

Summary

Modeling of nonlinear reactive electronic circuits using artificial neural networks

The problem of modeling of electronic components and circuits has been interesting since the first component was developed. Lately, though the behavioural simulators involving continuous and discrete signals at the same time are developed, the problem of modeling electronic circuits, especially nonlinear, reactive circuits, has become particularly actual. This kind of models enables hierarchical presentation of the complex electronic systems and verification of every synthesis phase from the functional to the physical presentation. The lack of alternative means of verification of the synthesis results makes the modeling problem solutions very significant. The main problem in modeling of nonlinear reactive circuits is because their characteristics are irreversible, sometimes causing chaotic behaviour.

Artificial neural networks have been used for many applications for years, such as: pattern recognition, speech recognition, process control, and so on. The fact they are universal approximators was the motivation for their use in modeling of electronic components. Very often, the physics of the component is not known in a detail, because there exist many complex processes that can be electrical, magnetic, or mechanical. This is the reason because it is very difficult to make the physical model of the component, and in the cases like these, black-box approach is used. In fact, in order to get the analytical expression convenient for the equation formulation, the function of the component is approximated using the measured input-output characteristics. One of the very good approximators is the artificial neural network, so the goal of the research presented in this paper is modeling of nonlinear reactive circuits using neural networks.

In this work modeling of nonlinear dynamic electronic circuits in the natural, time-domain is presented. Problems concerning the model making are solved first: synthesis of the signal waveform for excitation, synthesis of the network topology, and getting the network complexity. In that way fundamental solutions are established enabling modeling of most modern electronic components, circuits and systems.

Nonlinear resistive components are modeled first. The example is MOS transistor without capacitive components. Then, nonlinear resistive two-port circuits with the slope that changes sign are modeled. The example of such a circuit is negative resistor being an element in the chaotic attractor, Chua's circuit. In that way, their usability in simulation of cellular neural networks is demonstrated.

First reactive circuits modeled are linear circuits. Modeling of such circuits verified the process of modeling, topology and complexity of the network discussed before.

The methods of modeling of nonlinear dynamic circuits and their applications are presented for the first time. The principle of modeling is presented in an example of the circuit with known structure, although the motivation for modeling of nonlinear dynamic two-port circuits is related to the development of the model and electrical surrounding of the actuator. In that case, the required method of modeling should be applied immediately based on the available knowledge, so the black-box method based on the neural networks is very suitable. Concerning that, the method of modeling of implanted hearing aids is presented.

When designing electronic and telecommunication integrated circuits, more and more complex mixed-signal systems containing both analogue and digital parts are developed. Design of such systems needs simulation tools that perform fast and accurate in the same time. One of the obstacles to this requirement is related to the accurately enough modeling of the digital-analogue (D/A) and analogue-digital (A/D) interfaces being frequently encountered in such systems. The main problem is to model input and output impedance of the logic circuit, that are highly nonlinear. In this work, the approximation of the impedance based on neural networks is presented, and it was shown in many different examples that it models the interface well enough.

All these models are verified in a simulation. The behavioral simulator is used, referring to the neural network the same as to the circuit element. Every model is implemented in a real surrounding in a simulation, so its interaction to environment and usability are presented.

Given examples show that the concept of modeling based on artificial neural networks is applicable in different situations, and it is especially useful when the model of the component is needed fast, and its physics is not completely known.

Further research in this area will be directed to the application of the presented concept in modeling of real circuits that are difficult to model, and to their realization. The improvement of the training process itself could be done by modeling of time, and the time step would be the new network input. In that way, the information on time would be implemented in the network, so the variable time step could be used. One more task is to simulate the cellular network of any complexity, because they can process signals in the real time, meaning they function like biological neural networks.

Uvod

Poslednjih decenija razvijeni su najsavremeniji digitalni računari koji koriste frekvenciju takta reda gigaherca, nasuprot frekvencije funkcionisanja ljudskog nervnog sistema koja je reda 100Hz. To znači da su procesni elementi nervnog sistema daleko sporiji od računara, ali rešavaju neke kompleksne probleme mnogo brže, a znamo i da računar može da obavi samo mali deo operacija koje čovek obavlja sa lakoćom. Upravo taj fascinantni podatak motivisao je čoveka da počne da se bavi proučavanjem neurona kao strukturnim jedinicama mozga, jer je uočio da nije od presudnog značaja brzina rada, već nešto drugo. Da bi otkrio šta je to, morao je da prouči mehanizme funkcionisanja mozga i nervnog sistema.

Kako mozak radi? Najjednostavnije rečeno, mozak obrađuje i koristi informacije. Na neki način, ljudski mozak je vrsta računara čiji su sastavni elementi nervne ćelije, a čija arhitektura je ograničena biološkom prirodom njenih elemenata i istorijom evolucije. Ali, glavno pitanje je: Koja je to vrsta računara? Koji su principi njegovih operacija? Kako on obrađuje, smešta, i pronalazi informacije? Moderne teorije zahtevaju proučavanje obrade informacija kako u pojedinačnim nervnim ćelijama, tako i u velikim mrežama ćelija, a zatim kvantitativno rešavanje i analizu predloženih modela. Za ove zadatke digitalni računar je od neprocenjive vrednosti, jer bi bez savremene računarske tehnike ova nova oblast brzo zamrla. Tako je čovek pokušao da modeluje prirodni neuron, odnosno da imitira njegov način rada, da bi povezivanjem mnoštva neurona na način sličan kao u mozgu, dobio kompleksne strukture koje bi obavljale kompleksne funkcije.

Veštačke neuronske mreže (VNM) se razlikuju od sličnih, biološki inspirisanih pristupa, po tome što one simuliraju način rada nervnog sistema, a ne psihologiju rešavanja određenih problema od strane inteligentnih bića [Mi96]. Osnovna prednost nervnog sistema je što, iako sadrži ogroman broj neurona, oni rade paralelno. I veštačka neuronska mreža je paralelna distribuirana struktura koja se takođe sastoji od velikog broja međusobno povezanih procesnih jedinica, koji su po analogiji nazvani- neuroni. Glavno svojstvo VNM, njihova sposobnost učenja, je takođe princip preuzet iz prirodnog nervnog sistema. Baš kao i čovek, VNM ima sposobnost generalizacije, tj. iz izvesnog broja rešenih problema, ona stiče "iskustvo", pa zna da pravilno reaguje u sasvim nepoznatim situacijama.

VNM se danas primenjuju u elektronici, automatici, telekomunikacijama, medicini, ekonomiji, itd. Tolika njihova popularnost objašnjava se svakako njihovom atraktivnom strukturom, ali one predstavljaju i veliki naučno- istraživački izazov.

U saglasnosti sa prethodnim, nastao je i ovaj rad, koji predstavlja rezultate primene VNM u elektronici, ili bliže rečeno, u modelovanju elektronskih kola. Istovremeno, rad sadrži niz rezultata različitih istraživača u periodu od deset godina, pa može da služi i kao podsetnik na desetogodišnjicu istraživanja u ovoj oblasti u Laboratoriji za projektovanje elektronskih kola Elektronskog fakulteta u Nišu.

U prvoj glavi biće objašnjeni osnovni pojmovi koji se tiču modelovanja elektronskih komponenti, kao što su: pojam modela, klasifikacija modela, i njihovo generisanje. Tema ovog rada je generisanje modela, ali specifičnim pristupom- upotreborom VNM.

U drugoj glavi će najpre biti objašnjeno funkcionisanje prirodnog neurona, a zatim će biti prikazana njegova analogija sa veštačkim. Slediće pregled najčešće korišćenih struktura VNM, a zatim i pregled topologija koje će biti korišćene u daljem radu. Biće objašnjen osnovni mehanizam učenja, backpropagation algoritam i njegovo poboljšanje.

⁴injenica na kojoj je zasnovano čitavo ovo istraživanje, da su neuronske mreže univerzalni aproksimatori funkcija, biće pokazana kroz niz teorema.

U trećoj glavi biće dati odgovori na pitanja koja treba rešiti pre generisanja svakog modela: koju i kakvu neuronsku mrežu koristiti, koliko uzoraka, koji je to pobudni signal, itd. Pored mnogobrojne literature i mnogih teorema koje pokušavaju da daju precizan odgovor na ova pitanja, valjanost odgovora najčešće zavisi od iskustva projektanta.

