

Vančo B. Litovski*, Jasna I. Radjenović*, Željko M. Mrčarica*, Srdjan LJ. Milenković*,
Zlatko Zografski**

* Elektronski fakultet, Niš, Beogradska 14

** Elektrotehnički fakultet, Skopje, Karpoš II, bb

MODELIRANJE MOS TRANZISTORA NEURONSKOM MREŽOM

MOS TRANSISTOR MODELING USING NEURAL NETWORK

SADRŽAJ: Neuronska mreža je iskorišćena za modeliranje MOS tranzistora. Neuronska mreža, naučena na skupu podataka iz karakteristika tranzistora, sposobna je da reprodukuje te karakteristike. Ospozljivena je i da daje izvode struje komponente po naponima priključaka, potrebne u procesu simulacije. Dobijeni rezultati pokazuju da se ovim pristupom mogu modelirati elektronske komponente za potrebe simulacije elektroničkih kola. Time je omogućeno da se čitav niz elektronskih komponenata, pa i složenija kola nepoznate strukture, na jednostavan način modeliraju, samo na osnovu niza tačaka dobijenih merenjem.

ABSTRACT: Neural network is used for MOS transistor modeling. Neural network, learned on the basis of the training set extracted from the transistor characteristics, is able to reproduce those characteristics. Network is enabled to produce derivatives of component current over terminal voltages, needed in circuit simulation. Results show that it is feasible to model electronic components for the purpose of electronic circuit simulation. It gives us opportunity to model wide range of electronic components, even complex circuits of unknown structures, using method of network learning. Data needed for modeling is a set of measured points.

1. UVOD

1.1 Neuronske mreže

Kako se mnogi problemi ne mogu rešiti konvencionalnim programiranjem javila se potreba za jednim novim, biološki inspirisanim sistemom koji može da uči i koristi iskustvo, vrši slične aktivnosti onima koje se odvijaju u mozgu živog bića. Tako je počeo razvoj veštačkih neuronskih mreža [1].

Veštačke neuronske mreže sastoje se od mnogo prostih, međusobno povezanih veštačkih neurona. Ovi veštački neuroni imaju samo skromnu sličnost sa realnim. Svaki veštački neuron ima određeni broj ulaza x_i i poseduje težinu veze w_i . Težine su prilagodljivi koeficijenti na vezama unutar mreže i one određuju intenzitet ulaznog signala. Možemo razmišljati o njima kao o meri jačine veze. Suma proizvoda $w_i x_i$ daje jedan izlaz y_i . Ovaj izlaz je funkcija f težinske sume kao i praga T_i . U eksperimentu opisanom u ovom radu korišćena je mreža gde je izlaz veštačkog neurona oblika:

$$y_i = \sum_{i=1}^n w_i x_i + T_i \quad (1.1)$$

Slika 1.1 prikazuje veštački neuron.

Funkcija f naziva se prenosnom funkcijom veštačkog neurona. U upotrebi je određen broj prenosnih funkcija i to: sigmoid "S" funkcija, sinusna funkcija, hiperbolična funkcija i razne pragovske i linearne funkcije. Funkcija f zadržava svoju vrednost tokom života (rada) veštačkog neurona. Drugim rečima, ona ne može biti podešena ili modifikovana tokom rada neuronske mreže.

Medutim, težine su promenljive. One mogu biti dinamički prilagodjenje u cilju proizvodnje željenog izlaza. Ova mogućnost prilagodjenja težina je osnova učenja neuronske mreže. Na nivou jednog veštačkog neurona ovo prilagodjenje je jednostavna stvar. Kada mnogo međusobno povezanih veštačkih neurona to rade zajedno, ovu pojavu nazivamo "inteligencijom". Pragovi se mogu menjati na isti način kao težine.

Veštački neuroni se obično grupišu u linearne oblasti (slojeve). Može se povezati više slojeva. Sloj koji je povezan sa ulazima neuronske mreže je ulazni sloj. Izlazi neuronske mreže se generišu od strane izlaznog sloja. Svi ostali slojevi se nazivaju skrivenim slojevima jer nemaju dodir sa spoljašnjosti.

