

NEURONSKI PRISTUP U MODELOVANJU DC I RF KARAKTERISTIKA HBT TRANZISTORA

Vera Marković, Aleksandar Stošić, *Elektronski fakultet u Nišu*

Sadržaj – HBT tehnologija smatra se vrlo pogodnom za aktivne mikrotalasne sklopove u savremenim bežičnim komunikacijama. U ovom radu biće predstavljen objedinjeni model HBT tranzistora koji generiše kako jednosmerne karakteristike tranzistora, tako i njegove S parametre u celom radnom opsegu. Za modelovanje je primenjen neuronski pristup koji omogućava visoku tačnost uz efikasnost i jednostavnost primene koje se zahtevaju od CAD tehnika.

1. UVOD

Paralelno sa naglim razvojem bežičnih komunikacionih sistema, značajan napredak je postignut na planu tehnološkog razvoja aktivnih mikrotalasnih komponenata koje se ugrađuju u ove sisteme. Kada su u pitanju mikrotalasni tranzistori koji se mogu koristiti za bežične aplikacije, danas je na raspolaganju više različitih tipova počev od standardnog MESFET-a do HEMT-a, PHEMT-a, HBT-a ili MOSFET-a. Izbor RF tranzistora za konkretne aplikacije zavisice pre svega od zahtevanih performansi, ali i od ostalih faktora kao što je cena, dostupnost, raspoloživost CAD modela itd.

Heterospojni bipolarni tranzistori (HBT - Heterojunction Bipolar Transistors) pokazuju odlične karakteristike na veoma visokim frekvencijama i stoga predstavljaju vrlo atraktivnu aktivnu komponentu za sklopove koji se koriste u savremenim bežičnim komunikacijama [1], [2]. Na primer, ovaj tip tranzistora se može koristiti kod pojačavača snage ili kod malošumnih pojačavača u mobilnim komunikacijama.


Princip rada HBT tranzistora bazira se na efektu postojanja razlike energetskog procepa dva različita poluprovodna materijala. Korišćenjem emitora sa širim energetskim procepom i baze sa užim energetskim procepom povećava se efikasnost injekcije elektrona u bazu, a otežava ubacivanje šupljina u emitor. Ovo svojstvo se zadržava i kada je baza visoko dopirana, a što smanjuje otpornost baze i povećava prekidnu frekvenciju. Istovremeno, emitor može biti niskodopiran. Otuda, kod HBT-a se može dobiti veliko strujno pojačanje, a da istovremeno parazitne otpornosti i kapacitivnosti mogu biti niže nego kod konvencionalnog bipolarnog tranzistora. Takođe, HBT tranzistori imaju znatno manji šum na visokim frekvencijama u odnosu na standardne bipolarnu tranzistore, a odlikuje ih i dobra efikasnost pri radu sa velikim snagama. Zbog svoje dobre linearne karakteristike kada rade u režimu pojačavača, HBT tranzistori su našli veliku primenu kod RF pojačavača u mobilnoj telefoniji. Prednost u odnosu na FET tranzistore je što se pri izradi HBT tranzistora koristi manje zahtevna tehnika litografije što ima za posledicu manju cenu proizvodnje. Ova tehnologija takođe obezbeđuje veće radne napone i jednostavnije širokopojasno prilagođenje impedanse od FET tranzistora.

Sa stanovišta projektovanja većine sklopova baziranih na HBT tehnologiji potrebno je imati odgovarajuće modele DC i RF karakteristika tranzistora. Zapravo, efikasnost savremenih CAD tehnika umnogome zavisi od tačnosti i efikasnosti modela u celom radnom opsegu komponente.

Standardni fizički model za DC karakteristike bipolarnih tranzistora je Gummel-Poon-ov model. Obzirom na specifičnosti HBT tranzistora, a pre svega na postojanje diskontinuiteta u energetskom procepu između emitora i baze, fizički modeli konvencionalnih bipolarnih tranzistora su od strane nekih autora dalje modifikovani tako da se mogu primeniti i na HBT tranzistore [3]. Međutim, fizički modeli po pravilu zahtevaju poznavanje brojnih tehnoloških parametara komponente kojima projektant po pravilu ne raspolaže.