U poslednjoj, četvrtoj glavi biće dati primjeri primene VNM, tj. biće prikazan niz novih modela za elektronske komponente. Najpre će biti modelovane nelinearne otporne komponente kao što je MOS tranzistor bez kapacitivnih komponenata. Zatim će biti modelovani nelinearni otporni dvopoli koji ispoljavaju nagib sa promenljivim znakom. Biće demonstrirana njihova upotrebljivost za simulaciju celularnih neuronskih mreža. Prva reaktivna kola koja će biti modelovana biće linearna. Po prvi put će biti prikazani postupci modelovanja nelinearnih reaktivnih dvopola kao i njihova primena za modelovanje implantiranih slušnih pomagala, A/D i D/A sprege u integrisanim kolima i sl. Svi ovi modeli bi bili "neupotrebljivi" kada ne bismo mogli da ih implementiramo u simulator elektronskih kola da bismo videli njihovo ponašanje u prisustvu drugih elemenata kola. Zato će svaki od ovih modela biti implementiran u realno okruženje, prirodno za njegovu strukturu, kako bi se pokazala njegova svrha i upotrebljivost.

Sledi zaključak i spisak korišćene literature.

1 Modelovanje komponenata

Analiza električnih kola sastoji se iz dva koraka. Najpre se formuliše sistem jednačina koji opisuje dato kolo, a zatim taj sistem treba rešiti odgovarajućim analitičkim ili numeričkim metodama.

Složenost današnjih integrisanih kola i sistema zahteva automatsku analizu kola, tj. upotrebu specijalizovanih računarskih programa-simulatora elektronskih kola. Svaki simulator sadrži određeni, ograničeni skup komponenata definisanih njihovim funkcijama. Problem nastaje kada treba opisati kolo koje sadrži elemente koji nisu definisani u simulatoru. Naime, svako složeno kolo treba opisati samo pomoću elemenata koji su prethodno definisani u simulatoru. To naravno u većini slučajeva nije moguće, pa za takve elemente treba razviti opis, odnosno generisati model tog elementa.

U ovom poglavlju biće opisan pojam modela, klasifikacija i hijerarhija modela, njegova struktura i generisanje.

Model elektronske komponente je opis koji omogućava potpunu formulaciju jednačina kola u kome se nalazi komponenta, a sastoji se iz matematičkih izraza, opisa topološke strukture i algoritama za ekstrakciju parametara koji se pojavljuju u njemu [Li00]. Modeluje se baš svaka električna komponenta, s tim što su neki od modela toliko uobičajeni da se uopšte nema utisak da je bilo modelovanja. Kada pišemo Ohm-ov zakon za otpornik, ne razmišljamo o tome da je to u stvari model otpornika. Međutim, da bismo dobili potpuniji model otpornika, treba modelovati njegove nelinearnosti i temperaturske zavisnosti otpornosti. Kada otpornik radi na visokim frekvencijama, uzimaju se u obzir i induktivnosti uvodnika otpornika i parazitna kapacitivnost prema masi, pa se tada otpornik predstavlja kao složeno kolo sa svojom unutrašnjom strukturom.

1.1 Klasifikacija i hijerarhija modela

Jedna elektronska komponenta može imati nekoliko različitih modela. Svaki od tih modela može biti “bolji” od drugog za određeno kolo, pa se bira “najbolji” model za određenu primenu. Sa stanovišta modelovanja, dva najvažnija parametra signala su veličina signala i frekvencija signala.

1.1.1 Klasifikacija modela prema veličini signala

Prema veličini signala, modeli se dele na globalne, lokalne i modele za male signale [Ch75]. Globalni model je projektovan tako da može da se primeni za signale čija veličina

pokriva celokupnu oblast rada komponente. Tako bi globalni model bipolarnog NPN tranzistora obuhvatio i normalnu i inverznu polarizaciju. Globalni model fizičke komponente je uvek nelinearan, tj. mora da sadrži bar jedan nelinearni otpornik, kalem ili kondenzator. Lokalni model može i ne mora da bude nelinearan, u zavisnosti od oblasti u kojoj treba da radi. On je projektovan tako da tačno simulira ponašanje jedne komponente samo u nekim režimima rada. Tako bi model bipolarnog NPN tranzistora za normalnu polarizaciju bio lokalni. Ako se porede globalni i lokalni model neke komponente kojima se postiže ista tačnost, uvek je lokalni model jednostavniji, pa ga treba koristiti kada god je to moguće. Lokalni model se može, u opštem slučaju, dobiti iz globalnog izostavljanjem nekih elemenata, izraza ili delova modela. Globalni model je jedan, lokalnih ima mnogo.

Ako u okolini jedne tačke na karakteristikama elementa signal ima vremenski promenljivu komponentu male amplitude, tada se može primeniti model za male signale. U ovom slučaju se jednosmerne komponente struja i napona apstrahuju, pa model i dalje predstavlja vezu između napona i struja, ali važi samo za veoma malu okolinu radne tačke gde se pretpostavlja da su karakteristike linearne. Ovaj model je iskazan sistemom linearnih jednačina, pa se zato zove linearni model za male signale. On se dobija posle manipulacija sa izvodima karakteristika.

1.1.2 Klasifikacija modela prema frekvenciji signala

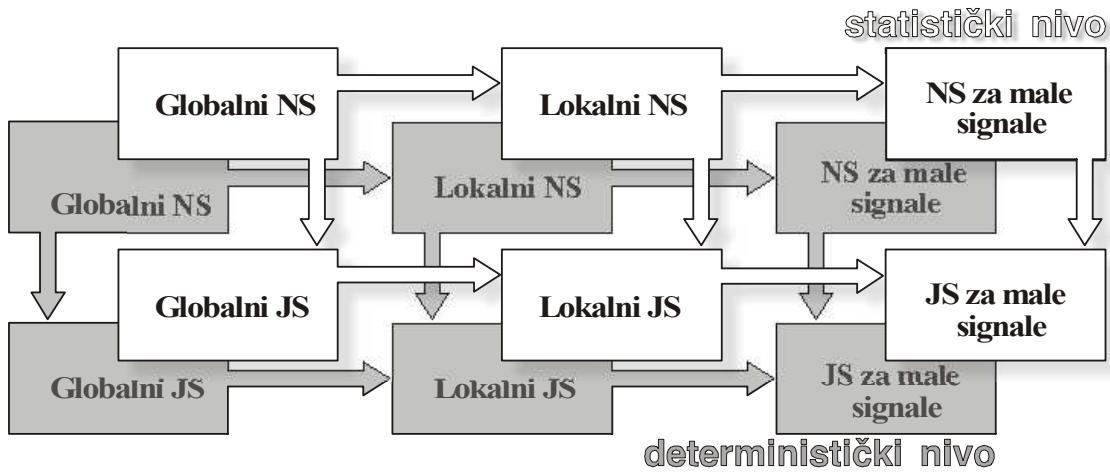
Prema frekvencijskom opsegu za koji je model projektovan, napravljena je podela u dve grupe: modeli za jednosmerne signale (JS modeli) i modeli za naizmenične signale (NS modeli) [Li00].

JS modeli se koriste kada su promene signala spore u poređenju sa vremenskim konstantama kola, pa su ovakvi modeli čisto otporni, tj. nije potrebno u njih ugrađivati reaktivne elemente. Kako frekvencija signala raste, tako vremenske konstante kola postaju uporedive sa brzinom rada kola, pa dolaze do izražaja i reaktivna svojstva komponente. Tada se koriste NS modeli koji se najlakše dobijaju tako što se JS modelima dodaju kapacitivnosti koje pokazuju nagomilavanje nanelektrisanja u komponenti.

NS modeli se vrlo često i dalje dele, i to na modele za niske, srednje i visoke frekvencije. Tako se za model za visoke frekvencije uzimaju u obzir i parazitni efekti. Treba samo imati u vidu da je pojam visokih frekvencija relativan, tj. određena frekvencija može za jedan tip komponente da bude veoma visoka, a za drugi niska.

