

NOVI PRISTUP U PROSTORNOJ OBRADI SIGNALA ZASNOVAN NA UPOTREBI VEŠTAČKIH NEURONSKIH MREŽA

Bratislav Milovanović, Marija Agatonović, Zoran Stanković, Nebojša Dončov
Elektronski fakultet, Univerzitet u Nišu

Sadržaj: *U radu je prikazan novi metod za precizno određivanje pravca dolazećeg EM signala. Metod je zasnovan na primeni hijerarhijskog neuronskog modela čiji su gradivni elementi međusobno spregnute MLP (Multi-Layer Perceptron) i RBF (Radial Basis Function) neuronske mreže. Odgovarajuće obučeni hijerarhijski neuronski model, može se upotrebiti za preciznu procenu pravca dolazećeg EM signala u azimutu i elevaciji. Predloženi model ima veliku brzinu određivanja pravca dolazećeg signala i kao takav, veoma je pogodan za primenu u realnom vremenu. Istovremeno, tačnost rezultata dobijenih hijerarhijskim neuronskim modelom može se porediti sa super-rezolucijskim 2D MUSIC algoritmom.*

Ključne reči: *procena pravca dolazećeg EM signala, MLP, RBF, uniformni pravougaoni antenski niz.*

1. Uvod

Problem određivanja pravca dolazećeg EM signala proučavan je dugi niz godina. Danas je posebno važna njegova primena u mobilnim komunikacionim sistemima gde se informacija o pravcu signala korisnika prosleđuje algoritmima za adaptivni *beamforming*. Nakon toga se vrši optimizacija karakteristike zračenja antenskog niza odnosno, usmeravanje glavnog lista zračenja prema željenom korisniku i nula u karakteristici zračenja prema izvorima interferencije. S obzirom da je izabran samo željeni korisnik, nivo interferencije od drugih mobilnih korisnika sveden je na minimum. Najveći broj današnjih algoritama za DOA (*Direction of Arrival*) estimaciju zasnovani su obradi prostorne kovarijanske matrice signala koji se primaju sensorima antenskog niza. Najpoznatiji i najpouzdaniji algoritmi za procenu pravca, MUSIC (*Multiple User Signal Classification*) [1] i ESPRIT (*Estimation of Signal Parameters via Rotational Invariance Technique*) [2,3], vrše dekompoziciju prostorne kovarijanske matrice, određujući podprostore signala i šuma. Pretraživanjem spektra primljenih signala, MUSIC algoritam daje precizne rezultate po cenu veoma kompleksnih izračunavanja. Sa druge strane,

ESPRIT algoritam ima značajnu prednost u odnosu na MUSIC, jer ne traži maksimume u spektru. Kompleksnost izračunavanja kod ovog algoritma raste linearno sa povećanjem dimenzija antenskog niza dok je kod MUSIC algoritma ova zavisnost esponentijalna. U slučaju kada je potrebno odrediti ugaone pozicije izvora signala u obe ravni (azimut i elevacija), povećava se dimenzionalnost problema tako da vremenski zahtevan proces dekompozicije prostorne kovarijanske matrice onemogućava upotrebu 2D MUSIC i 2D ESPRIT algoritama u realnom vremenu.

Primena veštačkih neuronskih mreža u oblasti DOA estimacije predstavlja alternativu prethodno navedenim super-rezolucijskim algoritmima [4-15]. S obzirom na veoma brzo prostiranje signala kroz neuronske modele, njihova efikasnost u DOA estimaciji je neuporedivo veća od vremenski zahtevnih algoritama, zasnovanih na dekompoziciji prostorne kovarijanske matrice \mathbf{R} . Veštačke neuronske mreže posmatraju problem procene pravca dolazećeg EM signala kao preslikavanje između matrice \mathbf{R} i uglova u azimutu i elevaciji. U ovom radu je predstavljen pristup koji kombinuje MLP (*Multi-Layer Perceptron*) i RBF (*Radial Basis Function*) neuronske mreže, obučene da detektuju izvore signala i obezbede rezultate DOA estimacije u veoma visokoj rezoluciji. S obzirom da obavljaju samo klasifikaciju ulaznih vektora, MLP modeli se obučavaju podacima iz jako redukovano skupa DOA vrednosti. Za obuku RBF mreža za DOA estimaciju, koriste se znatno precizniji podaci. Ovakav pristup u obuci mreža znatno skraćuje vreme potrebno za obuku krajnjeg neuronskog modela [6,14]. Pokazano je da su neuronski modeli u mogućnosti da precizno procene pravac dolazećeg signala u opsegu uglova u azimutu od -90° to 90° , i elevaciji od -45° to 45° . Takođe, broj neurona u ulaznom sloju svake manje mreže je smanjen jer se samo prva vrsta prostorne kovarijanske matrice koristi za DOA estimaciju. U poređenju sa referencama [6-8], gde je sektorizacioni model formiran za slučaj 1D DOA estimacije, u ovom radu je razmotren kompleksniji dvodimenzionalni slučaj. Tačnost dobijenih rezultata je znatno bolja od onih prikazanih u referencama [9-11].

