendista Ministarstva prosvete i nauke Republike Srbije. Do sada je aktivno učestvovala u realizaciji dva projekta Ministarstva: „*Razvoj novih modela mikrotalasnih sklopova i uređaja za primenu u sistemima bežičnih komunikacija*“, evidencijski broj TR-11033, „*Istraživanje i razvoj rešenja za poboljšanje performansi bežičnih komunikacionih sistema u mikrotalasnem i milimetarskom opsegu frekvencija*“, evidencijski broj TR-32052.

U periodu od 23.05.2011. do 30.04.2012., bila je gostujući istraživač na institutu IHE (*Institut für Hochfrequenztechnik und Elektronik, KIT*), u Karlsruheu, Nemačka, u okviru projekta CARE (*Coordinating the Antenna Research in Europe*). Projekat je finansiran od strane EurAAP (*The European Association on Antennas and Propagation*). U 2012. godini dobila je stipendiju EUROWEB projekta, za studijski boravak u trajanju od 10 meseci na univerzitetu u L'Aquila, Italija. Od januara 2013. godine zaposlena je kao istraživač u Inovacionom centru naprednih tehnologija u Nišu. U januaru 2014. godine izabrana je u zvanje istraživač-saradnik.

Služi se engleskim, nemačkim i italijanskim jezikom.

Reference autora

M21: Radovi objavljeni u vrhunskim međunarodnim časopisima

- 1a. **Marija Agatonović**, Zoran Stanković, Ivan Milovanović, Nebojša Dončov, Leen Sit, Thomas Zwick, Bratislav Milovanović, "Efficient neural network approach for 2D DOA estimation based on antenna array measurements," *Progress In Electromagnetics Research-PIER*, Vol. 137, pp. 741-758, 2013, ISSN: 1070-4698, E-ISSN: 1559-8985. (**M21, IF 2011 5.298**)
[doi:10.2528/PIER13012114](http://www.jpier.org/pier/pier.php?paper=13012114)
<http://www.jpier.org/pier/pier.php?paper=13012114>

M22: Radovi objavljeni u istaknutim časopisima međunarodnog značaja

- 1b. **Marija Agatonović**, Zlatica Marinković, Vera Marković, "Application of ANNs in Evaluation of Microwave Pyramidal Absorber Performance," *Applied Computational Electromagnetics Society Journal*, Vol. 27, No. 4, pp. 326-333, 2012, ISSN: 1054-4887. (**M22 IF 2012 1.012**)
<http://www.aces-society.org/search.php?vol=27&no=4&type=2>

M23: Radovi objavljeni u časopisima međunarodnog značaja

- 1c. **Marija Agatonović**, Zoran Stanković, Nebojša Dončov, Leen Sit, Bratislav Milovanović, Thomas Zwick, "Application of Artificial Neural Networks for Efficient 2D DOA Estimation," *Radioengineering*, Vol. 21, No. 4, pp. 1178-1186, 2012, ISSN: 1210-2512. (**M23, IF 2012 0.687**)
www.radioeng.cz/fulltexts/2012/12_04_1178_1186.pdf
- 2c. **Marija Stoilković**, Zoran Stanković, Ivan Milovanović, Nebojša Dončov, Bratislav Milovanović, Thomas Zwick, "Experimental verification of an ANN based model for 2D DOA estimation of closely spaced coherent sources," *Microwave and Optical Technology Letters*, Vol. 56, No. 11, pp: 2558-2562, 2014, Online ISSN: 1098-2760. (**M23, IF 2013, 0.623**)
<http://onlinelibrary.wiley.com/doi/10.1002/mop.28635/abstract>

M52: Radovi objavljeni u domaćim časopisima ili međunarodnim časopisima koji nisu na SCI listi

- 1d. Zoran Stanković, Nebojša Dončov, Johannes Russer, Ivan Milovanović, **Marija Agatonović**, "Neural Networks Based DOA Estimation of Multiple Stochastic Narrow-Band EM Sources," *Microwave Review*, Vol. 19, No. 2, December 2013, pp. 44-49, ISSN: 14505835.
http://www.mtt-serbia.org.rs/microwave_review/pdf/Vol19No2-07-ZStankovic.pdf

- 2d. **Marija Agatonović**, Zoran Stanković, Ivan Milovanović, Nebojša Dončov, Bratislav Milovanović, "Neural Network Model for 2D DOA Estimation of Two Coherent Sources," *International Journal of Reasoning-based Intelligent Systems (IJRIS)*, Vol. 6, No. 2, 2014, pp. XXX, ISSN online: 1755-0564, ISSN print: 1755-0556. (prihvaćen za publikovanje)
<http://www.inderscience.com/jhome.php?jcode=ijris>