1.1.3 Hijerarhija modela

Veza između različitih tipova modela prikazana je na Sl. 1.1 [Ch75]. Najpre posmatramo deterministički nivo. Strelice ukazuju na smer transformacije od višeg ka nižem hijerarhijskom nivou, odnosno na to koji model može biti ekstrahovan iz prethodnog. Na vrhu hijerarhije nalazi se globalni model za naizmenične signale, koji je najpotpuniji i najopštiji. Njegovim uprošćavanjem mogu se izvesti svi ostali tipovi modela. Model koji sadrži najmanje informacija- JS model za male signale, je na najnižem nivou.



Sl. 1.1 Hjерархија модела

Model компоненте може да обухвата и њена статистичка својства. Наиме, ако се физички параметри посматрају као статистичке променљиве, и параметри модела постaju slučajne величине, и одзив кола постаје slučajna величина [Mi91]. Када се компоненти укину њена статистичка својства, она поново добија своју детерминистичку верзију. На Sl. 1.1 статистички модели приказани су у једној равни, а детерминистички у другој, што значи да сваки тип раније представљених модела има партнера у другој равни.

1.2 Struktura modela

Свака компонента састоји се од унутрашњег, спољашnjег и паразитног модела, тј. има структуру гнезда, приказану на Sl. 1.2 [Li00].



Sl. 1.2 Тополошка структура модела компоненте

У унутрашњем делу компоненте дешавају се основне појаве које карактеришу ту компоненту. Спољашњи део обавља пренос сигнала од унутрашњег дела ка спојним

priklučcima. Parazitni efekti u potpunosti opisuju ponašanje komponente i njenu spregu sa susednim komponentama. To mogu da budu induktivnosti uvodnika, kapacitivnosti prema kućištu, i sl. Svaki sloj uvodi nove elemente što modelovanje čini komplikovanijim, jer prisustvo spoljnih prstenova udaljava funkcionalni deo komponente od priključaka. Unutrašnji deo modela obično je iskazan kao nelinearni kontrolisani strujni generator opisan komplikovanim matematičkim izrazom ili algoritmom, a ostatak modela se iskazuje kao mreža sa poznatim tipovima elemenata. Međutim, parazitni efekti nisu od važnosti u najvećem broju primena, pa mogu da se zanemare.

1.3 Generisanje modela

Model elektronske komponente treba da bude takav da olakšava projektovanje kola [Sp67], tačan da bi analiza bila verodostojna. Takođe, treba da postoji jednoznačna korespondencija između parametara modela i veličina koje predstavljaju merljive fizičke veličine: dimenzije, koncentracije i sl. Model treba da omogući lakšu ekstrakciju parametara i lakšu povratnu spregu od analize kola ka zahtevima vezanim za procesiranje komponenata, a elementi kola koji se ugrađuju u taj model treba da budu linearni i frekvencijski i vremenski nezavisni ukoliko je to moguće. Kao celina, model treba da dozvoljava dodavanje specifičnih efekata uvek kada je to moguće.

Postoje dva osnovna pristupa modelovanju elektronskih komponenti: fizički pristup i pristup "crne kutije". Ukoliko su poznati fizički zakoni na osnovu kojih jedna komponenta funkcioniše, moguće je definisati skup jednačina koji opisuje datu komponentu. Na taj način može se opisati strujno-naponska karakteristika koja definiše fizički model komponente. Osnovna prednost ovog pristupa je fizičko značenje koje se pridružuje parametrima datim u jednačinama modela. Međutim, postoji mnogo problema koji se javljaju pri realizaciji ovog modela [Ch75]. Prvo, veoma retko je poznata fizika komponente do takvih detalja da bi bilo moguće odrediti dominantnost i međusobnu vezu između fizičkih i tehnoloških parametara. Takvih parametara ima mnogo, pa bi uvođenje svih parametara u model dovelo do veoma složenog modela [Ch96]. Zatim, jednom jednačinom nije moguće opisati ponašanje komponente u svim režimima rada [Fo98]. Različite fizičke pojave dolaze do izražaja u različitim područjima rada komponente, tako da jednačine koje opisuju modele postaju nekompatibilne. Te jednačine mogu biti eksponencijalne, algebarske i algebarske sa racionalnim stepenima, i trebalo bi da, kada se sastave, formiraju analitičku funkciju. To nije uvek moguće ako se razmatra samo fizika komponente, jer je na granicama područja rada teško ustanoviti međusobnu dominantnost pojedinih pojava. Ovo postaje naročit problem kod komponenata kod kojih nemamo jasnu predstavu o mehanizmima koji upravljaju strujno-naponskom karakteristikom. U tim slučajevima koriste se neki drugi pristupi.

Drugi pristup modelovanju, pristup "crne kutije", koristi se kada nam nisu u potpunosti poznate fizičke pojave koje uslovjavaju ponašanje date komponente. Informacija o komponenti dobija se tada merenjem ulaznih i izlaznih veličina komponente koja se posmatra kao crna kutija, i na osnovu merenih podataka moguće je ustanoviti njenu strujno-naponsku karakteristiku. Komponenta je u tom slučaju opisana izrazom, tj. funkcijom dobijenom aproksimacijom merenih podataka. Ova se funkcija sintetizuje na više načina. Modelovanje pretraživanjem tabela koristi se tako što se skup merenih vrednosti zapamti, pa se vrednosti struje i izvoda u međuintervalima interpoliraju nekim interpolacionim postupkom [Sh99]. Kod segmentno-linearne aproksimacije koriste se što je moguće duži linearni segmenti kako bi se smanjila složenost komponente [Ch75], [Ka65]. Generisanje analitičkih funkcija, međutim, ostaje trajan problem pri primeni ovog koncepta.

Glavna prednost pristupa "crna kutija" je u tome što ne mora da se poseduje veliko znanje o fizici komponente koja se modeluje. Model može da se iskaže u onom obliku u kome je potreban pri formulaciji jednačina, a u nekim situacijama može da bude upotrebljen za objašnjenje načina rada komponente ili sistema koji se modeluje. Naime, odziv električnog kola koje se koristi kao model treba dovoljno dobro da aproksimira predviđeni odziv. U tom slučaju bi model mogao da se koristi i za objašnjenje načina rada komponente. Primena ovog koncepta je pogodna naročito kod modelovanja složenih bioloških, električnih, hemijskih i drugih interakcija koje se dešavaju u živom tkivu [Ko89].

Problem koji se javlja kod pristupa "crna kutija" vezan je za nelinearnost reaktivnih komponenata kod kojih se, u nekim slučajevima, javljaju nereverzibilne putanje odziva. Tako model dobijen metodom "crna kutija" može da bude ograničen samo na jedan skup signala. Još jedan problem vezan je za parametrizaciju karakteristika komponente. Promena samo jednog parametra u procesu projektovanja menja karakteristike komponente, što zahteva ponovna merenja i modelovanja, pa je potreban mnogo veliki skup podataka za svaki tip komponente.

Modelovanje pomoću crne kutije može biti zasnovano i na upotrebi veštačkih neuronskih mreža, kada se prostor kontrolišućih veličina (najčešće potencijala priključaka) preslikava u prostor kontrolisanih veličina (najčešće struja komponente). Veštačka neuronska mreža (VNM) je paralelna, distribuirana struktura za obradu podataka sa specifičnom topologijom koja sadrži algoritam za određivanje koeficijenata u operatorima.

Posle objavljivanja prvih rezultata u [Li92], veštačke neuronske mreže bile su više puta upotrebljene za modelovanje u elektronici. U literaturi su dati primeri modelovanja mikrotalasnih komponenti, mikrostrip veza, međuslojnih prelaza, spiralnih integrisanih kalemova, a najobimniji pregled ovih rezultata dat je u [Wa97]. Pri tome, modelovana su otporna svojstva komponenata. Prvi pokušaj primene VNM za modelovanje nelinearnih reaktivnih dvopola opisan je u [Li97]. Primena koncepta crne kutije pa time i VNM od posebnog je interesa za modelovanje senzora i aktuatora iz više razloga. Obično je situacija takva da nisu do detalja spoznati fizički fenomeni koji stoje u osnovi rada ovakvih dvopola, a u isto vreme, brzina izlaska na tržište je imperativ za opstanak komponente. Zato se zahteva metod modelovanja koji će biti primenjen odmah na bazi onih znanja koja su raspoloživa. Treba imati na umu još i da pri simulaciji integrisanih elektronskih sistema pre nego što se pristupi fizičkom projektovanju, dakle, pri verifikaciji sintetizovanog rešenja, potrebno je simulaciju analognih i kola sa mešovitim signalima obaviti na funkcionalnom nivou. Upravo je metod crne kutije taj koji je najpogodniji za modelovanje na ovom nivou, a VNM koncept koji otvara mogućnost za generisanje modela na efikasan način.