Rad je organizovan na sledeći način: u Sekciji 2 je dat model za obradu signala antenskim nizom. U Sekcijama 3 i 4, opisane su strukture RBF i MLP neuronskih mreža kao i odgovarajući algoritmi za obuku. U Sekciji 5, data je procedura za pretprocesiranje podataka za obuku neuronskih mreža. Primena sektorizacionog modela u 2D DOA estimaciji data je u Sekciji 6. U Sekciji 7, prikazani su rezultati simulacija i poređenje sa 2D MUSIC algoritmom. Poslednja sekcija u radu sadrži zaključke.

2. Model signala

Kako bi došli do jednačina zavisnosti primljenih signala na antenskom nizu i pravaca dolazećeg EM signala u azimutu i elevaciji, posmatraćemo pravougaoni antenski niz sačinjen od $M \times N$ omnidirekcionih antenskih elementa, kao što je prikazano na Slici 1. Svaki antenski element je određen svojim koordinatama (m, n) , gde je $m=0, 1, 2, \dots, M-1$ i $n=0, 1, 2, \dots, N-1$. Pretpostavićemo da su antenski elementi raspoređeni duž y - i z -ose sa jednakim rastojanjem između elemenata d_y i d_z , respektivno. Kako bi se izbegao prostorni *aliasing*, ovo rastojanje je obično jednako polovini talasne dužine EM signala odnosno, $d_y=d_z=d=\lambda/2$.


Pravci dolazećeg EM zračenja predstavljeni su preko parametara sfernog koordinatnog sistema. Za K uskopojasnih signala, sa centralnom frekvencijom ω_0 , koji

dolaze do uniformnog pravougaonog antenskog niza pod uglovima $\{(\varphi_1, \theta_1), (\varphi_2, \theta_2), \dots, (\varphi_k, \theta_k)\}$ u azimutu i elevaciji, vektor primljenih signal na antenskom nizu se može napisati u sledećem obliku

$$\mathbf{x}(t) = \mathbf{A}(\varphi, \theta)\mathbf{s}(t) + \mathbf{n}(t), \quad (1)$$

gde su $\mathbf{x}(t)$, $\mathbf{n}(t)$, i $\mathbf{s}(t)$ dati sa

$$\begin{aligned} \mathbf{x}(t) &= [x_{00}(t) \ x_{01}(t) \ \dots \ x_{0N-1}(t) \ x_{10}(t) \ x_{11}(t) \ \dots \ x_{M-1N-1}(t)]^T \\ \mathbf{n}(t) &= [n_{00}(t) \ n_{01}(t) \ \dots \ n_{0N-1}(t) \ n_{10}(t) \ n_{11}(t) \ \dots \ n_{M-1N-1}(t)]^T \\ \mathbf{s}(t) &= [s_1(t) \ s_2(t) \ \dots \ s_k(t)]^T. \end{aligned} \quad (2)$$



Slika. 1. Uniformni pravougaoni antenski niz

Vektor $\mathbf{n}(t)$ predstavlja vektor šuma jer se pretpostavlja da primljeni signali u sebi sadrže i određeni nivo belog šuma. Vektor signala koji potiču od izvora označen je sa $\mathbf{s}(t)$. Pravci dolazećih EM signala određuju se na osnovu faznih razlika signala primljenih na različitim antenskim elementima. Ukoliko se za referentni element za izračunavanje faze odabere antenski element pozicioniran u koordinatnom početku $(m, n) = (0, 0)$, tada se faza k -tog incidentnog signala na antenski element sa koordinatama (m, n) , može odrediti pomoću sledećeg izraza

$$\phi_{m,n}^{(k)}(\varphi_k, \theta_k) = \frac{2\pi}{\lambda} (d_y m \cos\theta_k \sin\varphi_k + d_z n \sin\theta_k). \quad (3)$$

