

## **PRIMENA VEŠTAČKIH NEURONSKIH MREŽA ZA RAZVOJ MODELIMA RF I MIKROTALASNIH TRANZISTORA**

Zlatica Marinković, Olivera Pronić-Rančić, Vera Marković

Univerzitet u Nišu - Elektronski fakultet, zlatica.marinkovic@elfak.ni.ac.rs,  
olivera.pronic@elfak.ni.ac.rs, vera.markovic@elfak.ni.ac.rs

**Sadržaj:** Razvoj savremenih komunikacionih sistema podrazumeva razvoj modela komponenata koje su sastavni delovi primopredajnih uređaja sa ciljem optimizacije performansi uređaja. U ovom radu razmatrani su modeli RF i mikrotalasnih tranzistora koji predstavljaju bazične komponente komunikacionih uređaja. U poslednjih petnaestak godina veštačke neuronske mreže su uspešno primenjene u razvoju modela RF i mikrotalasnih tranzistora. U radu je dat pregled modela tranzistora za male signale i modela šuma baziranih na primeni veštačkih neuronskih mreža, kao i pregled primena veštačkih neuronskih mreža za poboljšanje tačnosti postojećih modela. Opisani su postupci razvoja modela i prikazani najznačajniji rezultati autora u ovoj oblasti.

**Ključne reči:** modelovanje, RF i mikrotalasni tranzistori, veštačke neuronske mreže

### **1. Uvod**

Preformanse uređaja u savremenim komunikacionim sistemima zavise od karakteristika komponenata koje ih sačinjavaju. Stoga je u procesu projektovanja ovih uređaja veoma bitno koristiti tačne i pouzdane modele njihovih sastavnih komponenata. RF i mikrotalasni tranzistori predstavljaju veoma važne, čak se može reći ključne komponente kola i sklopova u primopredajnim uređajima komunikacionih sistema. Za potrebe projektovanja je potrebno imati pre svega modele tranzistora za male signale (u linearnom režimu rada), a zatim u zavisnosti od primene tranzistora, tj. od sklopa čiji je sastavni deo, potrebni su modeli šuma (npr. za primene u malošumnim pojačavačima na prijemnoj strani) ili nelinearni modeli (npr. za primene u pojačavačima snage, mešaćima i sl.) [1]. Modeli tranzistora mogu biti fizički modeli bazirani na matematičkom opisu fizičkih procesa koji se odvijaju u komponenti. Ovi modeli su veoma tačni, ali zahtevaju detaljno poznavanje svih procesa u komponenti, kao i poznavanje svih geometrijskih karakteristika i tehnoloških parametara, što u najvećem broju slučajeva nije na raspolaganju projektantima RF i mikrotalasnih kola i sklopova. Zbog toga se najčešće koriste modeli koji su bazirani na predstavljanju tranzistora pomoću ekvivalentnog kola. Elementi ekvivalentnog kola određuju se najčešće optimizacijom, a u nekim slučajevima dostupne su i analitičke procedure za ekstrakciju elemenata ekvivalentnog kola. Prilikom određivanja elementata ekvivalentnog kola cilj je odabratи njihove vrednosti tako da se

željene karakteristike ekvivalentnog kola (npr. parametri rasejanja, parametri šuma) što je moguće više približe njihovim odgovarajućim merenim vrednostima. Međutim, iako su ovakvi modeli jednostavni i pogodni za dalju upotrebu, dešava se da imaju oblast važenja samo za jedan deo radnih uslova tranzistora ili da nisu dovoljno tačni jer ne obuhvataju, odnosno ne uključuju adekvatno, sve procese u modelovanoj komponenti.

U poslednjih petnaestak godina dosta se radi na istraživanjima vezanim za primene veštačkih neuronskih mreža za razvoj modela mikrotalasnih tranzistora, ali i ostalih RF i mikrotalasnih komponenata [2]-[6]. Veštačke neuronske mreže imaju sposobnost učenja zavisnosti između dva skupa podataka, pa su kao takve pogodne za razvoj modela direktno iz merenih karakteristika, rezultirajući u visokoj tačnosti. Pri tome, vreme odziva im je veoma kratko, što ih svrstava u grupu visoko efikasnih modela i odražava se povoljno na vreme projektovanja kola i sklopova.