Zaključuje se da treba koristiti fizički pristup koliko god je to moguće, a modelu se kasnije dodaju delovi koji nastaju modelovanjem pristupom "crna kutija". Mešavina ova dva koncepta nastaje i kada se koristi više modela pojedinih poznatih komponenata pri modelovanju nove komponente čije ponašanje nije sasvim objasnjivo.

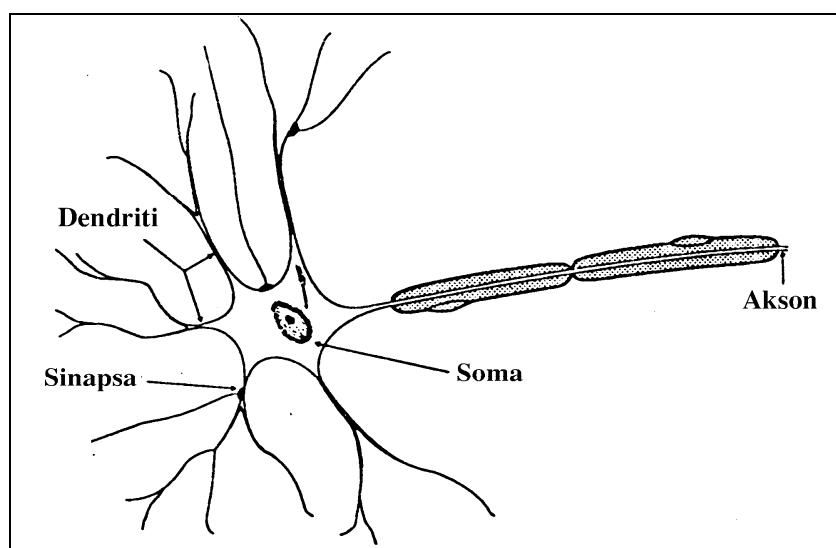
2 Neuronske mreže

Izgled tipičnog neurona u uprošćenom obliku prikazan je na Sl. 2.1. Nervna ćelija je sastavljena od some, ili tela neurona, dendrita i aksona. Električno gledano jedan neuron prima signale od drugih neurona, obrađuje svoj ulazni signal i generiše izlazni koji se dalje vodi na ulaze drugih neurona, ili na efektore organa kao što su, na primer, mišići.

Dendriti su tanki izdanci some koji služe za prihvatanje signala iz drugih neurona. Ovu funkciju obavlja i soma, ali je oko 90% veza izvedeno preko dendrita. Svoju aktivnost neuron dalje prenosi preko aksona. Akson se pri svom kraju grana tako da se izlaz vodi na dendrite (ili direktno na some) više drugih neurona. Spojevi između neurona nazivaju se sinapsama i igraju ključnu ulogu u funkcionisanju celog sistema.

U normalnom, nepobuđenom stanju, potencijal some iznosi tipično oko -70mV . U tom slučaju ne postoji nikakva izlazna aktivnost.

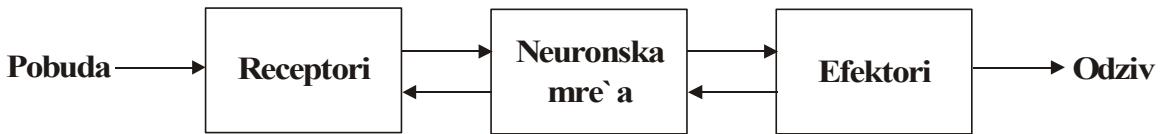
Dovođenje signala na neku od sinapsi izaziva fizičko-hemijski proces koji menja potencijal tela neurona. Zavisno od toga da li je sinapsa ekscitatorna ili inhibitorna, potencijal tela ćelije se povećava ili smanjuje, respektivno. Kada se prekorači aktivacioni potencijal dolazi do izlazne aktivnosti neurona koja rezultuje polarizacijom početnog dela aksona. Ta polarizacija se nadalje prostire do drugih neurona. Zavisno od veličine prekoračenja praga, na izlazu se generiše signal različite frekvencije što znači da neuron funkcioniše slično oscilatoru koji je kontrolisan naponom. Tipičan izlazni signal neurona je amplitudu 100mV , a brzina prenosa duž aksona je 120m/s bez slabljenja.



Sl. 2.1 Struktura tipičnog neurona

Aktiviranje jedne sinapse obično nije dovoljno da bi se neuron pobudio. Međutim, uzastopno aktiviranje jedne sinapse u kratkom vremenskom intervalu ili simultano aktiviranje više sinapsi može dovesti do izlazne aktivnosti neurona. Ovo znači da soma integriše ulazni signal i sabira signale sa više ulaza. Takođe treba napomenuti da aktivacioni signal iste amplitude koji prolazi kroz različite sinapse različito utiče na ukupni potencijal some. Signali sa sinapsi koje se nalaze na dendritima teže aktiviraju neuron nego signali sinapsi na somi. Osim ovoga, prolaz signala kroz sinapsu menja fizička svojstva spoja dva neurona tako da se u narednoj aktivaciji sinapsa i električno ponaša različito.

Procenjeno je da u kori velikog mozga čoveka ima oko 10 milijardi neurona, i 60 triliona sinapsi. Nervni sistem čoveka može se predstaviti kao trostopeni sistem [Ha94], kao što je prikazano na Sl. 2.2.



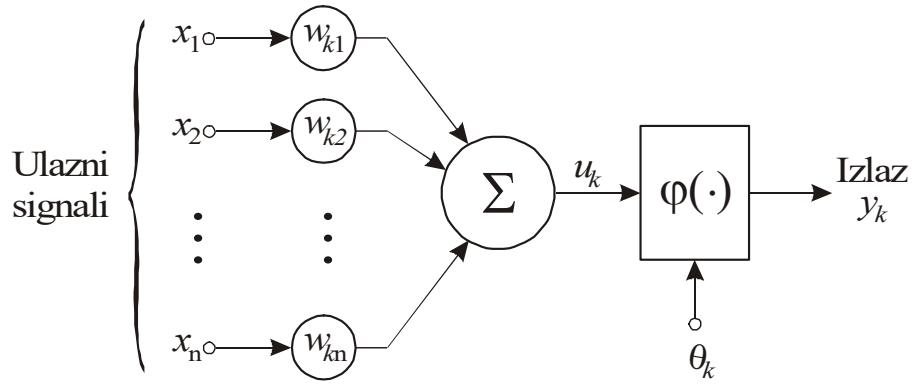
Sl. 2.2 Nervni sistem predstavljen kao trostopeni sistem

U centru sistema je mozak, na Sl. 2.2 predstavljen neuronskom mrežom, koji neprestano prima informacije, prihvata ih, i donosi odgovarajuće odluke. Strelice ulevo predstavljaju prenos podataka unapred kroz sistem. Strelice udesno pokazuju povratnu spregu u sistemu. Receptori konvertuju pobudu iz ljudskog tela ili okoline u električne impulse koje prenose do mozga. Efektori konvertuju električne impulse koje generiše neuronska mreža, i pretvaraju ih u odziv sistema. Zapaža se da je struktura organizacija mozga jedinstvena, i različita od one u računaru. Veštačke neuronske mreže su nastale kao pokušaj modelovanja neurona u mozgu. One su, naravno, mnogo jednostavnije strukture od pravih neurona. Kako mi sagledavamo neurone kao električne modele, dat je kratak pregled modela veštačkih neurona.

2.1 Modeli neurona

2.1.1 Statički modeli

Uopštена blok šema statičkog modela neurona prikazana je na Sl. 2.3. Može se uočiti analogija sa modelom prirodnog neurona (Sl. 2.1). Sinapse iz prirodnog modela ovde su predstavljene sinaptičkim težinama. Zapravo, signal x_j na ulazu sinapse j koji je povezan sa nevronom k množi se težinom w_{kj} . Težina w_{kj} je pozitivna ako je sinapsa ekscitatorna, a negativna ukoliko je sinapsa inhibitorna. Sabirač na Sl. 2.3 modeluje osobinu some da sabira signale sa više ulaza, a funkcija $\phi(\cdot)$ je nelinearna, aktivaciona funkcija neurona. Napon praga, θ_k , predstavlja napon koji utiče na mrežu spolja, i tako menja izlazni napon za određeni nivo.