Dalje, *steering* vektor k -tog incidentnog signala se može napisati u sledećem obliku

$$\mathbf{a}^{(k)} = [a_{00}^{(k)} \ a_{01}^{(k)} \ \dots \ a_{0N-1}^{(k)} \ a_{10}^{(k)} \ a_{11}^{(k)} \ \dots \ a_{mn}^{(k)} \ \dots \ a_{M-1N-1}^{(k)}] \quad (4)$$

$$a_{mn}^{(k)} = a_{mn}^{(k)}(\varphi_k, \theta_k) = e^{j\phi_{m,n}^{(k)}(\varphi_k, \theta_k)}$$

gde je $k = 1, 2, \dots, K$. $\mathbf{A}(\varphi, \theta)$ u (1) predstavlja *steering* matricu čije su kolone *steering* vektori, usmerenih prema K različitih pravaca dolazećih signala, i može se izraziti kao

$$\mathbf{A}(\varphi, \theta) = [\mathbf{a}^{(1)} \ \mathbf{a}^{(2)} \ \mathbf{a}^{(3)} \ \dots \ \mathbf{a}^{(k)} \ \dots \ \mathbf{a}^{(K-1)} \ \mathbf{a}^{(K)}] \quad (5)$$

Za DOA estimaciju neophodno je odrediti prostornu kovarijansnu matricu primljenih signala \mathbf{R} . Ova matrica se dobija na osnovu sledećeg izraza

$$\begin{aligned} \mathbf{R} &= E\{\mathbf{x}(t)\mathbf{x}(t)^H\} = \mathbf{A}E[\mathbf{s}(t)\mathbf{s}(t)^H]\mathbf{A}^H + E[\mathbf{n}(t)\mathbf{n}(t)^H] \\ &= \mathbf{A}\mathbf{R}_{xx}\mathbf{A}^H + \sigma_{noise}^2 \mathbf{I} = \sum_{i=1}^{M \times N} \lambda_i \mathbf{e}_i \mathbf{e}_i^H. \end{aligned} \quad (6)$$


U (6), $\mathbf{R}_{xx} = E[\mathbf{s}(t)\mathbf{s}(t)^H]$ predstavlja korelacionu matricu primljenih signala, λ_i su sopstvene vrednosti matrice \mathbf{R} , σ_{noise}^2 je varijansa statistički nezavisnog belog šuma, dok oznaka H stoji za konjugovano transponovani signal. U praksi je prostorna kovarijansna matrica \mathbf{R} nepoznata i procenjuje se na osnovu određenog broja vremenskih uzoraka izlaza elemenata antenskog niza

$$r_{ij} = \frac{1}{S} \sum_{k=1}^S x_i(k) \cdot x_j^*(k) \quad (7)$$

gde je $x_i(k)$ k -ti uzorak i -tog elementa, $x_j(k)$ je k -th uzorak j -tog elementa i S je ukupan broj uzoraka. Na osnovu jednačina (1)-(6), može se zaključiti da uniformni pravougaoni antenski niz vrši preslikavanje $G: \mathbf{R}^K \rightarrow \mathbf{C}^{(M \times N)}$ iz prostora pravaca dolazećih EM signala, $\Phi = [(\varphi_1, \theta_1), (\varphi_2, \theta_2), \dots, (\varphi_K, \theta_K)]^T$ u prostor signala na izlazu antenskog niza $\{\mathbf{x}(t) = [x_{00}(t) \ x_{01}(t) \ \dots \ x_{M-1N-1}(t)]^T\}$.