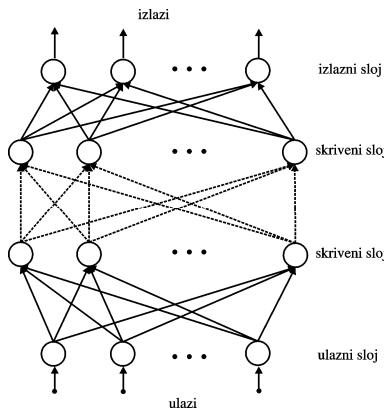
Što se RF i mikrotalasnih tranzistora tiče, modeli bazirani na veštačkim neuronskim mrežama, se mogu razviti za jednosmerne karakteristike [2], [7], modele za male signale [2], [4], [5], [7] modele šuma [5]-[7] i nelinearne modele [8]- [9]. U ovom radu pažnja će biti usmerena na modele za male signale, koji su bazični za razvoj modela šuma i nelinearnih modela, kao i na modele šuma, koji su značajni za projektovanje malošumnih sklopova u komunikacionim sistemima.

U radu je najpre, u sekciji 2 data osnovna teorija o veštačkim neuronskim mrežama. Sekcija 3 se odnosi na tzv. modele crne kutije, odnosno *black-box* modele, razvijene za RF i mikrotalasne tranzistore. Zatim je, u sekciji 4 prikazana primena veštačkih neuronskih mreža za poboljšanje postojećih modela, i to proširenje opsega važenja modela i poboljšanje tačnosti modela. Na kraju su izvedeni zaključci u sekciji 5.

## 2. Veštačke neuronske mreže

Veštačke neuronske mreže su napravljene po ugledu na nervni sistem čoveka. Sastoje se iz većeg broja međusobno povezanih osnovnih procesnih jedinica - neurona. Najčešće korišćena struktura veštačkih neuronskih mreža je višeslojna neuronska mreža (*MLP - Multilayer Perceptron Neural Network*) kod koje su neuroni grupisani u slojeve, pri čemu nema veza između neurona u slojevima, a svaki neuron je povezan sa svim neuronima iz narednog sloja, kao što je prikazano na Slici 1 [2]. Neuronima su pridružene aktivacione prenosne funkcije, a svakoj vezi između neurona pridružena je težina. Informacija iz okruženja se dovodi na neurone iz prvog, ulaznog sloja, procesira se pri prolasku kroz mrežu tako da se na izlazima poslednjeg, izlaznog sloja, dobija odziv mreže. Slojevi koji nemaju direktnu vezu sa okruženjem se nazivaju skriveni slojevi. Najčešće prvi sloj ima ulogu bafera i ulazni neuroni imaju linearnu prenosnu funkciju, kao i izlazni neuroni. Neuroni iz skrivenih slojevima najčešće imaju sigmoidne prenosne funkcije (*logsig* ili *tansig*). Mreža uči zavisnost između skupova ulazno-izlaznih podataka podešavanjem pragova aktivacionih funkcija neurona i težina između veza tokom procesa obučavanja (treniranja) mreže. Za potrebe obučavanja veštačkih neuronskih mreža najčešće se koristi tzv. *backpropagation* algoritam i njegove modifikacije, poput *Quasi-Newton* ili *Levenberg-Marquardt* algoritama [2]. Najvažnija osobina korektno obučenih neuronskih mreža, pored naučene zavisnosti između predstavljenih skupova podataka, je njihova mogućnost da daju tačan odziv i za vrednosti ulaznih parametara koji nisu bili predstavljeni mreži u toku procesa obuke, tj.

mogućnost generalizacije. Upravo je mogućnost generalizacije kvalifikovala veštačke neuronske mreže kao veoma efikasno sredstvo za modelovanje za različite primene, između ostalog i za modelovanje komponenata i procesa u savremenim komunikacionim sistemima. Kako neuronske mreže daju odziv praktično trenutno, one se mogu iskoristiti za formiranje modela koji predstavljaju alternativu modelima u standardnim simulatorima koji zahtevaju značajno vreme simulacije karakteristika razmatrane komponente. Naime, na osnovu određenog broja vrednosti modelovanih parametara dobijenih u standardnom simulatoru (npr. elektromagnetski simulator) obučava se neuronska mreža, koja će generisati korektni odziv sa tačnošću bliskoj tačnosti simulatora, ali u daleko kraćem vremenu. Još jedan od mogućih primera primene veštačkih neuronskih mreža je u slučaju kad ne postoje matematički modeli nekog problema. Tada se na osnovu poznatih ulazno-izlaznih vrednosti obučavanjem mreže dobija zavisnost ulazno-izlaznih parametara u zatvorenom obliku. Treba, napomenuti da se svaka mreža može opisati pomoću skupa matematičkih izraza, zasnovanih samo na korišćenju osnovnih matematičkih operacija i eksponencijalne funkcije, koji se dalje veoma lako mogu koristiti i implementirati u neke od standardnih simulatora.