Sl. 2.3 Nelinearni model neurona

Na ulaz neurona dovodi se n signala, $x = (x_1 \ x_2 \ \dots x_n)$, a y_k je izlazni signal. Neuron k može se opisati parom jednačina (2.1) i (2.2):

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (2.1)$$

$$y_k = \varphi(u_k - \theta_k) \quad (2.2)$$

U literaturi je u upotrebi više tipova aktivacionih funkcija.

Najjednostvanija je linearna aktivaciona funkcija:

$$\varphi(u) = u - \theta \quad (2.3)$$

Imajući u vidu da je prenosna karakteristika prirodnog neurona nelinearna, linearna aktivaciona funkcija u modelu je loša imitacija prirodnog stanja. Primena neurona sa ovakvom aktivacionom funkcijom je mala, a sreće se uglavnom u mrežama koje sadrže i neurone sa nelinearnim aktivacionim funkcijama.

Jedna od češće korišćenih nelinearnih aktivacionih funkcija jeste odskočna funkcija koja se sreće u dva oblika:

$$\varphi(u) = \begin{cases} 1 & \text{ako je } u \geq \theta \\ -1 & \text{ako je } u < \theta \end{cases} \quad (2.4)$$

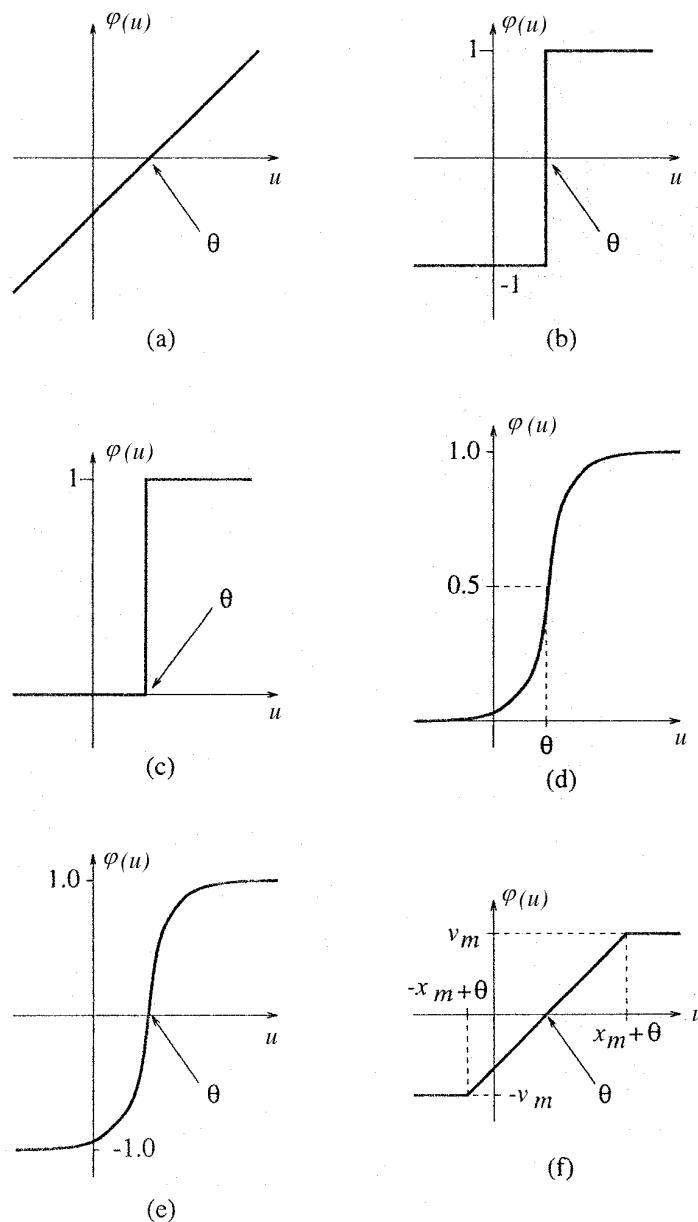
Klasu sigmoidnih aktivacionih funkcija čine logistička funkcija (2.5) i funkcija tangens hiperbolički (2.6):

$$\varphi(u) = \frac{1}{1 + e^{-(u-\theta)}} \quad (2.5)$$

$$\varphi(u) = \frac{e^{(u-\theta)} - e^{-(u-\theta)}}{e^{(u-\theta)} + e^{-(u-\theta)}} \quad (2.6)$$

U nekim primenama sreće se još i upotreba takozvane linearne odsečene aktivacione funkcije:

$$\varphi(u) = \frac{v_m}{2u_m} (|u + u_m - \theta| - |u - u_m - \theta|) \quad (2.7)$$

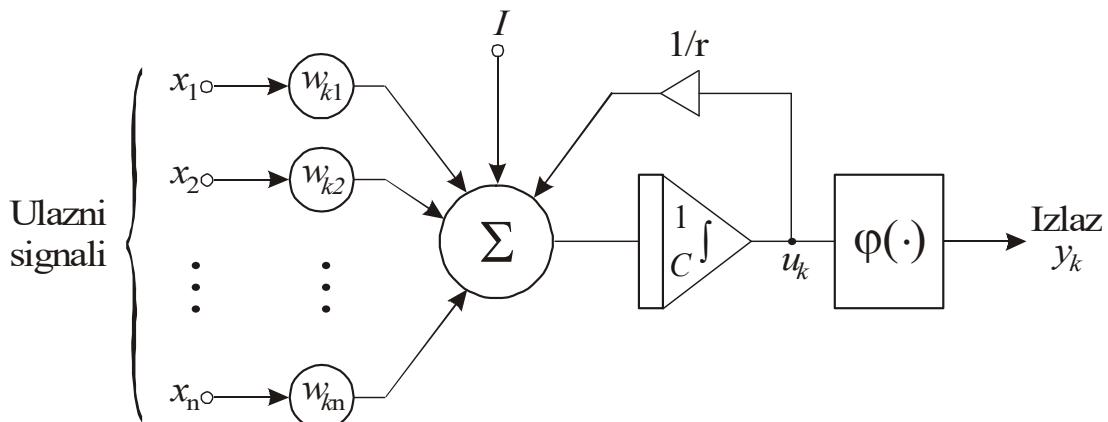


Sl. 2.4 Aktivacione funkcije: (a) linearna, (b), (c) odskočna, (d) logistička, (e) tangens hiperbolički, (f) linearna odsečena

Grafički prikaz aktivacionih funkcija dat je na Sl. 2.4. U svim aktivacionim funkcijama θ je ona vrednost za u čije prekoračenje dovodi do promene stanja neurona. Drugim rečima, θ predstavlja prag i ima sličnu ulogu kao i aktivacioni prag prirodnog neurona.

2.1.2 Dinamički modeli

Biološki neuron može da se aktivira tek kada ga pobudi više različitih ulaznih signala koje on sumira i integrali. Ovo svojstvo doprinelo je razvoju dinamičkih modela neurona. Isto tako, postoji i potreba da se veštačkim neuronskim mrežama obrađuju i vremenski promenljivi signali. Primenom izvesnih trikova upotreba statičkih modela u ovakvim slučajevima je moguća, ali neprirodna.