Učenje je proces kojim neuronska mreža menja svoje težine kao odgovor na spoljašnji ulaz. Recimo, kod nadgledanog tipa učenja tekući izlaz neuronske mreže se poredi sa željenim izlazom. Početne vrednosti težina se slučajno zadaju, a zatim modifikuju tako da sledeća iteracija ili sledeći ciklus daje bliže slaganje sa željenim izlazom. Cilj svih procedura je da se na kraju minimizira greška (razlika) između željenog i tekućeg izlaza.

Kod ovakvog učenja neophodno je zadati mreži skup podataka za treniranje. To znači da je za svaki ulaz u skupu podataka za treniranje predstavljen željeni izlaz neuronske mreže.

Faza učenja može zahtevati mnogo vremena. Smatra se da je učenje završeno kada neuronska mreža daje željene izlaze za zadatu sekvencu ulaza. Težine se onda "zamrzavaju". Naučena mreža onda može da vrši preslikavanje ulaznog skupa podataka u izlazni. Kao takva, ona se može koristiti za aproksimaciju analitičkih funkcija, pa i analitičkih izraza kojima se modelira elektronska komponenta.

1.2 Modeliranje elektronskih komponenata

Model elektronske komponente pretstavlja zavisnost struje komponente od napona na njenim priključcima. Model može biti vrlo složen. Medutim, za potrebe simulacije

elektronskih kola pomoću računara najpogodnije je da model bude analitički, dat jednotavnim izrazima. To omogućava da se izvodi izlazne veličine po naponima na njenim priključcima računaju brzo. To izračunavanje se izvršava mnogo puta, u svakoj iteraciji rešavanja nelinearnog sistema.

Model MOS tranzistora može se, uz izvesne aproksimacije, izraziti analitičkim izrazima. Postojeći modeli koji su zadovoljavajući u pogledu brzine i tačnosti su bazirani na polu-empirijskom pristupu modeliranju [2,3]. Znači da se pojednostavljeni model, nastao analizom fizičkih procesa u komponenti, podešava prema merenim karakteristikama.

Model MOS tranzistora sadrži, sem dimenzija i niz tehnoloških podataka potrebnih za kvalitetno modeliranje. On je dat posebnim izrazima u različitim oblastima rada: triodna oblast, zasićenje i prepragovska oblast. Za uspešnu simulaciju veoma je bitno da postoji neprekidnost analitičke funkcije i njenih izvoda pri prelasku iz jedne u drugu oblast rada. Obično je obezbeđenje ovih uslova najteži problem prilikom modeliranja.

Analitički izrazi kojima se opisuje komponenta mogu se dobiti analizom fizičkih procesa u njoj. Drugi pristup je modeliranje komponente kao "crne kutije". Tu se samo na osnovu merenih karakteristika komponente dobijaju analitički izrazi kojima se ona opisuje. Time se, istina je, gubi uvid u fizičke procese u sistemu, ali se dobijaju jednostavniji izrazi koji dovoljno tačno aproksimiraju stvarne funkcije.

Neuronska mreža modelira elektronsku komponentu kao "crnu kutiju". Ona nauči karakteristiku tranzistora na osnovu niza tačaka iz polja tih karakteristika. Zatim naučena mreža, u procesu eksploracije reproducuje te karakteristike. Proširivanjem programa za korišćenje naučene neuronske mreže ona je osposobljena da sem izlazne struje, daje i izvode potrebne u programu za simulaciju.

2. POSTUPAK MODELIRANJA

Kao što je već pomenuto, da bi neuronska mreža naučila analitičku funkciju, potrebno je zadati skup ulaznih i izlaznih podataka za učenje. Kao ulazi neuronske mreže u našem eksperimentu zadavane su vrednosti napona U_{ds} i U_{gs} , a kao željeni izlaz struja I_d , tako da se postupak svodi na preslikavanje ulaznih napona u struju drejna. Znači, za treniranje neuronske mreže koriste se trojke $\{U_{ds}, U_{gs}\}$, $\{I_d\}$.