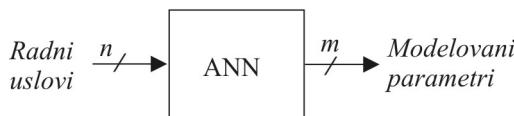


Slika 1. Višeslojna veštačka neuronska mreža (MLP)

Samu strukturu jedne neuronske mreže određuje problem za koji se model razvija. Naime, broj ulaznih i izlaznih neurona jednak je broju ulaznih, odnosno izlaznih parametara, dok se broj skrivenih slojeva i broj neurona u njima ne može unapred odrediti. Zbog toga je potrebno za svaki model izvršiti obuku većeg broja mreža sa različitim brojem skrivenih neurona i zatim odabratи mrežu sa najboljim performansama modelovanja kako na skupu za učenje (trening skup), tako i na test skupu koji se razlikuje od skupa za učenje. U najvećem broju slučajeva prikazanih u ovom radu, za testiranje neuronskih mreža korišćene su srednja relativna greška testiranja (ATE - *Average Test Error*), maksimalna relativna greška testiranja (WCE - *Wors Case Error*), i Pearson Product Moment korelacioni koeficijent [2]. U nekim slučajevima je bilo potrebno i vizuelno uporediti modelovane i referentne vrednosti, jer nekada upkos maloj greški modelovanja, modelovane vrednosti ne prate adekvatno referentne vrednosti.

### 3. Black-box modeli mikrotalasnih tranzistora

Veštačke neuronske mreže se u modelovanju RF i mikrotalasnih tranzistora najčešće koriste za razvoj takozvanih modela baziranih na principu crne kutije, tj. *black-box* modela. Kod ovakvih modela, kao što je prikazano na Slici 2, jedna veštačka neuronska mreža (ANN - *Artificial Neural Network*) se obučava da modeluje zavisnost  $m$  parametara kojima se opisuju željene karakteristike tranzistora od  $n$  radnih uslova rada tranzistora (najčešće frekvencija i jednosmerni naponi/struje, napajanja, temperatura i sl.). U slučaju modela za male signale veličine koje se modeluju su parametri rasejanja (S-parametri, ima ih 4 i svi su kompleksne veličine) i parametri šuma (minimalni faktor šuma  $F_{min}$ , optimalni koeficijent refleksije  $\Gamma_{opt}$  koji je kompleksna veličina i normalizovana ekvivalentna otpornost šuma  $r_n$ ). Alternativno, može se izvršiti dekompozicija modela, što podrazumeva da se za svaku modelovanu veličinu ili grupu veličina razvija posebna neuronska mreža. Za obučavanje ovakvih mreža, potrebno je obezbediti odgovarajući broj merenih vrednosti modelovanih parametara, za različite vrednosti ulaznih parametara odabranih tako da adekvatno reprezentuju prostor ulaznih veličina. Treba imati na umu da je opseg ulaznih parametara za koji je model validan određen izborom vrednosti ulaznih parametara na koje se odnose ciljni podaci korišćeni za učenje. U nastavku će biti prikazani karakteristični *black-box* neuronski modeli razvijeni od strane autora ovog rada, sa nekim od najilustrativnijih rezultata.



Slika 2. Opšta struktura black-box neuronskog modela karakteristika tranzistora

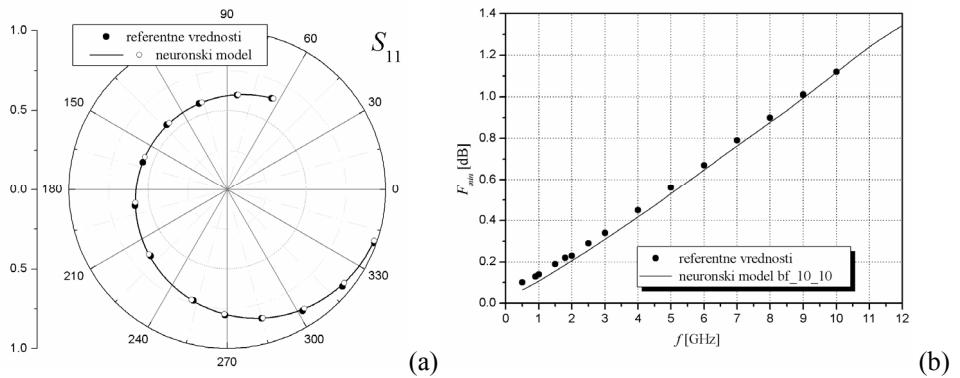
Kao primer, u [10] i [11] predloženi su modeli S-parametara i parametara šuma tranzistora ATF35143 u zavisnosti od jednosmernih napona i struje napajanja ( $V_{ds}$  i  $I_{ds}$ ) i frekvencije. Mreža za modelovanje S-parametara ima 8 izlaznih neurona koji odgovaraju modulima i argumentima 4 S-parametra, a mreža za modelovanje parametara šuma ima 4 izlazna neurona koji odgovaraju parametrima šuma. Obe mreže imaju po tri neurona u ulaznom sloju, na koje se dovode vrednosti struje i napona napajanja i frekvencije.