Sl. 2.5 Dinamički model neurona

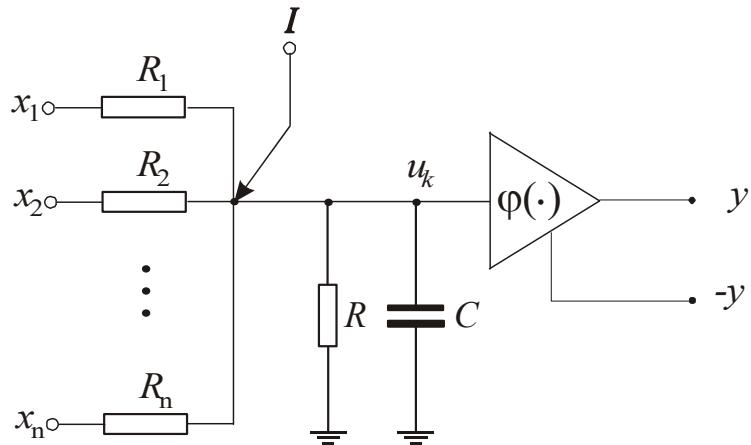
Zato se uvode dinamički modeli koji razmatraju signale u vremenskom domenu. Sl. 2.5 prikazuje najpoznatiji, aditivni dinamički model neurona. U ovom slučaju aktivacioni signal u_k se dobija tako što se najpre sumiraju ulazni signali x_j , eksterni ulaz I i sam aktivacioni signal. Model sa Sl. 2.5 opisan je jednačinama (2.8) i (2.9):

$$C \frac{du_k}{dt} + \frac{u_k}{r} = \sum_{j=1}^n w_{kj} x_j + I \quad (2.8)$$

$$y_k = \varphi(u_k) \quad (2.9)$$

Zbog efekta integracije aktivacioni signal će postojati još izvesno vreme nakon prestanka delovanja ulaznih signala. To znači da dinamički model neurona poseduje mogućnost pamćenja kraće predistorije zbivanja na ulazima. Zbog toga se signal u_k naziva još i kratkotrajnom memorijom. Dugotrajnu memoriju, naravno, predstavljaju težine veza. S obzirom da se u prirodnom nervnom sistemu i dugotrajne memorije, to jest sinapse, menjaju sa vremenom, postoje pristupi gde se u modelu uzima u obzir i vremenska promenljivost težina veza.

Na Sl. 2.6. prikazana je Hopfield-ova realizacija dinamičkog modela neurona. Model je sastavljen od elektronskih komponenata tako što su mrežom otpornika R_i , $i = 1, 2, \dots, n$ realizovane težine veza; strujni izvor I predstavlja eksterni ulaz, dok je aktivaciona funkcija realizovana izlaznim pojačavačem i obično je sigmoidnog oblika.



Sl. 2.6 Hopfieldov model neurona

Pojačavač je sa komplementarnim izlazom što omogućava realizaciju i negativnih težina. R i C predstavljaju ulaznu otpornost i kapacitivnost izlaznog pojačavača. Ako sa u_k označimo potencijal čvora na ulazu pojačavača, onda za ovo kolo važe jednačine (2.10) i (2.11):

$$C \frac{du_k}{dt} + \frac{u_k}{r} = \sum_{j=1}^n \frac{x_{jk}}{R_j} + I \quad (2.10)$$

$$y_k = \varphi(u_k) \quad (2.11)$$

gde je sa r označena ekvivalentna otpornost (2.12):

$$\frac{1}{r} = \frac{1}{R} + \sum_{j=1}^n \frac{1}{R_j}. \quad (2.12)$$

U svim opisanim modelima prisutno je izvesno odstupanje od prirodnog neurona. Kako je već napomenuto kod statičkih modela, za razliku od prirodnih neurona, ne postoji efekat integracije ulaznih signala. Predložene polinomske funkcije interakcije ulaza nisu prisutne u prirodnom neuronu. Takođe, oblik aktivacionih funkcija u modelu u mnogome odstupa od oblika prenosne funkcije prirodnog neurona. Stanje neurona u većini modela nije kodovano frekvencijom izlaznog signala. Međutim, cilj razvoja veštačkih neuronskih mreža nije verna simulacija rada nervnog sistema, već upotreba osnovnih principa njegovog funkcionisanja s ciljem generisanja alata za rešavanje raznih problema gde klasični metodi ne daju zadovoljavajuće rezultate. To znači da odstupanje od verne imitacije rada prirodnog nervnog sistema ne umanjuje kvalitet celog pristupa.

2.2 Arhitekture neuronskih mreža

Veštačka neuronska mreža se formira od više neurona, tako što se izlazi jednih neurona vezuju na ulaze drugih. Neuroni koji prihvataju informacije iz spoljašnje sredine nazivaju se ulazni neuroni, a oni koji takođe imaju dodira sa okolinom, ali generišu signale

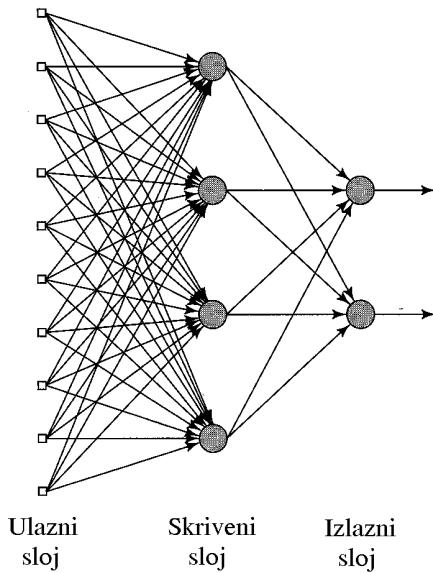
za određene akcije su izlazni. Neuroni koji nisu direktno vezani za okruženje, već su samo povezani sa ulaznim i izlaznim neuronima su skriveni, i oni služe za internu prezentaciju informacija o okruženju.

Veštačke neuronske mreže poseduju izvesnu uređenost u svojoj topologiji, zato što struktura mreže diktira i proceduru za učenje i konkretnu primenu mreže. Najpoznatija arhitektura mreža je slojovita struktura, gde su neuroni organizovani tako da formiraju slojeve. Na ulaz jednog neurona dovode se izlazi svih neurona iz prethodnog sloja, a njegov izlaz se vodi na ulaze svih neurona u narednom sloju. Mogu se uočiti dve klase neuronskih mreža: mreža bez povratnih veza, ili nerekurentna mreža, i mreža sa povratnim vezama, tj. rekurentna mreža.

2.2.1 Nerekurentne neuronske mreže

Nerekurentne neuronske mreže imaju jedan ili više skrivenih slojeva koji se nalaze između ulaznog i izlaznog sloja neurona.

Nerekurentna neuronska mreža sa Sl. 2.7 je potpuno povezana, što znači da je svaki neuron u svakom sloju mreže povezan sa svakim neuronom u susednom narednom sloju.



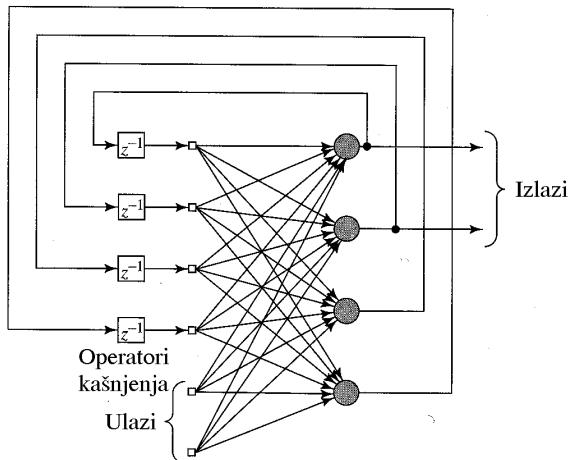
Sl. 2.7 Potpuno povezana nerekurentna mreža

Ukoliko svaki neuron nije povezan sa svakim neuronom iz narednog sloja, mreža je delimično povezana. Oblik delimično povezane mreže je lokalno povezana mreža, kod koje je svaki neuron u skrivenom sloju povezan samo sa određenim neuronima iz ulaznog sloja iz neposrednog susedstva. Slično, svaki neuron u izlaznom sloju je povezan samo sa lokalnim skupom skrivenih neurona. Ovakve mreže specijalizovane su za tačno određenu funkciju za koju se i generiše njihova struktura.

2.2.2 Rekurentne neuronske mreže

Rekurentne neuronske mreže se razlikuju od nerekurentnih jer imaju bar jednu povratnu petlju.

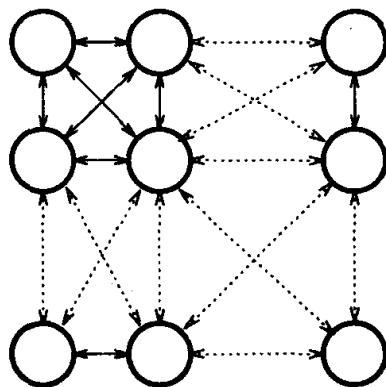
Najpoznatiji predstavnik klase rekurentnih mreža jeste potpuno povezana rekurentna mreža, a njena topologija prikazana je na Sl. 2.8. Ovde se izlaz jednog neurona vodi na ulaze svih, pa i na ulaz tog neurona.