Što se tiče RF modela HBT-a za male signale standardni pristup kao i kod drugih mikrotalasnih tranzistora je ekstrakcija ekvivalentnog kola podešavanjem odziva modela u odnosu na karakteristike dobijene merenjem. Problemi koji se javljaju kod takvog pristupa su sledeći: Ekstrahovane vrednosti parametara modela validne su za samo jednu tačku DC napajanja, a za bilo koju drugu treba ponovo vršiti optimizaciju elemenata ekvivalentnog kola. Drugo, jednom izabrana topologija ekvivalentnog kola najčešće nije odgovarajuća za ceo radni opseg frekvencija. Sa porastom frekvencije, naime, raste kompleksnost ekvivalentnog kola jer neki dodatni parazitni efekti moraju da se uzmu u obzir.

Kao rešenje koje može da prevaziđe navedene nedostatke standardnih načina modelovanja, u ovom radu je korišćen pristup neuronskih mreža [4]. Neuronski modeli su poslednjih godina zauzeli značajno mesto u oblasti projektovanja mikrotalasnih kola [5]. Oni su dovoljno tačni sa jedne strane, a sa druge strane omogućavaju vrlo brzu simulaciju što je danas od velikog značaja za brze CAD cikluse, statističku analizu tolerancija, optimizaciju proizvodnje itd. Kada su u pitanju aktivne komponente, korišćenjem neuronskih mreža mogu se prevazići nedostaci kako fizičkih modela, tako i empirijskih baziranih na ekvivalentnim kolima [6]. Štaviše, mogućnost da se na osnovu određenog broja eksperimentalnih podataka obuči neuronska mreža tako da daje DC karakteristike i S parametre HBT tranzistora bez korišćenja ekvivalentnog kola kao međukoraka, predstavlja značajnu prednost u slučajevima kada ekvivalentno kolo nije raspoloživo, nije dovoljno tačno, kada je proces njegove ekstrakcije dugotrajan ili kada ono uopšte nije neophodno u procesu projektovanja.



Slika 1. Blok šema neuronskog modela za predikciju DC i S parametra HBT tranzistora

2. MODELOVANJE STATIČKIH KARAKTERISTIKA HBT-a POMOĆU NEURONSKIH MREŽA

Za potrebe simulacije i projektovanja kola koja sadrže HBT tranzistore, razvijen je neuronski DC model koji obezbeđuje predikciju sledećih statičkih karakteristika komponente (u sprezi sa zajedničkim emitorom): $I_c(V_{ce}, I_b)$ - struja kolektora I_c u funkciji napona između kolektora i emitora V_{ce} , za konstantne vrednosti struje baze I_b i $V_{be}(V_{ce}, I_b)$ - napon između baze i emitora V_{be} u funkciji napona V_{ce} , za konstantne vrednosti I_b .

Model za statičke karakteristike prikazan je na Sl.1. Neuronska mreža označena sa N_{bc} obezbeđuje da se na osnovu jednosmerne struje baze I_b i jednosmernog napona između kolektora i emitora V_{ce} na ulazu, na izlazu generišu odgovarajuće vrednosti struje kolektora I_c i napona između baze i emitora V_{be} .

Za ovu svrhu korišćena je tzv. MLP (Multi-Layer Perceptron Network) neuronska mreža, sa ukupno četiri sloja neurona: jednim ulaznim slojem sa dva neurona, jednim izlaznim slojem sa dva neurona i dva skrivena sloja. Neuronu u ulaznom sloju odgovaraju naponu V_{ce} i struji I_b , a izlazni neuroni odgovaraju struji I_c i naponu V_{be} . Za obučavanje neuronskih mreža korišćen je back-propagation algoritam [4]. Skup podataka za obučavanje (trening skup) obezbeđuje se eksperimentalnim putem tj. neposrednim merenjem, ili pak simulacijom pomoću neke tehnike koja je po pravilu kompleksna i zahtevna po pitanju vremenskih i drugih resursa. U ovom radu za obučavanje su korišćeni eksperimentalno dobijeni podaci.

Kod razvoja neuronskih mreža bitno je dobro odabrati topologiju mreže. Broj skrivenih slojeva i broj neurona u njima treba odabrati tako da bude ostvarena zadovoljavajuća tačnost a da pri tome neuronska mreža ne bude previše kompleksna. Moguća su dva pristupa kada su u pitanju skriveni slojevi: da se njihova topologija unapred fiksira i da za takvu konfiguraciju mreže izvrši obučavanje, ili da se više modela sa različitim topologijama skrivenih slojeva obučava, a zatim da se odabere najbolji. U radu je korišćen ovaj drugi pristup.