Na Slici 3 prikazan je deo test rezultata koji se odnosi na tačku napajanja koja nije bila uključena u skup za obuku, sa kog se može uočiti veoma dobra generalizacija modela. U cilju dodatnog poboljšanja tačnosti modela, moguće je na ulaz modela šuma dodati S-parametre za odgovarajuće uslove napajanja, čime se dimenzija ulaznog sloja mreže povećava za 8 neurona [12].

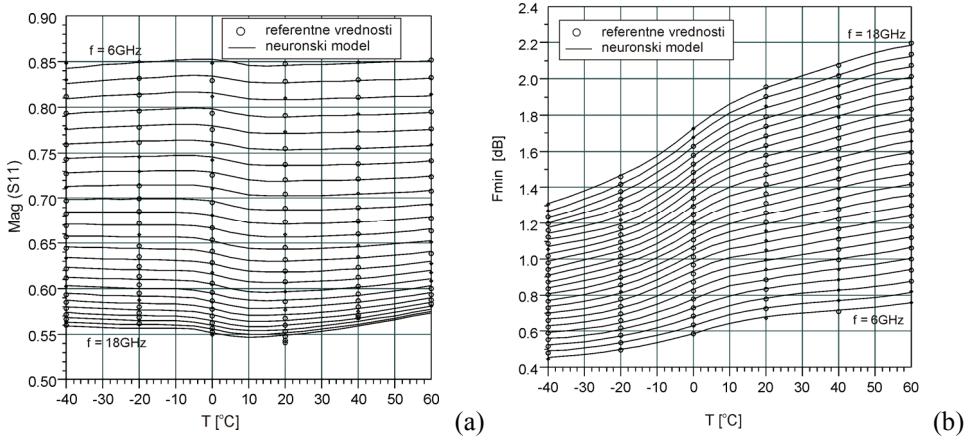
U radu [13] razmatrani su modeli S-parametara i parametara šuma u zavisnosti od temperature i frekvencije za tranzistor NEC20283A. Neuronske mreže u ovom slučaju imaju samo dva ulazna neurona. Ovakvi modeli omogućavaju da se veoma efikasno predviđi ponašanje karakteristika komponente za bilo koju temperaturu iz razmatranog temperturnog opsega, kao što je pokazano na Slici 4, za moduo parametra  $S_{11}$  i za minimalni faktor šuma.

Model koji uključuje istovremeno i temperturnu zavisnost i zavisnost od uslova napajanja frekvencijski zavisnih S-parametara za GaN HEMT tranzistor prikazan je u

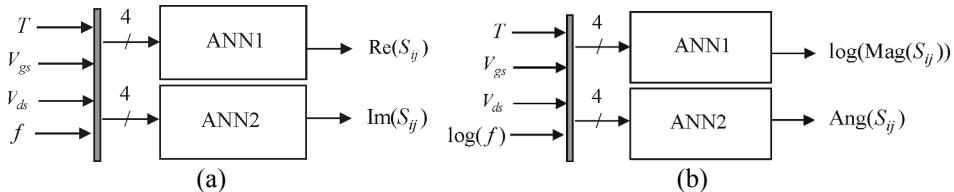
[14]. Za razliku od prethodno pomenutog modela koji razmatra zavisnost S-parametara od uslova napajanja, a koji je razvijen samo za opseg tipičnih uslova napajanja, kod ovog modela razmatran je ceo opseg mogućih vrednosti jednosmernih napona napajanja, što je dovelo do toga da je potrebno razvijati modele posebno za svaki od S-parametara kako bi se adekvatno modelovala njihova zavisnost od uslova napajanja i temperature. Štaviše, za modelovanje jednog S-parametra korišćene su dve mreže, jedna za realni i jedna za imaginarni deo modelovanog parametra, Slika 5a. U cilju postizanja što boljeg modelovanja parametra  $S_{21}$ , modelovani su moduo i argument umesto realnog i imaginarnog dela, pri čemu je korišćena logaritamska reprezentacija frekvencije i modula  $S_{21}$ , Slika 5b. Testiranje u celom radnom opsegu temperaturu (od 20 do 80°C) pokazalo je da su srednje relativne greške uglavnom manje od 3%, što se može smatrati veoma dobrim modelovanjem. Ilustracije radi, na Slici 6 su prikazani S-parametri za temperaturu i uslove napajanja koji nisu korišćeni pri razvoju modela.