3. RBF (*Radial Basis Function*) neuronske mreže

Neuronska mreža je sistem sastavljen od velikog broja jednostavnih elemenata za obradu podataka koji rade paralelno. Kod svih elemenata (neurona), donošenje odluka je simultano uzimajući u obzir promene u globalnom stanju mreže. Funcionalnost mreže je određena njenom strukturom, težinskim koeficijentima veza između neurona i načinom obrade signala u njima. Kod RBF neuronskih mreže, neuroni su organizovani u tri sloja, ulazni, izlazni i jedan skriveni sloj. Neuron svakog sloja u mreži je povezan sa svim neuronima u narednom sloju, dok veze između neurona istog sloja nisu dozvoljene. Svaki neuron karakteriše prenosna funkcija, a svaku vezu težinski koeficijent. Neuroni u ulaznom i izlaznom sloju imaju linearne prenosne funkcije dok su neuroni skrivenog sloja okarakterisani nelineranom (radijalno-bazisnom) prenosnom funkcijom.



Slika 2. Primer jedne neuronske mreže

Najvažniji parametri radijalno-bazisne funkcije su centralni vektor i standardna devijacija [4], [5]. Funkcija preslikavanja zavisi od rastojanja između ulaznog i centralnog vektora. RBF mreža sa n -dimenzionalnim ulazom $x \in R^n$ i m -dimenzionalnim izlazom $y \in R^m$ može se predstaviti težinskom sumom konačnog broja radijalno-bazisnih funkcija na sledeći način

$$y = F(x) = \sum_{i=1}^L w_i \psi(\|x - x_i\|) \quad (8)$$

gde je $\psi(\|x - x_i\|)$ radijalno-bazisna funkcija vektora \mathbf{x} , dobijena transliranjem $\psi(\|x\|)$ za x_i , L je set proizvoljnih funkcija dok su x_i centri radijalno-bazisnih funkcija. Funkcija $\psi(\|x - x_i\|)$ ima svoj minimum na $x = x_i$ i monotono opada do nule kako se $\|x - x_i\|$ približava beskonačnosti. Radijalno bazisna funkcija $\psi(\|x - x_i\|)$ ima istu vrednost za sve ulaze neuronske mreže koji leže na hipersferi sa centrom u x_i . U jednačini (8), ψ predstavlja nenormalizovanu Gausovu funkciju koja se može napisati u sledećem obliku

$$\psi(x) = e^{\frac{-x^2}{2\sigma^2}} \quad (9)$$

gde σ označava standardnu devijaciju radijalno-bazisne funkcije. Gausova funkcija je jako nelinearna i samim tim, ima dobre karakteristike za primenu u inkrementalnom učenju.

Mreža se obučava setom ulazno-izlaznih vektora. U toku procesa obuke, skrivenom sloju se dodaje po jedan neuron po iteraciji sa centrom koji odgovara ulaznom vektoru sa najvećom greškom. Nakon toga, vrši se ažuriranje težina između neurona. Ova procedura se ponavlja sve dok se ne ispuni prethodno definisani kriterijum za srednje kvadratnu grešku (MSE - *Mean Squared Error*), ili maksimalni broj neurona u skrivenom sloju. Standardna devijacija (*spread*) radijalno-bazisne funkcije ima istu vrednost za sve neurone u skrivenom sloju. Pošto optimalna vrednost ovog parametra nije unapred poznata, on se obično eksperimentalno određuje kroz obuku nekoliko neuronskih modela i poređenje njihovih performansi. Konačan broj neurona u RBF mreži poznat je tek nakon

njene obuke. Jednom obučena mreža daje tačne rezultate i za ulazne vektore koji nisu korišćeni u procesu obuke. Skup podataka (vektora) za testiranje neuronske mreže formira se na osnovu iste raspodele kao i skup korišćen za obuku neuronske mreže (opseg uglova u azimutu i elevaciji je isti, razlikuju se ugaone pozicije izvora EM signala). Performanse obučeni RBF mreža mogu se 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 . Korelacioni koeficijent između referentnih vrednosti i odziva mreže može se definisati sledećim izrazom

$$r = \frac{\sum (p_i - \bar{p})(q_i - \bar{q})}{\sqrt{\sum (p_i - \bar{p})^2 \sum (q_i - \bar{q})^2}} \quad (10)$$

gde p_i predstavlja referentnu vrednost, q_i je odziv neuronske mreže, \bar{p} je srednja vrednost referentnog uzorka dok \bar{q} predstavlja srednju vrednost odziva mreže. Korelacioni koeficijent pokazuje u kojoj meri odziv mreže odgovara referentnim vrednostima. Vrednost bliska jedinici ukazuje na dobre performanse neuronske mreže.