Napon osnova-sors je održavan na nuli. Naravno, može i on biti uključen u skup promenljivih napona. Ulagani parametar može biti i temperatura.

Za učenje neuronske mreže korišćen je program LEARNNET [4]. Ovaj program učenja je nadgledani model učenja i predstavlja jednu varijantu pravila gradjentne metode [5]. Proces učenja se odvija tako što se a) predstavlja ulaz, b) prosledjuje unapred kroz mrežu, c) izračunava se izlaz za svaki veštački neuron, d) svi tekući izlazi se porede sa željenim i zatim se e) izračunava greška. U cilju minimizacije greške se zatim vrši modifikacija težina i pragova.

Program LEARNNET realizovan je za troslojnu neuronsku mrežu, sa samo jednim skrivenim slojem neurona. Neuroni ulaznog sloja nemaju težine ni pragove i oni samo prosledjuju signale neuronima sledećeg, skrivenog sloja.

Struktura neuronske mreže kojom smo modelirali MOS tranzistor prikazana je na slici 2.1. Neuronska mreža ima dva neurona u ulaznom sloju, deset neurona u skrivenom sloju i jedan neuron u izlaznom sloju. Pokazalo se da je kao prenosne funkcije najbolje koristiti sigmoid funkciju za skriveni sloj neurona (2.1) i linearnu funkciju za izlazni sloj neurona (2.2).

$$y = \frac{1}{1 + e^{-\lambda_1 x}}, \quad (2.1)$$

$$y = \lambda_2 x. \quad (2.2)$$

Ulazi neuronske mreže odgovaraju vrednostima napona U_{ds} i U_{gs} , dok je izlaz struja I_d .

Skup podataka za učenje generisan je programom SPICE [3]. Prvi eksperimenti pokazali su da mreža lako nauči da dobro reprodukuje karakteristike u oblasti zasićenja na osnovu malog broja tačaka, ali da je potrebno zadati veći broj tačaka za učenje u triodnoj oblasti rada i u slučaju kada je napon gejt-sors blizak naponu praga ili manji od njega.

Za generisanje izlaza neuronske mreže na osnovu naučenih vrednosti težina i pragova korišćen je program RUNNET [4]. Ulaz u program RUNNET u ovom eksperimentu su naponi drejn-sors i gejt-sors, dok je izlaz struja drejna.

Za računanje izvoda izlaza neuronske mreže po ulazima realizovan je novi program GRADNET. Program GRADNET ima iste ulaze kao program RUNNET, dok su izlazi

$\frac{\delta I_d}{\delta U_{ds}}$ i $\frac{\delta I_d}{\delta U_{gs}}$. Pomenuti izvodi se u ovom eksperimentu računaju po zakonu:

$$\frac{\delta I_d}{\delta U_{ds}} = \lambda_2 \lambda_1 \sum_{i=1}^{10} \frac{1}{1 + e^{-\lambda_1 y_i}} \left(1 - \frac{1}{1 + e^{-\lambda_1 y_i}}\right) w_{ii}^{(1)} w_{3i}^{(2)}, \quad (2.3)$$

$$\frac{\delta I_d}{\delta U_{gs}} = \lambda_2 \lambda_1 \sum_{i=1}^{10} \frac{1}{1 + e^{-\lambda_1 y_i}} \left(1 - \frac{1}{1 + e^{-\lambda_1 y_i}}\right) w_{2i}^{(1)} w_{3i}^{(2)}, \quad (2.4)$$

gde su $w_{ii}^{(1)}$ i $w_{2i}^{(1)}$ težine skrivenog sloja neurona, a $w_{3i}^{(2)}$ težine izlaznog sloja neurona, dok je:

$$y_i = \sum_{j=1}^2 x_j w_{ij}^{(1)} + T_i^{(1)}. \quad (2.5)$$

i $x_1 = U_{ds}$, a $x_2 = U_{gs}$.

GRADNET se može primeniti i na uopšteni slučaj kada je zadat proizvoljan broj neurona ulaznog i skrivenog sloja.