Sl. 2.8 Potpuno povezana rekurentna mreža

Na Sl. 2.9 prikazana je dvodimenzionalna čelijska mreža. Dimenzija susedstva je u ovom slučaju jedan, što znači da se susedima jedne ćelije smatraju samo njoj najbliže. Veze su dvosmerne tako da izlaz jedne utiče na ulaz druge ćelije i obrnuto. Mreža ima eksternih ulaza koliko i ćelija, s tim što se jedan ulaz takođe vodi na više susednih ćelija, a ne samo na jednu kao u prethodnim slučajevima. Izlazi mreže su izlazi svih ćelija.

Ukoliko se neuronska mreža sastoji iz više slojeva, moguće je više različitih vrsta povratne sprege [Ts94]. Signal koji predstavlja povratnu spregu, odnosno još jedan ulaz u mrežu, može biti signal pre nelinearnosti (signal u_k sa Sl. 2.3) ili signal koji je prošao nelinearnost (signal y_k sa Sl. 2.3). Takođe, i svaka sinapsa može učestvovati u povratnoj spregi, tj. može se posmatrati kao posebna aktivaciona struktura.



Sl. 2.9 Čelijska neuronska mreža

Ako bismo poredili veštačke neuronske mreže sa nervnim sistemom, može se reći da su, po svojoj strukturi, rekurentne mreže bliže prirodnim. Povratne veze u nervnom sistemu su pravilo, a ne slučajnost. Zbog povratnih veza rekurentne mreže imaju bogatiju dinamiku i veće procesne mogućnosti. Međutim, slojevite mreže daju sasvim zadovoljavajuće rezultate pri rešavanju široke klase problema. Procedure za njihovo učenje, osim što su jednostavnije, brže su, a to važi i za odziv. Kod rekurentnih mreža se posebna pažnja mora posvetiti obezbeđivanju uslova stabilnosti s obzirom da je moguća pojava oscilacija zbog postojanja povratnih veza. Slojevite mreže su stabilne po definiciji. Zbog toga se rekurentne mreže primenjuju samo u onim slučajevima kada je sposobnost slojevitih mreža nedovoljna.

2.3 Učenje veštačkih neuronskih mreža

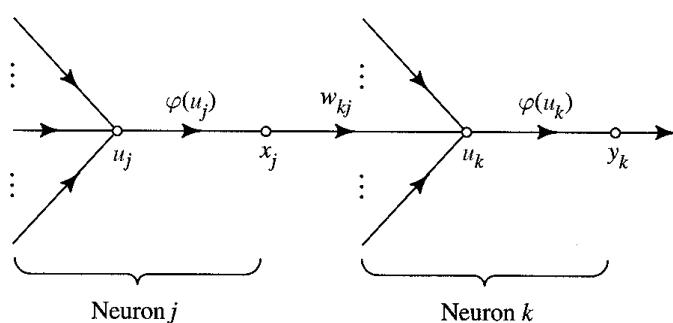
Najzanimljivije svojstvo neuronskih mreža je njihova sposobnost učenja. Mreža uči na osnovu informacija iz okruženja iterativnim postupkom, menjajući svoje težine i pravove u svakoj iteraciji, tako da, teorijski, ima više “znanja” nakon svake iteracije.

U literaturi je prikazan zanimljiv pristup aproksimacije kontinualne funkcije jedne promenljive gde se težine veza troslojne mreže generišu bez procesa učenja na osnovu izvedenih formula [Ch92a]. Kako se ovaj rad odnosi na mreže koje se obučavaju, biće opisani principi na kojima se učenje zasniva, kao i algoritmi učenja.

Razmotrimo signale x_j i u_k povezane sinaptičkom težinom w_{kj} , (Sl. 2.10), gde je x_j izlaz neurona j , a u_k unutrašnji signal neurona k . Signali x_j i u_k predstavljaju predsinaptičku i postsinaptičku aktivnost, respektivno. Ako sa $w_{kj}(n)$ označimo vrednost sinaptičke težine w_{kj} u trenutku n , ovoj vrednosti se dodaje korekcija u trenutku n , Δw_{kj} , da bi se dobila vrednost težine za trenutak $n+1$, $w_{kj}(n+1)$:

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (2.13)$$

Vrednosti $w_{kj}(n)$ i $w_{kj}(n+1)$ se mogu posmatrati kao stara i nova vrednost sinaptičke težine w_{kj} , respektivno. Zapravo, $\Delta w_{kj}(n)$ se računa na osnovu pobude neurona iz spoljašnjeg okruženja. Zbog te pobude, parametri mreže se menjaju, pa tako nastaje nova vrednost težine, $w_{kj}(n+1)$. Sada neuronska mreža daje drugačiji odziv.

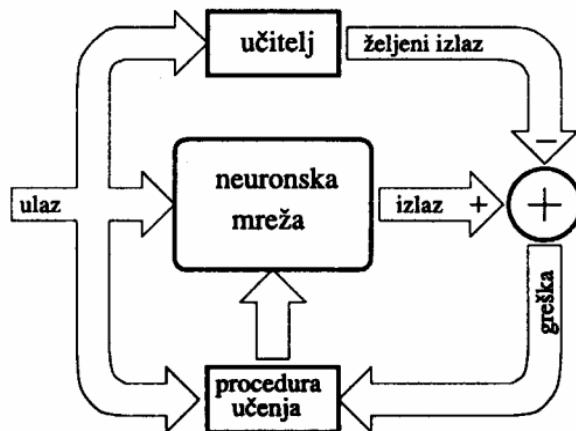


Sl. 2.10 Par neurona j i k iz neuronske mreže

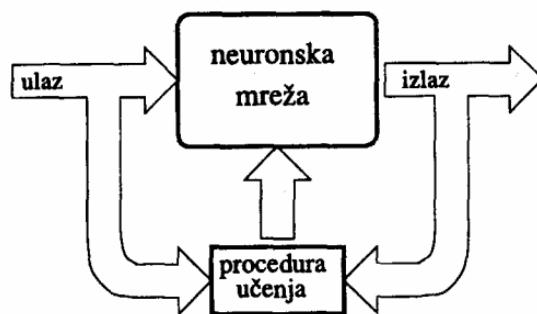
Postavlja se pitanje na koji način neuronska mreža može menjati svoje ponašanje kao odgovor na delovanje sredine. Njeno ponašanje pre svega zavisi od ukupnog broja neurona koji je čine i od njihove međusobne povezanosti ili, kraće rečeno, od arhitekture mreže. Dalje, ponašanje mreže zavisi i od težina veza između neurona. Modeli, to jest funkcije interakcije i aktivacione funkcije upotrebljenih neurona takođe imaju svoj uticaj na ponašanje neuronske mreže.

Kada je mreža konstruisana i realizovana, naknadne promene u arhitekturi i izmene modela neurona su teško izvodljive. Najfleksibilniji način promene ponašanja je promena težina veza, tako da na delovanje sredine neuronska mreža reaguje promenom svojih sinapsi. Ista je situacija i u prirodnom nervnom sistemu. Pravila za te promene nazivaju se procedurama za učenje i predstavljaju značajan faktor pri projektovanju neuronskih mreža.

Pre svega, učenje neuronskih mreža može biti nadgledano (supervised) ili nenadgledano (unsupervised). Ova dva načina su ilustrovana na Sl. 2.11 i Sl. 2.12, respektivno. Na osnovu prethodnih izlaganja može se zaključiti da neuronska mreža radi kao procesor signala. Na ulaz mreže se dovode signali iz radne okoline, a ona na takvu pobudu na svojim izlazima generiše signale koji se vraćaju u sredinu. Od naučene mreže se očekuje da na određenu pobudu reaguje ispravno.



Sl. 2.11 Nadgledano učenje



Sl. 2.12 Nenadgledano učenje

U postupku nadgledanog učenja mreži se prezentuju pobuda i korektan, to jest željeni odziv koji se od nje očekuje. Za određivanje željenog, to jest tačnog odziva zadužen je učitelj ili supervizor. Stvarni odziv mreže se upoređuje sa željenim, a mera odstupanja jednog od drugog se vraća proceduri za učenje. Na osnovu ove greške procedura učenja vrši promenu parametara mreže, težeći da minimizira razliku ova dva odziva.