4. MLP (Multi-Layer Perceptron) neuronske mreže

MLP neuronske mreže su sastavljene od ulaznog, izlaznog i nekoliko skrivenih slojeva. Sa jednim ili dva skrivena sloja one mogu da aproksimiraju bilo koje preslikavanje. Zahvaljujući ovoj osobini, MLP mreže su veoma pogodne za modelovanje više-dimenzionalnih i izrazito nelinearnih problema [12], [13].

U ovom radu su MLP neuronske mreže sa dva skrivena sloja upotrebljene u detekcionom delu predloženog sektorizacionog modela. MLP mreže predstavljaju veoma moćne klasifikatore i demonstriraju superiorne performanse u poređenju sa drugim tipovima neuronskih mreža. Međutim, dugo vreme obuke i problem sa lokalnim minimumima predstavljaju najveće teškoće pri razvoju MLP neuronskih modela. Njihovo vreme konvergencije je sporije nego u slučaju RBF mreža ali su uprkos tome, zbog njihove sposobnosti da obezbede rezultate veće tačnosti odbrane su za ulogu klasifikatora u detekcionom delu hijerarhijskog modela.

U procesu obuke MLP mreža, najpre se formiraju dva skupa. Trening skup sadrži podatke za razvoj klasifikatora dok se za procenu performansi neuronskih modela koristi test skup. Najpoznatiji algoritam za obuku MLP neuronskih modela je *backpropagation algoritam* i njegove modifikacije kao što su *kvazi-Newton* ili *Levenberg-Marquardt* algoritmi [4]. Sledeći ovu proceduru, izlaz l -tog sloja mreže se može izraziti kao

$$Y_l = F(W_L Y_{l-1} + B_l) \quad (11)$$

gde su Y_l i Y_{l-1} izlazi l -og i $(l-1)$ -og sloja, respektivno, W_l je matrica težina između $(l-1)$ -og i l -tog sloja i B_l je matrica biasa između slojeva $(l-1)$ i l . F označava aktivacionu (prenosnu) funkciju neurona koja je linearna za neurone u ulaznom i izlaznom sloju i tan-sigmoidna za neurone u skrivenom sloju

$$F(u) = (1 - e^{-u}) / (1 + e^{-u}) . \quad (12)$$

Nakon izračunavanja odziva neuronske mreže vrši se poređenje sa referentnim vrednostima i određuje greška. U sledećem koraku se izračunavaju izvodi greške i sabiraju za svaki težinu i bias sve dok se celokupni skup za obuku ne prikaže mreži. Izvodi greške se koriste za ažiriranje težina i biasa neurona u modelu nakon čega se proces obuke nastavlja sve dok se ne ispune unapred definisani kriterijumi za srednje kvadratnu grešku ili maksimani broj epoha [4]. Obučena neuronska mreža daje brz i tačan odziv za različite ulazne vektore, pa tako i za one koji nisu bili uključeni u skup za obuku. Performanse trenirane MLP neuronske mreže se može izraziti u vidu maksimalne greške, srednje greške ili korelacionog koeficijenta [4], [5].