Sa novim skupom podataka za učenje, neuronska mreža je prošla kroz 805 iterativnih ciklusa, dok funkcija greške nije ušla u oblast minimuma. Ukupna apsolutna kvadratna greška na 3136 uzoraka (tačaka na karakteristikama) dostigla je minimum od 0.0066492A².

Naučena mreža sada u stvari predstavlja model MOS tranzistora. Karakteristike ovog modela prikazane su dalje u ovom radu.

3. DOBIJENI REZULTATI

Na slici 3.1 prikazane su izlazne karakteristike novog modela MOS tranzistora (puna linija) i izlazne karakteristike tranzistora korišćenog za učenje generisane programom SPICE (isprekidana linija).

Slika 3.2 prikazuje izvode modela izlazne struje (struje drejna) po naponu U_{ds}, pri konstantnom naponu U_{gs}.

Kao što pokazuju slike 3.1 i 3.2 naučene izlazne karakteristike ispoljavaju vrlo dobro poklapanje sa izvornim izlaznim karakteristikama. Postoji kontinualnost struje i izvoda struje pri prelasku iz triodne oblasti u zasićenje (slika 3.3) što je bitno za simulaciju. Relativna odstupanja su međutim, nešto veća pri malim vrednostima napona i struje.

Na slici 3.4 mogu se videti prenosne karakteristike modela MOS tranzistora (puna linija) i prenosne karakteristike tranzistora korišćene za učenje (isprekidana linija).

Strmina modela MOS tranzistora (izvod struje drejna po naponu U_{gs} pri konstantnom naponu U_{ds}) prikazana je na slici 3.5.

Poklapanje prenosne karakteristike dobijenog modela MOS tranzistora sa karakteristikama koje su dobijene programom SPICE je vrlo dobro (slika 3.4).

Opet se mogu uočiti nešto veća relativna odstupanja pri malim naponima U_{gs} (bliskim naponu praga ili manjim od njega).

Ova odstupanja se manifestuju i kroz grešku izvoda u pretpragovskoj oblasti.

U programu LEARNNET kao kriterijum konvergencije ka željenim izlazima koristi se apsolutna greška. Kako je kod malih vrednosti struje apsolutna greška u zadovoljavajućim granicama, a relativna nije, u daljim eksperimentima koristiće se kombinacija apsolutne i relativne greške.

Sem toga nešto su veća odstupanja pri eksploataciji modela pri naponima koji su na granici oblasti napona korišćenih u procesu učenja. Zato je pogodno da se mreža uči na širem skupu podataka od onog koji se može javiti pri normalnoj upotrebni. To u ovom eksperimentu znači da treba preći u oblast inverzne polarizacije i oblast negativnih napona gejt-sors pri učenju mreže.

Povećavanje broja neurona skrivenog sloja daje bolje rezultate u pogledu učenja karakteristika komponente. To, međutim povećava vreme učenja, što nije od velikog značaja jer se učenje vrši samo jednom.

Povećanje broja neurona u izvesnoj meri usporava i izračunavanje vrednosti parcijalnih izvoda (2.3) i (2.4). Iako je vreme potrebno za njegovo izvršavanje i dalje veoma kratko, to može biti od značaja jer se izvodi u programu za simulaciju računaju veliki broj puta, u

svakoj iteraciji pri rešavanju nelinearnih kola. Zato ne treba koristiti veću tačnost modela od one koja je neophodna za željenu primenu.

4. ZAKLJUČAK

Neuronska mreža je sposobna da nauči karakteristiku električnog elementa i da postane njegov model. Ona može da daje sve informacije o tom elementu potrebne u programu za simulaciju elektronskih kola.