M53: Radovi objavljeni u domaćim časopisima

- 1e. **Marija Agatonović**, Vera Marković, "Bežični komunikacioni sistemi sa stratosferskim platformama," *Telekomunikacije*, No. 6, November 2010, pp. 64-72, ISSN: 1820-7782.
http://www.telekomunikacije.rs/arhiva_brojeva/sesti_broj/mr_marija_agatonovic_prof_dr_vera_markovic_bežični_komunikacioni_sistemi_sa_stratosferskim_platformama.345.html

M31: Predavanje po pozivu sa međunarodnog skupa štampano u celini

- 1f. Bratislav Milovanović, **Marija Agatonović**, Zoran Stanković, Nebojša Dončov, "Application of Neural Networks in Spatial Signal Processing," *NEUREL 2012*, Belgrade, Serbia, September 22-24, 2012, pp. 5-14, ISBN: 978-1-4673-1569-2.
doi : 10.1109/NEUREL.2012.6419950
http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6419950

M33: Saopštenje sa međunarodnog skupa štampano u celini

- 1g. **Marija Stoilković**, Zoran Stanković, Nebojša Dončov, Bratislav Milovanović, "ANN Models for DOA Estimation of Correlated Signals using Circular Antenna Array," *ICEST 2014*, Niš, Serbia, June 25-27, 2014, pp. 343-346.
http://www.icestconf.org/images/proceedings/icest_2014_01.pdf
- 2g. Zoran Stanković, Nebojša Dončov, Ivan Milovanović, Bratislav Milovanović, **Marija Stoilković**, "DOA Estimation of Stochastic EM Signals," *ICEST 2014*, Niš, Serbia, June 25-27, 2014, pp. 347-350.
http://www.icestconf.org/images/proceedings/icest_2014_01.pdf
- 3g. **Marija Agatonovic**, Zoran Stankovic, "Hybrid ANN Model for Accurate 2D DOA Estimation of a Radiating Source," *TELSIKS 2013*, Niš, Serbia, October 16-19, 2013, pp. 370-373, 2013, ISBN: 978-1-4799-0899-8.
http://www.telsiks.org.rs/TELSIKS_2013_Conference_Program.pdf
- 4g. **Marija Agatonovic**, Emidio Di Giampaolo, Piero Tognolatti, Bratislav Milovanovic, "Artificial Neural Networks for Ranging of Passive UHF RFID Tags," *TELSIKS 2013*, Niš, Serbia, October 16-19, 2013, pp. 505-508, 2013, ISBN: 978-1-4799-0899-8.
http://www.telsiks.org.rs/TELSIKS_2013_Conference_Program.pdf
- 5g. Zoran Stankovic, Nebojsa Doncov, Bratislav Milovanovic, Johannes Russer, Ivan Milovanovic, **Marija Agatonovic**, "Neural Networks Based DOA Estimation of

Multiple Stochastic Narrow-Band EM Sources," *TELSIKS 2013*, Niš, Serbia, October 16-19, 2013, pp. 526-529, 2013, ISBN: 978-1-4799-0899-8.
http://www.telsiks.org.rs/TELSIKS_2013_Conference_Program.pdf