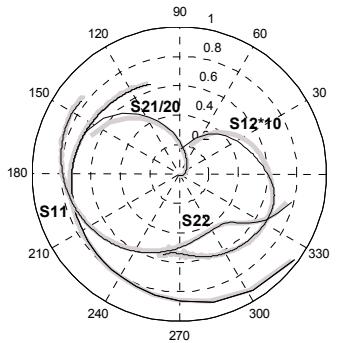
Slika 3. (a) Parametar  $S_{11}$  i (b) minimalni faktor šuma za test uslove napajanja određeni korišćenjem neuronskog modela



Slika 4. (a) Moduo parametra  $S_{11}$  i (b) minimalni faktor šuma u zavisnosti od temperature

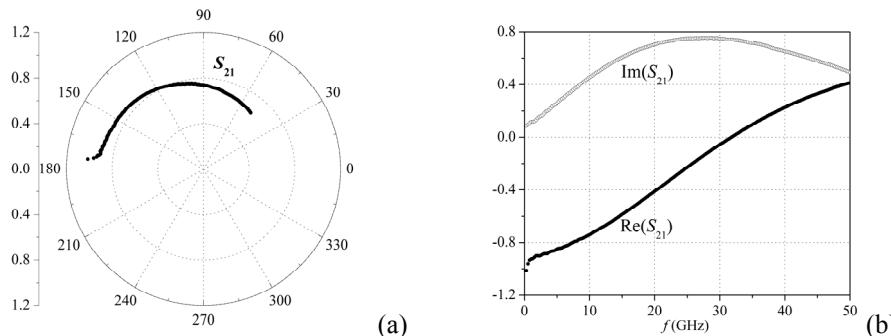


Slika 5. Neuronski modeli S-parametara GaN HEMT tranzistora (a) model za korišćen za  $S_{11}$ ,  $S_{12}$  i  $S_{22}$  i (b) model korišćen za  $S_{21}$

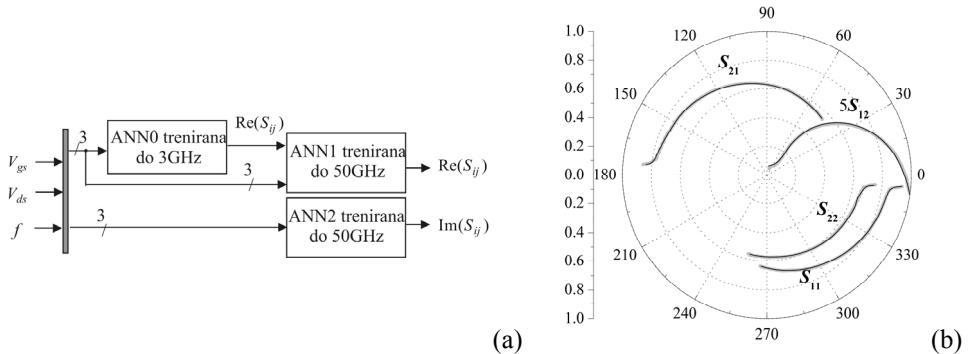


Slika 6. S-parametari modelovanog GaN HEMT tranzistora za temperaturu i uslove napajanja koji nisu korišćeni pri razvoju modela (sivi simboli - merene referentne vrednosti, crne linije -model) [14]

Kao što se može videti, ključni zadatok prilikom razvoja jednog black-box modela je razmatranje ponašanja modelovanih karakteristika i izbor odgovarajuće strukture i hijerarhije neuronskih modela. Na primer, u slučaju modelovanja FinFET tranzistora zbog specifičnog ponašanja S-parametara na nižim frekvencijama, koje je uslovljeno ponašanjem realnih delova S-parametra, kao što je ilustrovano na primeru parametra  $S_{21}$  na Slici 7, iskorišćen je model koji ima hijerarhijsku strukturu [15]. Naime, za realni deo najpre se razvija mreža za niže frekvencije, u ovom slučaju do 3 GHz, a zatim se izlaz iz te mreže vodi na ulaz mreže koja se razvija za ceo frekvencijski opseg, Slika 8a. Time se postiže da se dobiju dobri rezultati modelovanja za sve frekvencije, Slika 8b.