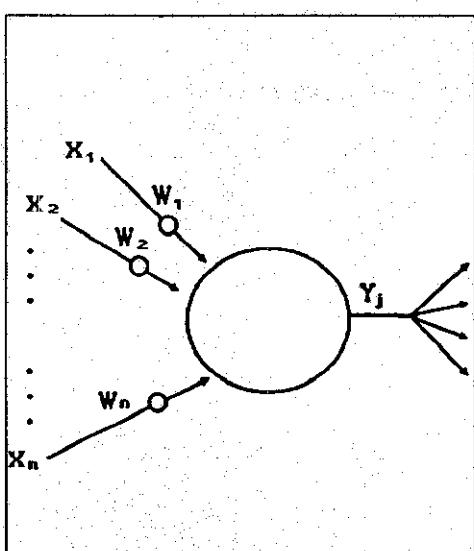
Ovo otvara mogućnosti da se veliki broj različitih elektronskih komponenata, pre svega složenih sklopova modelira na jednostavan način, bez potrebe da se analizira unutrašnja struktura. Dobijeni modeli svrstavaju se u kategoriju funkcionalnih modela.

Modeliranje komponenata je sadržano u procesu učenja mreže. Vreme učenja može uzeti sate rada računara, zavisno od složenosti karakteristike kola (ne i od složenosti samog kola). Kada se radi o modeliranju po principu "crne kutije", prednost neuronske mreže ogleda se u tome što se koristi jedinstvena mreža, nezavisno od tipa komponente i unificiran način učenja. Tako, čak i ako učenje traje duže od rada eventualnog programa za ekstrakciju parametara modela "crne kutije", ostaju značajne prednosti neuronske mreže kao modela.

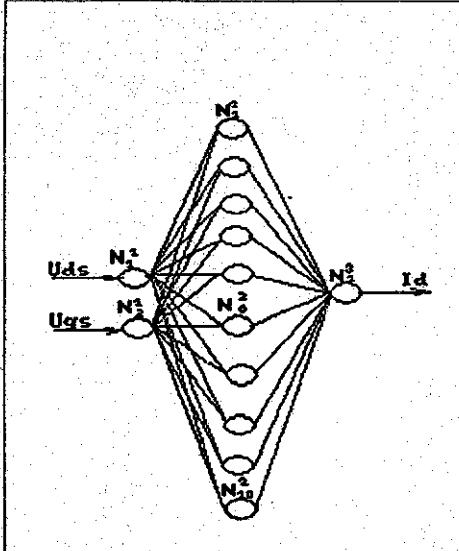
Rezultati prikazani u ovom radu potvrdili su nam opravdanost ovakvog pristupa. Dalji eksperimenti biće usmereni ka poboljšanju karakteristika modela, modeliranju složenih kola i ugradnji u program za simulaciju, kao i redukciji skupa podataka za učenje uz zadržavanje tačnosti.

5. LITERATURA

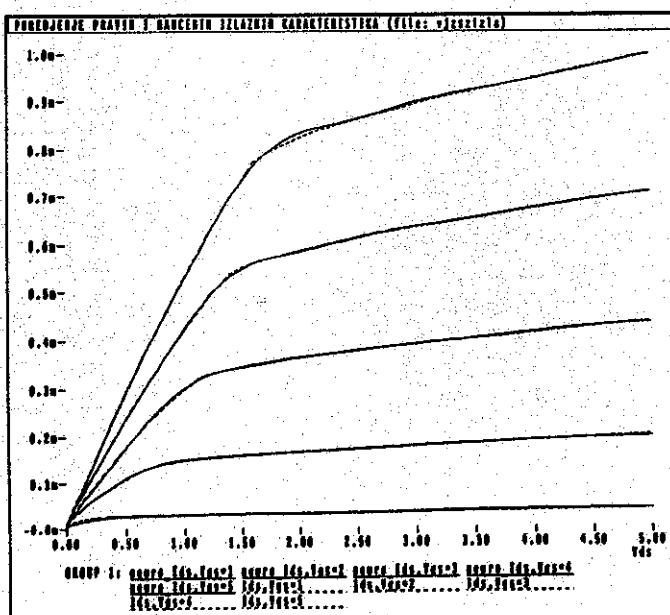
- [1] M. McCord Nelson and W.T. Illingworth, "A Practical Guide to Neural Nets", edited by Addison-Wesley Publishing Company, Inc., 1990.
- [2] Ž. Mrčarica, V. Litovski, P. Petković, "Izbor modela kratkokanalnog MOS tranzistora za simulaciju elektronskih kola", Tehnika (Elektrotehnika), Beograd, No. 5-6, pp. 391-395, 1991.
- [3] E. Profumo, "The MOS Transistor", in "Semiconductor Device Modeling with SPICE", edited by P. Antognetti, G. Massobrio, McGraw-Hill Book Company, pp. 143-207, 1987.
- [4] Z. Zografski, "A Novel Machine Learning Algoritam and its Use in Modelling and Simulation of Dynamical Systems", Proceeding of European Computer Conference, pp. 860-864, 1991.
- [5] D.E Rumelhart, G.E. Hinton, and R.J. Williams, "Learning internal representations by error propagation", Parallel Distributed Processing: Explorations in the Microstructures of Cognition, Vol.1, D.E. Rumelhart and J.L. McClelland(Eds.), MA: MIT Press, pp. 318-362.