- 6g. **Marija Agatonovic**, Zoran Stankovic, Bratislav Milovanovic, Ivan Milovanovic, Nebojsa Doncov, "2D DOA Estimation of Two Coherent Sources based on RBF Neural Networks," *ICEST 2013*, Ohrid, Macedonia, June 26-29, 2013, pp. 429-432, ISBN: 978-9989-786-90-7.
<http://www.icestconf.org/about-icest/paper-status>
- 7g. Ivan Milovanovic, Zoran Stankovic, **Marija Agatonovic**, Marija Milijic, "Efficient Neural Model for Estimation of the Microwave Antenna Noise Temperature," *ICEST 2013*, Ohrid, Macedonia, June 26-29, 2013, pp. 425-428, ISBN: 978-9989-786-90-7.
<http://www.icestconf.org/about-icest/paper-status>
- 8g. **Marija Agatonović**, Zoran Stanković, Bratislav Milovanović, Nebojša Dončov, Leen Sit, Thomas Zwick, "Empirical ANN model for 2D DOA estimation," *NEUREL 2012*, Belgrade, Serbia, September 22-24, 2012, pp. 15-19, ISBN: 978-1-4673-1569-2.
doi : [10.1109/NEUREL.2012.6419951](https://doi.org/10.1109/NEUREL.2012.6419951)
http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6419951
- 9g. **Marija Agatonović**, Zoran Stanković, Bratislav Milovanović, "High resolution two-dimensional DOA estimation using artificial neural networks," *EuCAP 2012*, Prague, Czech Republic, March 26-30, 2012, pp. 1-5, E-ISBN: 978-1-4577-0919-7, Print ISBN: 978-1-4577-0918-0.
doi : [10.1109/EuCAP.2012.6206729](https://doi.org/10.1109/EuCAP.2012.6206729)
<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?reload=true&arnumber=6206729&contentType=Conference+Publications>
- 10g. **Marija Agatonović**, Zoran Stanković, Bratislav Milovanović, Nebojša Dončov, Leen Sit, Thomas Zwick, "Measurement Site and Procedures for Experimental 2D DOA Estimation," *ICEST 2012*, Veliko Tarnovo, Bulgaria, Vol. 2, pp. 311-314, June 28-30, 2012, ISBN: 978-619-167-003-1.
http://www.icestconf.org/images/proceedings/icest_2012_02.pdf
- 11g. Leen Sit, **Marija Agatonović**, Thomas Zwick, "Neural Network based Direction of Arrival Estimation for a MIMO OFDM Radar," *EuRAD 2012*, October 28–November 2, Amsterdam, Netherlands, 2012, pp. 298 – 301, ISBN: 978-1-4673-2471-7.
http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6450703&tag=1
- 12g. **Marija Agatonović**, Zoran Stanković, Bratislav Milovanović, Nebojša Dončov, "An Approach in Linear Antenna Array Synthesis based on Artificial Neural Network Modelling," *MIT 2011*, Vrnjačka Banja and Budva, Serbia and Montenegro, August 27-September 5, 2011, pp. 12-16, ISBN: 978-86-83237-90-6.
<http://www.mit.rs/2011/zbornik-2011.pdf>
- 13g. **Marija Agatonović**, Zoran Stanković, Bratislav Milovanović, Nebojša Dončov, "DOA Estimation based on Radial Basis Neural Networks as Uniform Circular Antenna Array Processor," *TELSIKS 2011*, Niš, Serbia, October 5-8, 2011, Vol. 2, pp. 544-547, ISBN: 978-1-4577-2018-5.

doi : 10.1109/TELSKS.2011.6143173
http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=06143173

- 14g. Zoran Stanković, Bratislav Milovanović, Nebojša Dončov, **Marija Agatonović**, "Design of an Anechoic Chamber at the Faculty of Electronic Engineering in Niš," *ICEST 2010*, Ohrid, Macedonia, June 23-26, 2010, Vol. 2, pp. 567-572, ISBN: 978-9989-786-58-7.
http://www.icestconf.org/images/proceedings/icest_2010_02.pdf

M61: Predavanje po pozivu sa skupa nacionalnog značaja štampano u celini

- 1h. Bratislav Milovanović, **Marija Agatonović**, Zoran Stanković, Nebojša Dončov, "Novi pristup u prostornoj obradi signala zasnovan na upotrebi veštačkih neuronskih mreža," *POSTEL 2012*, Belgrade, Serbia, December 4-5, 2012, pp. 233-244.
<http://postel.sf.bg.ac.rs/downloads/simpozijumi/POSTEL2012/RADOVI%20PDF/Telekomunikacioni%20saobracaj,%20mreze%20i%20servisi/3.%20B.%20Milovanovic%20et%20al..pdf>

M63: Saopštenje sa skupa nacionalnog značaja štampano u celini

- 1i. **Marija Agatonović**, Zoran Stanković, Bratislav Milovanović, "Eksperimentalni rezultati primene 2D MUSIC algoritma za DOA estimaciju pomoću pravougaonog antenskog niza," *Zbornik radova (CD ROM)*, ETRAN 2012, Zlatibor, Serbia, June 11-14, 2012, ISBN: 978-86-80509-67-9.
<http://etran.etf.rs>
- 2i. **Marija Agatonović**, Zoran Stanković, Bratislav Milovanović, Nebojša Dončov, "A linear antenna array synthesis using artificial neural networks," *Zbornik radova (CD ROM)*, YUINFO 2011, Kopaonik, Serbia, March 6-9, 2011.
[http://conference.informationsociety.rs/index.php?conference=yuinfo&schedConf=2011&page=paper&op=view&path\[\]&path\[\]](http://conference.informationsociety.rs/index.php?conference=yuinfo&schedConf=2011&page=paper&op=view&path[]&path[])
- 3i. **Marija Agatonović**, Zlatica Marinković, Vera Marković, "Modelovanje mikrotalasnih piramidalnih apsorbera primenom veštačkih neuronskih mreža," *Zbornik radova (CD ROM)*, 19. Telekomunikacioni Forum TELFOR 2011, Belgrade, Serbia, November 22-24, 2011, pp. 1012-1015, ISBN: 978-1-4577-1500-6.
doi: 10.1109/TELFOR.2011.6143719
<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=06143719>
- 4i. Zoran Stanković, Bratislav Milovanović, Nebojša Dončov, **Marija Agatonović**, "Anehoična komora Laboratorije za antene, prostiranje i elektromagnetsku kompatibilnost Elektronskog fakulteta u Nišu," *Zbornik radova (CD ROM)*, YUINFO 2010, Kopaonik, Serbia, March 3-6, 2010.
<http://www.e-drustvo.org/proceedings/YuInfo2010/html/pdf/163.pdf>
- 5i. **Marija Agatonović**, Zoran Stanković, "Modeling of microwave pyramidal absorber using 3D EM solver WIPL-D," *Proceedings of Papers of 54th Conference ETRAN 2010 (CD ROM)*, Donji Milanovac, Serbia, June 7-11, 2010.
http://etran.etf.rs/etran2010/Program_ETRAN_2010.pdf