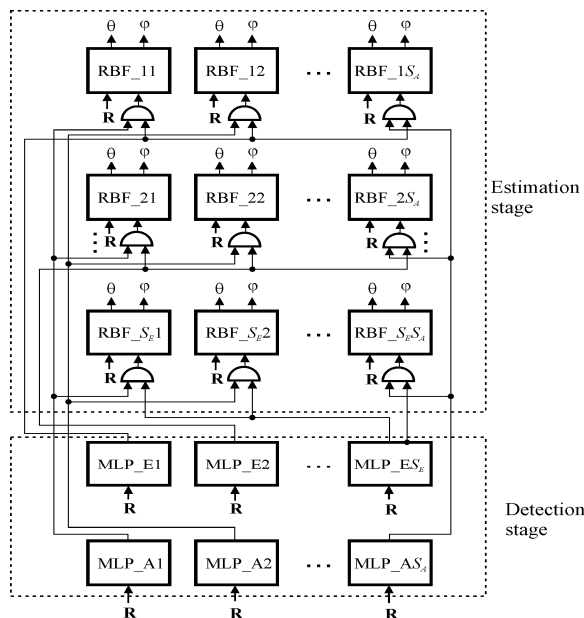
4. Pretprocesiranje podataka

Primena veštačkih neuronskih mreža u oblasti DOA estimacije predstavlja preslikavanje $G: \mathbf{C}^{(M*N)} \rightarrow \mathbf{R}^K$, iz prostora primljenih signala na antenskom nizu $\{\mathbf{x}(t)=[x_{00}(t) x_{01}(t) \dots x_{M-1N-1}(t)]^T\}$, u prostor pravaca dolazećeg EM zračenja $\Phi=[(\varphi_1, \theta_1), (\varphi_2, \theta_2), \dots, (\varphi_K, \theta_K)]^T$. Ulaz u neuronsku mrežu je prostorna kovarijanska matrica \mathbf{R} primljenih signala, dok su pravci dolazećih EM signala odziv mreže. Broj neurona u ulaznom sloju mreže zavisi od dimenzija matrice \mathbf{R} . S obzirom da je $\mathbf{R} (M*N) \times (M*N)$ kvadratna matrica i imajući u vidu da neuronske mreže ne mogu da rade sa kompleksnim brojevima, ulazni sloj mreže sadrži $2(M*N)^2$ neurona. Za razvoj oba tipa neuronskih mreža (MLP i RBF) u ovom radu, formiran je redukovani set za obuku gde se za prikaz signala na izlazu antenskog niza koristi se samo prva vrsta prostorne kovarijanske [7]. Elementi prve vrste matrice \mathbf{R} organizovani su u vektor \mathbf{b} , koji sadrži $2(M*N) - 1$ elemenata. Pre nego što se dovede na ulaze neuronske mreže, vektor \mathbf{b} se normalizuje svojom sopstvenom normom, $\mathbf{z} = \mathbf{b}/\|\mathbf{b}\|$. Primenjajući ovaj postupak dimenzionalnost ulaznih vektora je značajno smanjena i omogućava efikasniju obuku neuronskih modela.

4. Sektorizacioni model

Koncept sektorizacionog modela za dobijanje veoma preciznih podataka o pravcu dolazećeg signala, prikazan je na Slici 3. U prvom delu predloženog modela detektuje se prisustvo izvora signala u sektoru posle čega se u drugom delu modela određuje pravac dolazećeg EM signala. S_E i S_A predstavljaju broj sektora u azimutu i elevaciji, respektivno. MLP mreže u detekcionom delu imaju ulogu klasifikatora i daju na izlazu nulu ukoliko je izvor signala van posmatranog sektora i jedinicu, za izvor u sektoru. Odgovarajuću RBF mrežu u delu za estimaciju će aktivirati samo jedinica na izlazu obe MLP mreže (azimuth i elevacija) određenog sektora. Na ovaj način je omogućena detekcija izvora EM zračenja u veoma visokoj rezoluciji.

Kako bi ilustrovali performanse predloženog pristupa, izvršena je simulacija sektorizacionog modela sastavljenog od neuronskih mreža. Softver je napisan u MATLAB-u, pri čemu su podrazumevani sledeći parametri: uniformni pravougaoni antenski niz sačinjen od 16 identičnih, omnidirekcionih elemenata, rastojanje između susednih elementa $d = \lambda/2$, 1024 snapshot-a BPSK (Binary Phase Shift Keying) signala, i odnos signal/šum od 20 dB.



Slika 3. Koncept sektorizacionog modela

5. Rezultati modelovanja

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 estimacionom delu opisana je u tekstu koji sledi. Najpre su podaci neophodni za treniranje MLP neuronskih mreža neuniformno uzorkovani. Imajući u vidu da je potrebno precizno definisati granice između sektora, finije uzorkovanje je primenjeno u njihovoj blizini dok su grublji podaci uzimani iz delova sektora bliskih centru sektora. Nakon toga se, za izvor signala koji pripada određenom sektoru, koriste veoma fini uzorci za obuku RBF mreža za preciznu procenu pravca dolazećeg EM signala. Sledeći ovu proceduru, formira se nekoliko manjih skupova podataka koji omogućavaju efikasniju obuku MLP i RBF neuronskih mreža.