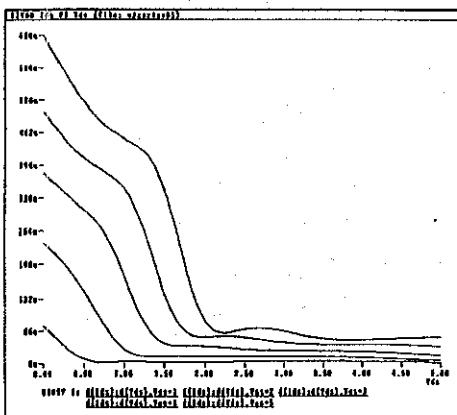
Slika 1.1 Veštački neuron



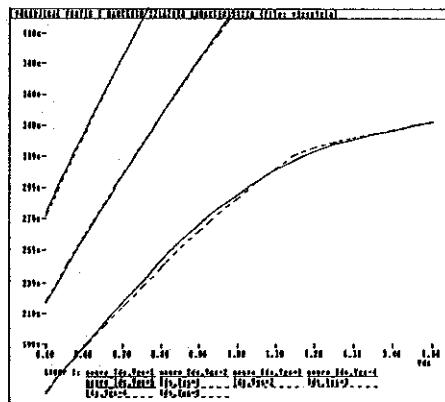
Slika 2.1 Neuronska mreža korišćena za modeliranje MOS tranzistora



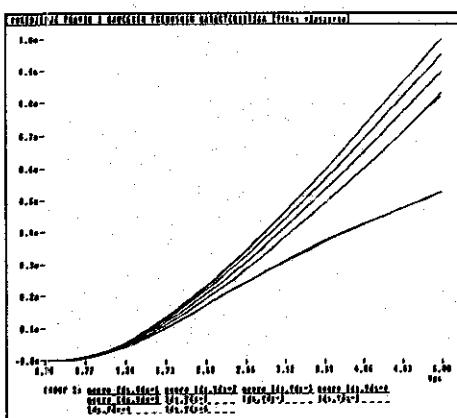
Slika 3.1 Poredjivanje izvornih i naučenih izlaznih karakteristika



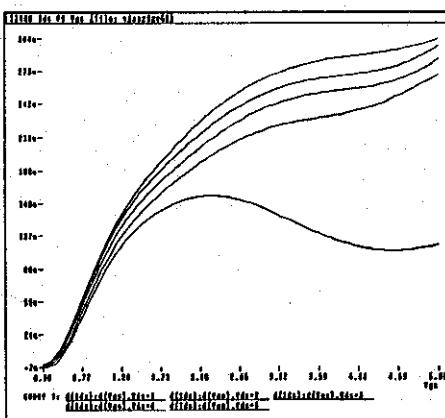
Slika 3.2 Izvod Ids po Uds



Slika 3.3 Poredjene izvorne i naučene izlazne karakteristike



Slika 3.4 Poredjene izvorne i naučene prenosne karakteristike



Slika 3.5 Izvod Ids po Ugs