Slika 7. Parametar  $S_{21}$  FinFET tranzistora (a) polarni prikaz i (b) realni i imaginarni deo

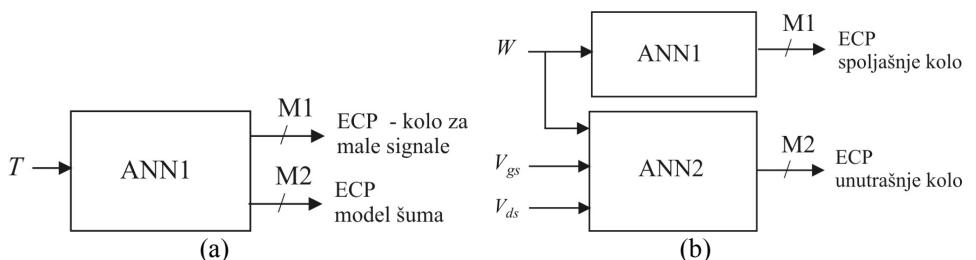


Slika 8. (a) Neuronski model S-parametra FinFET tranzistora (b) Rezultati modelovanja (sivi simboli - merene referentne vrednosti, crne linije - modelovane vrednosti)

Neuronski modeli za male signale najčešće podrazumevaju modelovanje S-parametara, ali se mogu modelovati i Y-parametri [16], jer je takva reprezentacija veoma pogodna za dalji razvoj nelinearnih modela. Pored modela koji se odnose na jednu komponentu, *black-box* modeli mogu biti razvijeni i za više komponenata različitih dimenzija, tj. za klasu komponenata. U tom slučaju potrebno je na ulaze odgovarajućih mreža uključiti i razmatrane dimenzije, a i obezbediti podatke za obučavanje neuronskih mreža koji se odnose na komponente različitih dimenzija [17]- [18].

#### 4. Proširenje opsega važenja i poboljšanje tačnosti modela

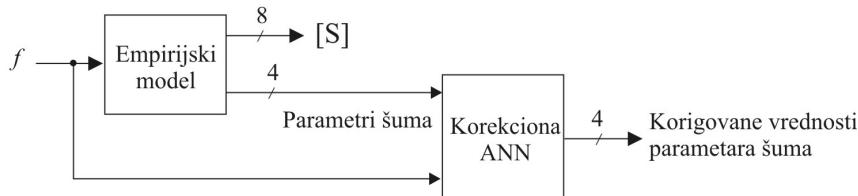
Kao što je rečeno u uvodnoj glavi, projektanti RF i mikrotalasnih kola najčešće koriste modele bazirane na ekvivalentnom kolu. Međutim, ekvivalentno kolo se u najvećem broju slučajeva odnosi samo na jednu kombinaciju radnih uslova, tako da je pri promeni radnih uslova potrebno iznova vršiti ekstrakciju elemenata ekvivalentnog kola. Primenom veštačkih neuronskih mreža moguće je modelovati zavisnost elemenata ekvivalentnog kola (ECP - *Equivalent Circuit Parameters*) od razmatranih radnih uslova, tako da je za novu kombinaciju radnih uslova dovoljno potražiti odziv neuronske mreže. Što je najvažnije, merene vrednosti parametara su potrebne samo za razvoj modela, a ne i za njegovo korišćenje, čime postupak modelovanja postaje mnogo brži i efikasniji.



Slika 9. Neuronski modeli elemenata ekvivalentnog kola HEMT tranzistora (a) Temperaturna zavisnost u slučaju tranzistora (b) Zavisnost od uslova napajanja i dimenzija gejta