Pošto optimalan broj neurona u skrivenom sloju svake MLP mreže nije unapred poznat, primenjuje se 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 dobrim test statistikama. Optimalni model se izdvaja i koristi za dalje simulacije. U Tabeli 1 su prikazane 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 3, date su performanse najboljih MLP mreža, obučeni 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 ilustrovan na Slici 4(b). Vreme za

obuku mreža u elevacionom sektoru je 17s, i 10s za mreže u azimutnom sektoru (Intel(R) Core(TM)2 Quad CPU računar sa 8 GB RAM memorije).

Tabela 1. Test statistike MLP neuronske mreže za elevacioni (E) sektor [-15°, 15°]

MLP neuronski model	WCE [%]	ACE [%]	r
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 2. Test statistike MLP neuronske mreže za azimutni (A) sektor [-20°, 20°]

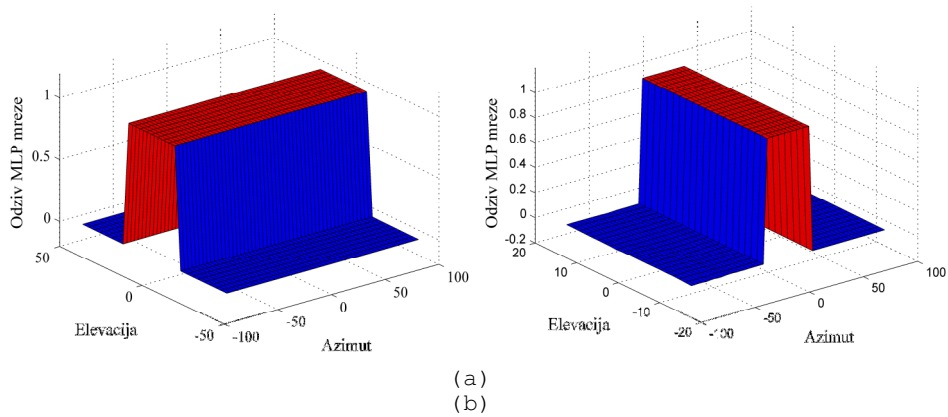
MLP neuronski model	WCE [%]	ACE [%]	r
MLP_A-22-22	1.7102	0.1359	1.0000
MLP_A-20-20	2.5157	0.0365	1.0000
MLP_A-14-11	3.1012	0.0657	1.0000
MLP_A-16-12	3.5327	0.0490	1.0000
MLP_A-18-18	3.8951	0.2885	0.9999

Tabela 3. Test statistike RBF neuronske mreže

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


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, set za obuku jedne RBF mrežu u sektorizacionom modelu sadrži 4941 uzoraka. Poređenja radi, ukoliko se samo jedna RBF mreža koristi u estimacionom delu, set za njenu obuku sadrži znatno veći broj uzoraka (65 341).

RBF mreža sa najboljim test statistikama (WCE=2.7997 %, ACE=0.3341 %, $r=0.9999$), se koristi u daljem simulacionom procesu (Tabela 3). Skriveni sloj odabrane mreže sadrži 81 neuron. Vreme za obuku jedne ovakve RBF mreže u estimacionom delu iznosi oko 60s. Kao što je prikazano na Slici 5, ugaone pozicije izvora procenjene RBF neuronskom mrežom u velikoj meri se poklapaju sa referentnim vrednostima čime su potvrđene dobre performanse predloženog modela. Na Slikama 6(a) i 6(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 i 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




Slika 4. Odziv MLP neuronske mreže u (a) elevacionom sektoru, (b) azimutnom sektoru (odziv je određen za test podatke)

i pronalaženje maksimuma potrebno oko 20s (Intel(R) Core(TM)2 Quad CPU računar sa 8 GB RAM).



Slika 5. Rezultati sektorizacionog modela za test podatke (x – odziv sektorizacionog modela, x – referentne DOA vrednosti)



Slika 6. Korelacioni dijagram sektorizacionog modela i 2D MUSIC algoritma za uglove u (a) azimutu, (b) elevaciji

6. Zaključak

U ovom radu je predložen efikasan neuronski model za preciznu 2D DOA estimaciju. Ključna prednost prikazanog modela u odnosu na super-rezolucijski 2D MUSIC algoritam je njegova sposobnost da za nekoliko milisekundi obezbedi tačne informacije o pravcu dolazećeg EM signala. Zaobilaznjem složenih matričnih izračunavanja, predloženi model je znatno pogodniji od 2D MUSIC algoritma za primenu u realnom vremenu. Redukovanjem seta za obuku svake manje mreže u modelu značajno je smanjeno vreme za njihovu obuku, a time i ukupno vreme za razvoj sektorizacionog modela.