- 6i. **Marija Agatonović**, Bratislav Milovanović, "Synthesis and Analysis of a Reduced Size Planar Hybrid Ring," *Zbornik radova (CD ROM), 17. Telekomunikacioni Forum TELFOR 2009*, Belgrade, Serbia, November 24-26, 2009, pp. 839-842.
http://2009.telfor.rs/files/radovi/08_03.pdf

M85: Tehničko rešenje (nova metoda)

- 1j. **Marija Stoilković**, Zoran Stanković, Bratislav Milovanović, Nebojša Dončov, "Automatizovano merno mesto za karakterizaciju zračenja antenskih nizova i prostornu obradu signala antenskim nizovima," 2014.
<http://www.elfak.ni.ac.rs/rs/nauka/projekti/tehnicka-resenja/2239-automatizovano-merno-mesto-za-karakterizaciju-zracenja-antenskih-nizova-i-prostornu-obradu-signala-antenskim-nizovima>

Radovi u procesu recenzije

- 1k. **Marija Stoilković**, Zoran Stanković, Bratislav Milovanović, "A cascade-connected neural model for improved 2D DOA estimation of an EM signal," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*.
- 2k. Zoran Stanković, Nebojša Dončov, **Marija Stoilković**, Johannes Russer, Ivan Milovanović, Bratislav Milovanović, "Efficient DOA Estimation of Deterministic and Stochastic Electromagnetic Signals Using Artificial Neural Networks," *IEEE Transactions on Microwave Theory and Techniques*.

Izjave autora



Прилог 1.

ИЗЈАВА О АУТОРСТВУ

Изјављујем да је докторска дисертација, под насловом

Нови приступ у процени правца долазећег ЕМ сигнала заснован на примени вештачких
неуронских мрежа

- резултат сопственог истраживачког рада,
- да предложена дисертација, ни 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, нити злоупотребио/ла интелектуалну својину других лица.

у Нишу, 28.10.2014.

Аутор дисертације:

Марија Стоилковић

Потпис докторанда:

Марија Стоилковић



Прилог 2.**ИЗЈАВА О ИСТОВЕТНОСТИ ШТАМПАНЕ И ЕЛЕКТРОНСКЕ ВЕРЗИЈЕ ДОКТОРСКЕ
ДИСЕРТАЦИЈЕ**

Име и презиме аутора:

Марија Стоилковић

Студијски програм:

Телекомуникације

Наслов рада:

Нови приступ у процени правца долазећег ЕМ сигнала заснован на примени вештачких неуронских мрежа

Ментор:

проф. др Братислав Миловановић

Изјављујем да је штампана верзија моје докторске дисертације истоветна електронској верзији, коју сам предао/ла за уношење у **Дигитални репозиторијум Универзитета у Нишу**.

Дозвољавам да се објаве моји лични подаци, који су у вези са добијањем академског звања доктора наука, као што су име и презиме, година и место рођења и датум одбране рада, и то у каталогу Библиотеке, Дигиталном репозиторијуму Универзитета у Нишу, као и у публикацијама Универзитета у Нишу.

У Нишу, 28.10.2014.

Аутор дисертације:

Марија Стоилковић

Потпис докторанда:

Марија Стоилковић



Прилог 3.**ИЗЈАВА О КОРИШЋЕЊУ**

Овлашћујем Универзитетску библиотеку „Никола Тесла“ да, у Дигитални репозиторијум Универзитета у Нишу, унесе моју докторску дисертацију, под насловом:
"Нови приступ у процени правца долазећег EM сигнала заснован на примени вештачких неуронских мрежа"
која је моје ауторско дело.

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

Моју докторску дисертацију, унету у Дигитални репозиторијум Универзитета у Нишу, могу користити 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 подвучете само једну од шест понуђених лиценци; кратак опис лиценци је у наставку текста).

У Нишу, 28.10.2014.

Аутор дисертације:

Марија Стоилковић

Потпис докторанда:

Марија Стоилковић