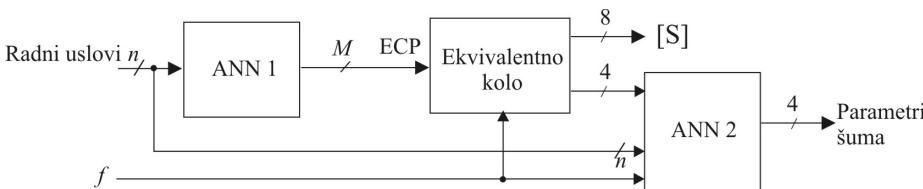
Ilustracije radi, na Slici 9a prikazan je neuronski model zavisnosti elemenata ekvivalentnog kola za male signale ( $M_1=19$  elemenata) sa pridruženim modelom šuma Pospieszalskog ( $M_2=1$ , jedan parametar - temperaturna šuma drezna) od temperature ambijenta [13]. Takva mreža ima  $M_1+M_2=20$  izlaza. Drugi primer je prikazan na Slici 9b, za klasu HEMT tranzistora. U ovom slučaju je razmatrana zavisnost ECP-a od uslova napajanja [19]. Pošto elementi spoljašnjeg kola tranzistora ne zavise od uslova napajanja, na ulazu u neuronsku mrežu je samo razmatrana dimenzija tranzistora (u ovom slučaju širina gejta  $W$ ), dok su elementi unutrašnjeg kola zavisni i od uslova napajanja i od dimenzija tranzistora. Za razvijanje ovakvih modela potrebno je obezbediti određeni broj vrednosti modelovanih elemenata ekvivalentnog kola za različite vrednosti razmatranih radnih uslova i/ili dimenzija tranzistora, određenih na standardni način (optimizacijom ili analitičkim postupkom) na osnovu merenih vrednosti. Treba naglasiti da je tačnost modela kod kojih je uključena zavisnost od radnih uslova na ovaj način ograničena tačnošću razmatranog ekvivalentnog kola.

Takođe, kao što je pomenuto u uvodnom delu, može se desiti, posebno u slučaju modelovanja parametara šuma, da razmatrani model baziran na ekvivalentnom kolu nije dovoljno tačan. I u ovom slučaju veštačke neuronske mreže mogu dati moguće rešenje. Naime, ekvivalentnom kolu pridružuje se dodatna neuronska mreža koja ima funkciju korekcije vrednosti dobijenih pomoću empirijskog modela baziranog na ekvivalentnom kolu. Kao što je prikazano na Slici 10, na kojoj je prikazan model šuma, najčešće korekciona mreža ima na ulazu frekvenciju i vrednosti parametara čije vrednosti treba korigovati, a to su u posmatranom primeru parametri šuma. Više detalja o ovakvim modelima je dostupno u [5] i [6].



Slika 10. Neuronska mreža za poboljšanje tačnosti empirijskih modела baziranih na ekvivalentnom kolu

Prethodno pomenuti pristupi za uključivanje zavisnosti od radnih uslova u empirijske modele i za korekciju vrednosti empirijskih modела mogu biti primjenjeni istovremeno, kao što je ilustrovano na Slici 11 [20].



Slika 11. Uključivanje zavisnosti od radnih uslova i poboljšanje tačnosti empirijskih modела baziranih na ekvivalentnom kolu

## 5. Zaključak

Rezultati prikazani u ovom radu pokazuju da je primenom veštačkih neuronskih mreža moguće razviti veoma tačne i efikasne modele RF i mikrotalasnih tranzistora. Takođe pokazano je i da se veštačke neuronske mreže efikasno mogu primeniti na poboljšanja postojećih modela zasnovanih na reprezentaciji pomoću ekvivalentnog kola, u pogledu tačnosti i opsega važenja. Imajući u vidu da veštačke neuronske mreže daju veoma brz odziv, primena ovih modela može značajno skratiti vreme potrebno za optimizaciju karakteristika komponenata i uređaja koji se projektuju.

**Zahvalnica:** Istraživanja prikazana u ovom radu podržana su od strane Ministarstva prosvete, nauke i tehnološkog razvoja u okviru projekata TR32052 i III43012.

## Literatura

- [1] D. Pozar, *Microwave Engineering*, J. Wiley & Sons, 1998.
- [2] Q. J. Zhang, K. C. Gupta, *Neural Networks for RF and Microwave Design*, Artech House, 2000.
- [3] C. Christodoulou, M. Gerogiopoulos, *Applications of Neural Networks in Electromagnetics*, Artech House, 2001.
- [4] H. Kabir, L. Zhang, M. Yu, P. Aaen, J. Wood, and Q. J. Zhang "Smart modeling of microwave devices," *IEEE Microw. Mag.*, vol. 11, pp.105–108, May 2010.
- [5] Z. Marinković, V. Marković, A. Caddemi, "Artificial Neural Networks in Small-Signal and Noise Modeling of Microwave Transistors", *Chapter 6* in „*Artificial Neural Networks*“ edited by Seoyun J. Kwon, Nova Science Publishers Inc., 2011, pp. 219-236.
- [6] Z. Marinković, O. Pronić-Rančić, V. Marković, " Artificial Neural Networks as a Tool for Improving Microwave Transistor Empirical Noise Models", *Chapter 14* in „*Artificial Intelligence and Hybrid Systems*“ edited by Claudio Rocha, iConcept Press Ltd., 2012.
- [7] F. Giannini, G. Leuzzi, G. Orengo, and M. Albertini, "Small-signal and large-signal modeling of active devices using CAD-optimized neural networks," *Int. J. RF Microw. Comput.-Aided Eng.*, vol. 12, pp. 71-78, Jan 2002.
- [8] K. Shirakawa, M. Shimizu, N. Okubo, and Y. Daido, "Structural determination of multilayered large signal neural-network HEMT model," *IEEE Trans. Microwave Theory Tech.*, vol. 46, no. 10, pp. 1367–1375, Oct. 1998.
- [9] Z. Marinković, G. Crupi, A. Raffo, G. Bosi, G. Avolio, V. Marković, A. Caddemi, G. Vannini, D. Schreurs, "A neural network approach for nonlinear modelling of LDMOSFETs," *INMMiC 2014*, Leuven, Belgium, 2014, pp.1-3.
- [10] Z. Marinković, A. Stošić, V. Marković, O. Pronić, "ANNs in Bias-Dependent Modeling of S-parameters of Microwave FETs and HBTs", *Microwave Review*, vol.12, no. 1, pp. 21-30, June 2006.
- [11] V. Marković, Z. Marinković, "HEMT Noise neural model based on bias conditions", *COMPEL*, vol. 23, no. 2, pp. 426-435, February 2004.