Napomena

Ovaj rad je podržan projektom TR-32052 Ministarstva prosvete u nauke Republike Srbije.

Literatura

- [1] R. Schmidt, Multiple emitter location and signal parameter estimation. *IEEE Transactions on Antennas and Propagation*, 1986, vol. 34, no. 3, p. 276-280.
- [2] R. Roy, T. Kailath, ESPRIT-estimation of signal parameters via rotational invariance techniques. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 1989, vol. 37, no. 7, p. 984 – 995.
- [3] B. Ottersten, M. Viberg, T. Kailath, Performance analysis of the total least squares ESPRIT algorithm. *IEEE Transactions on Signal Processing*, 1991, vol. 39, no. 5, p. 1122-1134.
- [4] Q. J. Zhang, K. C. Gupta, *Neural Networks for RF and Microwave Design*. Artech House, 2000.
- [5] C. G. Christodoulou, M. Georgiopoulos, *Application of Neural Networks in Electromagnetics*. Artech House, 2000.

- [6] A. H. El Zooghby, C. G. Christodoulou, M. Georgiopoulos, A neural network-based smart antenna for multiple source tracking. *IEEE Transactions on Antennas and Propagation*, 2000, vol. 48, no. 5, p. 768 – 776.
- [7] S. Çaylar, K. Leblebicioğlu, G. Dural, A new neural network approach to the target tracking problem with smart structure. In *Proceedings of IEEE AP-S International Symposium and USNC/URCI meeting*, Albuquerque (USA), 2006, p. 1121-1124.
- [8] M. Wang, S. Yang, S. Wu, F. Luo, A RBFNN approach for DOA estimation of ultra wideband antenna array. *Neurocomputing-Elsevier*, 2008, vol. 71, no. 4-6, p. 631-640.
- [9] 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 Transactions on Antennas and Propagation*, 2010, vol. 58, no. 2, p. 357-366.
- [10] 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)*, 2006, vol.89, no.9, p. 22-31.
- [11] C. Hongguang, L. Biao, S. Zhenkang, Efficient network training method for two-dimension DOA estimation. *Proc. of the 4th Int. Conference on Computer and Information Technology (CIT '04)*, Wuhan (China), 2004, p. 1028 – 1032.
- [12] Z. Stanković, B. Milovanović, N. Dončov, Hybrid empirical-neural model of loaded microwave cylindrical cavity. *Progress in Electromagnetics Research, PIER*, 2008, vol. 83, p. 257-277.
- [13] M. Sarevska, B. Milovanović, Z. Stanković, Reliability of radial basis function - neural network smart antenna. In *Proceedings of the 9th WSEAS International Conference on Communications*, Athens (Greece), 2005.
- [14] M. Sarevska, B. Milovanović, Z. Stanković, Antenna Array System Modeling Using RBF Neural Network, *6th International Nikola Tesla Symposium Conference Proceedings*, Belgrade, 18 -20 October 2006, pp.193-196.
- [15] M. Agatonović, Z. Stanković, B. Milovanović, N. Dončov, DOA Estimation using Radial Basis Function Neural Networks as Uniform Circular Antenna Array Signal Processor, *Proceedings of the 10th IEEE International Conference on Telecommunications in Modern Satellite, Cable and Broadcasting Services, TELSIKS 2011*, Niš, Serbia, Vol.2, pp.544-547, 2011

Abstract: *In this paper, a new method to provide high-resolution Direction of Arrival (DOA) estimates of an electromagnetic signal is presented. The method is based on a sectorization model realized by MLP and RBF Artificial Neural Networks. DOAs are provided in a matter of seconds which makes the sectorization model very convenient for real-time application. The accuracy of obtained results is comparable to that of super-resolution 2D MUSIC algorithm.*

Keywords: *Direction of Arrival Estimation, MLP, RBF, URA.*

A NEW APPROACH IN SPATIAL SIGNAL PROCESSING BASED ON ARTIFICIAL NEURAL NETWORKS

Bratislav Milovanović, Marija Agatonović, Zoran Stanković, Nebojša Dončov