Kao kriterijum za poređenje modela korišćeni su zahtevi da je vrednost srednje greške i greške najgoreg slučaja što manja, a vrednost *Pearson Product-Moment* korelacionog koeficijenta [4] što bliža jedinici. Testiranje sposobnosti generalizacije neuronske mreže vršeno je za one vrednosti ulaznih parametara koje nisu korišćene u procesu obučavanja.

Neuronski modeli su razvijeni za jednu grupu uzoraka AlGaAs HBT tranzistora za koje su DC i mikrotalasna merenja direktno na *wafer*-ima izvršena na *Northeastern University, Boston, USA*. Ovdje će biti prikazani rezultati za HBT sa oznakom *wafer*-a 40017-001-4. Za ovaj tranzistor za obučavanje i testiranje neuronske mreže na raspolaganju je bilo 195 vrednosti struje kolektora I_c i isto toliko vrednosti napona između emitora i baze V_{be} . Ove vrednosti su izmerene u opsegu vrednosti DC napona V_{ce} (-0.5 do +5)V i u opsegu vrednosti DC struje I_b (10 do 90) μA . "Prostor" ulaznih podataka je adekvatno pokriven imajući u vidu izraženu nelinearnost izlaznih karakteristika, na taj način što su tačke u kojima je vršeno merenje neuniformno

raspoređene. Naime, napon V_{ce} u podopsegu (-0.5 do +1)V menjan je sa korakom od 0.05V, a u podopsegu (1 do 5)V sa korakom od 0.5V. Struja baze I_b uzima ukupno 5 diskretnih vrednosti, a to su: 10 μA , 30 μA , 50 μA , 70 μA i 90 μA .

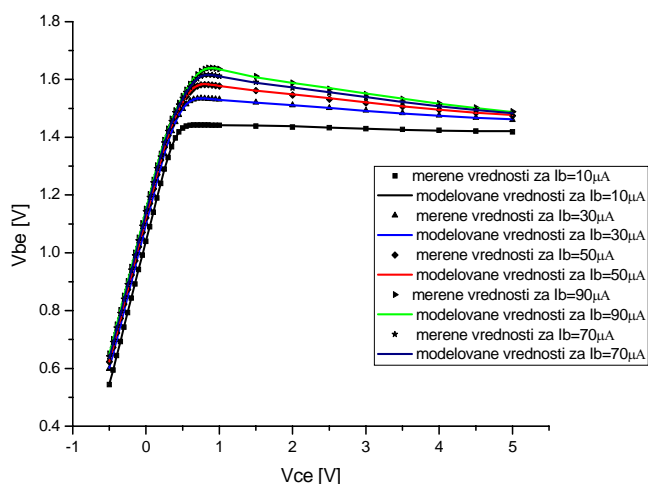
Od ukupnog broja tačaka sa različitim kombinacijama napona kolektora i struje baze, za obučavanje neuronske mreže korišćeno je 156 tačaka, tako da je trening datoteka sadržala 312 podatka. Ostatak od 39 tačaka sa ukupno 78 podataka korišćen je za formiranje test datoteke za proveru sposobnosti generalizacije mreže.

Izvršeno je obučavanje neuronskih modela sa dva skrivena sloja i sa različitim kombinacijama broja neurona u njima, pri čemu se broj neurona u skrivenim slojevima kretao u granicama od 2 do 10. Pošto su u procesu obučavanja korišćene mreže koje u svojim skrivenim slojevima imaju sve kombinacije brojeva od 2 do 10 ukupan broj obučanih neuronskih mreža bio je 90. Pored toga, u cilju poboljšanja tačnosti neuronskih modela u ovom radu izvršeno je višestruko obučavanje jedne iste mreže, jer se zbog različitih početnih vrednosti parametara neuronske mreže greške modela mogu u određenoj meri razlikovati. Konkretno, u ovom radu je izvršeno obučavanje svake mreže po tri puta kako bi se odabrala mreža čiji model daje najmanju grešku. Zbog toga je efektivan broj treniranih neuronskih mreža bio $3 \times 90 = 270$. Vreme potrebno za obučavanje ovih modela na današnjem Pentium 4 računaru sa procesorom deklarisanim na 2500+ i sa 512MB RAM-a iznosilo je u proseku 36 minuta. Međutim, kada se jednom razvije, neuronski model daje praktično trenutni odziv.