- [12] V. Marković, Z. Marinković, "Neural Models of Microwave Transistor Noise Parameters Based on Bias Conditions and S-parameters", TELSIKS 2001, Niš, Yugoslavia, pp. 683-686.
- [13] Z. Marinković, V. Marković, "Temperature Dependent Models of Low-Noise Microwave Transistors Based on Neural Networks", *Int. J. RF Microw. Comput.-Aided Eng.*, vol. 15, no. 6, pp. 567-577, November 2005.
- [14] Z. Marinković, G. Crupi, A. Caddemi, G. Avolio, A. Raffo, V. Marković, G. Vannini, and D. M. M.-P. Schreurs, "Neural approach for temperature-dependent modeling of GaN HEMTs," *Int. J. Numer. Model. El.*, vol. 28, no 4, pp. 359-370, July/August 2015.
- [15] Z. Marinković, G. Crupi, D. Schreurs, A. Caddemi, V. Marković, "Microwave FinFET modeling based on artificial neural networks including lossy silicon substrate," *Microelectronic Eng.*, vol. 88, no. 10, pp. 3158-3163, October 2011.
- [16] Z. Marinković, G. Crupi, D. Schreurs, A. Caddemi, V. Marković, "Multi-Bias Neural Modeling of FinFET Admittance Parameters," *Microw. Opt. Techn. Lett.*, vol. 54, no. 9, pp. 2082-2088, September 2012.
- [17] Z. Marinković, O. Pronić, V. Marković " Bias-dependent scalable modeling of microwave FETs based on artificial neural networks", *Microw. Opt. Techn. Lett.*, vol. 48, no. 10, pp. 1932-1936, October 2006.
- [18] Z. Marinković, G. Crupi, A. Caddemi, V. Marković, "Comparison Between Analytical and Neural Approaches for Multibias Small Signal Modeling of Microwave Scaled FETs", *Microw. Opt. Techn. Lett.*, vol. 52, no. 10, pp. 2238-2244, October 2010.
- [19] Z. Marinković, G. Crupi, A. Caddemi, V. Marković, "Development of a Neural Approach for Bias-Dependent Scalable Small-Signal Equivalent Circuit Modeling of GaAs HEMTs", *EuMIC 2010*, Paris, France, 2010, pp. 182-185.
- [20] Z. Marinković, V. Marković, "Accurate Temperature Dependent Noise Models of Microwave Transistors Based on Neural Networks", *13<sup>th</sup> GAAS Symposium, EUMW 2010*, Paris, France, pp. 389-392.

**Abstract:** *Development of modern communication systems requires development of the model of devices which are parts of transmitting and receiving devices with the aim at device performance optimization. In this papers modelling of RF and microwave transistors, which are basic parts of the communication devices, are considered. In the last fifteen years, artificial neural networks have been successfully applied in development of the RF and microwave transistor models. This paper gives an overview of the transistor small-signal and noise models based on artificial neural networks as well as summarize applications of the artificial neural networks for improving accuracy of the existing transistor models. Model development procedures are described and the most important results of the authors of this paper achieved in this field are reported.*

**Keywords:** Artificial neural networks, Modelling, RF and microwave transistors

## **APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR RF AND MICROWAVE TRANSISTOR MODEL DEVELOPMENT**

Zlatica Marinković, Olivera Pronić-Rančić, Vera Marković