Modeli su testirani na trening skupu i izvan trening skupa, tj. za podatke koji nisu korišćeni u procesu obučavanja. Na osnovu rezultata testiranja, kao najbolji dobijeni model izabran je model označen sa 2M4_6_10. Brojevi 6 i 10 označavaju broj neurona u prvom i drugom skrivenom sloju, respektivno. Broj 2 označava drugo sukcesivno obučavanje mreže sa izabranom konfiguracijom. Za izabrani model, vrednosti srednje greške pri testiranju na trening skupu su manje od 0.13%, a izvan trening skupa manje od 0.27%. Greška najgoreg slučaja pri testiranju na trening skupu ne prelazi 0.72%, a izvan trening skupa 0.88%. Korelacioni koeficijent za oba slučaja je veoma blizak jedinici.

Uspješnost modelovanja može se verifikovati i neposrednim poređenjem karakteristika generisanih pomoću neuronske mreže, sa referentnim krivama koje odgovaraju merenim podacima, kao što je prikazano na slikama 2. i 3. za $V_{be}(V_{ce}, I_b)$ i $I_c(V_{ce}, I_b)$, respektivno. Kod obe familije karakteristika, krive koje se odnose na $I_b = 70 \mu A$ dobijene su za ulazne podatke izvan trening skupa, a pri tome se može uočiti odlično slaganje.


Zahvaljujući dobroj sposobnosti generalizacije, razvijeni neuronski model omogućava odziv zadovoljavajuće tačnosti pri kontinuiranoj promeni napona V_{ce} i struje I_b unutar kompletnog radnog opsega. Na slikama 4. i 5. prikazani su trodimenzionalni dijagrami statičkih karakteristika $V_{be}(V_{ce}, I_b)$ i $I_c(V_{ce}, I_b)$, respektivno, generisani pomoću neuronske mreže sa mnogo manjim korakom promene ulaznih parametara u odnosu na trening skup. Uočava se da su 3D dijagrami glatki i bez naglih promena, što znači da neuronska mreža i između trening tačaka u kojima po pravilu "dobro nauči" postavljeni zadatak, daje zadovoljavajući odziv.




Slika 2. Karakteristike $V_{be}(V_{ce}, I_b)$ dobijene pomoću neuronskog modela u poređenju sa eksperimentalnim podacima



Slika 3. Karakteristike $I_c(V_{ce}, I_b)$ dobijene pomoću neuronskog modela u poređenju sa eksperimentalnim podacima



Slika 4. Trodimenzionalni prikaz statičkih karakteristika $V_{be}(V_{ce}, I_b)$ generisanih neuronskim modelom



Slika 5. Trodimenzionalni prikaz statičkih karakteristika $I_c(V_{ce}, I_b)$ generisanih neuronskim modelom


3. MODELOVANJE S PARAMETARA

Drugi deo neuronskog modela HBT tranzistora predstavlja neuronska mreža koja je na Sl.1. označena sa $N_{[S]}$ i koja obezbeđuje na izlazu S parametre tranzistora u čitavom radnom frekvencijskom opsegu komponente i za bilo koje uslove napajanja iz radnog opsega jednosmernog napona kolektora V_{ce} i jednosmerne struje baze I_b . Dakle, mreža ima tri ulaza koja odgovaraju naponu V_{ce} , struji I_b i frekvenciji f , i 8 izlaza koji odgovaraju modulima i argumentima parametara S_{11} , S_{12} , S_{21} i S_{22} .

Za istu grupu uzoraka AlGaAs HBT tranzistora razvijeni su neuronski modeli za S parametre, koristeći slične principe i metode za obučavanje i testiranje kao u slučaju DC modela. Kod pomenutog HBT tranzistora sa oznakom *waf*er-a 40017-001-4 ukupan broj podataka za S parametre je 5712. Ovaj set podataka odgovara frekvencijskom opsegu (0.1 do 40) GHz, s tim da je u podopsegu (0.1 do 0.5) GHz frekvencijski korak 0.05 GHz, u podopsegu (0.5 do 1) GHz - 0.1 GHz, u podopsegu (1 do 10) GHz - 1 GHz, a u podopsegu (10 do 40)GHz - 2 GHz. Na taj način broj diskretnih tačaka sa kojima je pokriven radni frekvencijski opseg bio je 34. U svakoj od ovih frekvencijskih tačaka merenja su vršena posebno za različite kombinacije napona kolektora i struje

baze, pri čemu je jednosmerni napon kolektora V_c uzimao vrednosti 1.5, 2 i 3 [V], dok su za jednosmernu struju baze uzimane vrednosti 6, 9, 15, 32, 56, 96 i 126 [μ A]. Ukupan broj tako dobijenih tačaka je 714, a za svaku od njih postoji po 8 merenih podataka: $|S_{11}|$, $\angle S_{11}$, $|S_{12}|$, $\angle S_{12}$, $|S_{21}|$, $\angle S_{21}$, $|S_{22}|$ i $\angle S_{22}$. Od ukupnog broja tačaka sa različitim kombinacijama frekvencije, napona kolektora i struje baze, za obučavanje neuronske mreže korišćeno je 578 tačaka, tako da je trening datoteka sadržala 4624 podatka. Ostatak od 136 tačaka sa ukupno 1088 podataka korišćen je za formiranje test datoteke za proveru sposobnosti generalizacije mreže. Obučavanje na gore pomenutom tipu računara iznosilo je u proseku dva sata i petnaest minuta. Na osnovu rezultata testiranja na trening skupu i izvan trening skupa, kao najbolji dobijeni model izabran je model označen sa 2M4_16_15.

Ilustracije radi na slici 6 prikazane su modelovane (kontinualne krive) i merene vrednosti S parametara za sledeće dve tačke napajanja: (1) $V_c = 2V$, $I_b = 9\mu A$ i (2) $V_c = 2V$, $I_b = 96\mu A$, koje se nalaze izvan trening skupa, dakle za koje nije vršeno obučavanje neuronske mreže. Može se uočiti izuzetno dobro slaganje odziva modela sa merenim podacima.



Slika 6. S parametri dobijeni pomoću neuronskog modela (kontinualne krive) u poređenju sa eksperimentalnim podacima (1) $V_c = 2V$, $I_b = 9\mu A$, (2) $V_c = 2V$, $I_b = 96\mu A$

Razvijeni neuronski modeli za DC karakteristike i S parametre HBT tranzistora jednostavno se mogu ugraditi u komercijalni mikrotalasni simulator kola kao što je ADS i koristiti kao korisnički-definisani bibliotečki elementi.

4. ZAKLJUČAK

Korišćenje neuronskog pristupa za modelovanje aktivnih komponenata u savremenim komunikacionim sistemima, na način prikazan u ovom radu, pogodno je kada u postupku analize i projektovanja nije neophodno poznavati ekvivalentno kolo komponente. Uspešno su razvijeni neuronski modeli za predikciju statičkih karakteristika i S parametara HBT tranzistora za praktično celi radni opseg uslova napajanja komponente. Oba neuronska modela mogu se implementirati u okviru nekog od standardnih mikrotalasnih simulatora (npr. ADS i sl.).

Da bi se kompletirao neuronski model za RF karakteristike HBT tranzistora za male signale i malošumne aplikacije, u narednoj fazi pored neuronskih mreža za određivanje S parametara biće razvijene i neuronske mreže za generisanje parametara šuma ovih komponenata.

Zahvalnica:

Ovaj rad je vezan za istraživanja u okviru projekta MNTR br. 101351. Autori se zahvaljuju prof. Sheili Prasad, *Northeastern University, Boston, USA*, za rezultate merenja na uzorcima HBT-a.

LITERATURA

- [1] N.L.Wang, "Transistor Technologies for RFICs in Wireless Applications", *Microwave Journal*, pp. 98-110, February, 1998.
- [2] P.F.Chen et al., "Application of GaInP/GaAs DHBTs to Power Amplifiers for Wireless Communications", *IEEE Trans. Microwave Theory Tech.*, vol. MTT-47, pp. 1433-1437, August 1999.
- [3] T. Daniel, R. Tayrani, "DC and High Frequency Models for Heterojunction Bipolar Transistors", *IEEE GaAs IC Symposium Proceedings*, pp. 299-302, 1996.
- [4] S. Haykin, *Neural networks*, New York, IEEE, 1994.
- [5] Q. J. Zhang, K. C. Gupta, *Neural Networks for RF and Microwave Design*, Artech House, 2000.
- [6] V. Marković, A. Stošić, "Modelovanje mikrotalasnih HBT tranzistora za primene u bežičnim komunikacijama", *Zbornik radova Telfor 2004*, Sekcija 9, Beograd, Novembar 2004.

Abstract – HBTs are very convenient active components for microwave wireless communications. This paper presents a unified model that generates DC characteristics as well as S parameters over the whole operating range. Modeling procedure is based on the neural network approach, which enables high accuracy together with the efficiency and simplicity commonly requested from CAD techniques.

MODELING DC AND RF CHARACTERISTICS FOR HBT's USING NEURAL APPROACH

Vera Marković, Aleksandar Stošić