Kod nenadgledanog učenja ne postoji supervizor, pa time ni željeni odziv mreže. Od mreže i procedure učenja se očekuje da same uoče pravilnosti u ulaznim podacima i da definišu korektan odziv. Procedura učenja vrši promenu težina samo na osnovu poznavanja trenutnog ulaza i izlaza mreže.

2.3.1 Backpropagation algoritam za učenje neuronskih mreža

Za nadgledano učenje neuronskih mreža postoji mnogo algoritama, a većina njih koristi metodologiju promene težina. Vektoru nepoznatih težina najpre se dodeljuju inicijalne vrednosti, slučajno izabrane, koje obično imaju vrednost oko nule. Zatim se na ulaz mreže sekvensijalno dovode uzorci iz trening skupa, a istovremeno se odvija proces korekcije težina koji se obično svodi na gradijentni spust niz površ, koja je u prostoru težina definisana funkcijom greške. Funkcija greške predstavlja neku meru razlike željenog i stvarnog odziva neuronske mreže.

Kod učenja višeslojnih mrež prisutan je jedan problem koji u istraživačkoj istoriji ove oblasti dugo nije bio rešen. Većina algoritama modifikuje težine veza na osnovu poređenja stvarnog i željenog odziva neurona, a željeni odziv neurona u skrivenom sloju, to jest željena interna reprezentacija ulaznih uzoraka nije poznata. Rešenje problema dali su Rumelhart, Hinton i Williams 1986. godine razvojem procedure za učenje višeslojnih neuronskih mreža koja je poznata pod imenom backpropagation [Ru86]. Istih godina je ova procedura otkrivena nezavisno i od strane drugih istraživača, a kasnije se uvidelo da je slična procedura opisana u Werbos-ovoj doktorskoj disertaciji još 1974. godine [An89]. Ipak, najveći uticaj na razvoj naučne misli u ovoj oblasti imali su radovi Rumelhart-a, Hinton-a i Williams-a, pa će ovde biti opisana njihova verzija backpropagation algoritma.

Backpropagation algoritam predstavlja generalizaciju Widrow-Hoff-ovog delta pravila, pa se često naziva i generalizovano delta pravilo. Backpropagation koristi nelinearni signal neurona, odnosno neurone sa nelinearnom aktivacionom funkcijom, a modifikacija težina veza skrivenih neurona se obavlja na osnovu signala greške izlaznih neurona.

Da bismo detaljnije pojasnili rad backpropagation algoritma, uvećemo prvo neke oznake. Slojevita neuronska mreža prikazana je na Sl. 2.13.

Neka je n broj ulaza mreže a n' broj izlaza. Takva mreža će biti obučavana na trening skupu $P = (p_1, p_2, \dots, p_{N_p})$. U ovom slučaju, svaki trening uzorak p_k iz P je definisan vektorom ulaznih $i_k = (i_{1k}, i_{2k}, \dots, i_{nk})^T$ i vektorom željenih izlaznih signala $t_k = (t_{1k}, t_{2k}, \dots, t_{n'k})^T$, tj. $p_k = (i_k, t_k)$. Neka je još:

N_l - broj slojeva u mreži,

N_l - broj neurona u l -tom sloju,

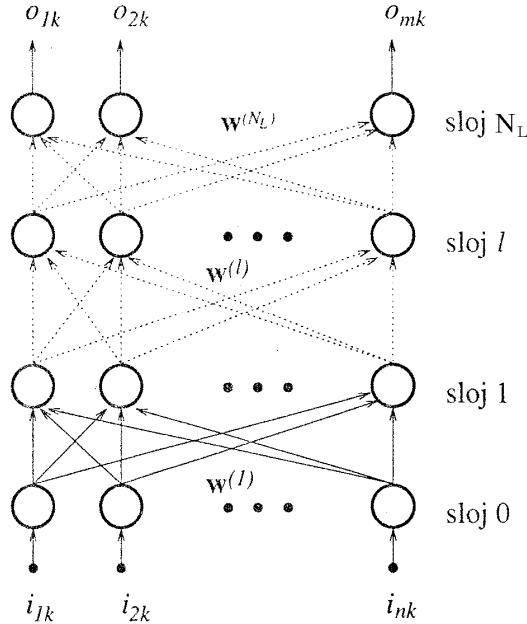
$\square_i^{(l)}$ - i -ti neuron u sloju l ,

$w_{ij}^{(l)}$ - težina veze koja povezuje izlaz neurona $\square_i^{(l-1)}$ sa i -tim ulazom neurona $\square_j^{(l)}$,

$v_{ik}^{(l)}$ - izlaz neurona $\square_i^{(l)}$ kada i_k pobuđuje mrežu,

$x_{ik}^{(l)}$ - aktivacioni signal neurona $\square_i^{(l)}$ kada je i_k na ulazu mreže,

$u_{ijk}^{(l)}$ - signal na i -tom ulazu neurona $\square_j^{(l)}$ kada je mreža pobuđena sa i_k ,
 $g_i^{(l)}(x)$ - aktivaciona funkcija neurona $\square_i^{(l)}$ i
 $o_k = (o_{1k}, o_{2k}, \dots, o_{nk})^T$ odziv mreže na pobudu i_k .



Sl. 2.13 Backpropagation mreža

Na osnovu definicije strukture višeslojnih mrež mogu se uočiti neke relacije između uvedenih veličina. Izlaz mreže predstavljaju izlazni signali neurona u zadnjem sloju N_L , pa je $o_{ik} = v_{ik}^{(N_L)}$. Na i -ti ulaz neurona $\square_j^{(l)}$ dovodi se izlazni signal neurona $\square_i^{(l-1)}$, tako da je $u_{ijk}^{(l)} = v_{ik}^{(l-1)}$. Neuron $\square_i^{(l)}$ u ulaznom sloju se pobuđuje ulaznim signalom i_{ik} , pa je $v_{ik}^{(l)} = i_{ik}$. Iz ovoga se može zaključiti da se neuroni u prvom sloju pobuđuju direktno signalima sa ulaza mreže, to jest $u_{ijk}^{(l)} = i_{ik}$.

Aktivacioni signal neurona $\square_j^{(l)}$ je:

$$x_{jk}^{(l)} = \sum_{i=0}^{N_{l-1}} w_{ij}^{(l)} u_{ijk}^{(l)} = \sum_{i=0}^{N_{l-1}} w_{ij}^{(l)} v_{ik}^{(l-1)} \quad (2.14)$$

Ovde je prag neurona $\square_j^{(l)}$ predstavljen konstantnim ulazom $u_{0jk}^{(l)} = v_{0k}^{(l-1)} = 1$ i težinom $w_{0j}^{(l)}$. Izlazni signal istog neurona je onda:

$$v_{jk}^{(l)} = g_j^{(l)}(x_{jk}^{(l)}). \quad (2.15)$$

Kada se na ulaz mreže dovede pobuda i_k , odziv mreže će biti o_k , tako da u postupku učenja treba minimizirati razliku ovog i želenog odziva t_k . Funkciju greške ćemo definisati na sledeći način:

$$e_k = \frac{1}{2} \sum_{s=1}^{n'} (o_{sk} - t_{sk})^2 = \frac{1}{2} \sum_{s=1}^{n'} (v_{sk}^{N_L} - t_{sk})^2 \quad (2.16)$$

Da bi se formirao iterativni proces za određivanje težina veza u višeslojnoj neuronskoj mreži, potražimo prvo parcijalne izvode funkcije greške (2.16):

$$\frac{\partial e_k}{\partial w_{ij}^{(l)}} = \frac{\partial e_k}{\partial x_{jk}^{(l)}} \frac{\partial x_{jk}^{(l)}}{\partial w_{ij}^{(l)}} \quad (2.17)$$

Na osnovu (2.14) je:

$$\frac{\partial x_{jk}^{(l)}}{\partial w_{ij}^{(l)}} = v_{ik}^{(l-1)} \quad (2.18)$$

Tako se (2.17) može napisati u obliku:

$$\frac{\partial e_k}{\partial w_{ij}^{(l)}} = \delta_{jk}^{(l)} v_{ik}^{(l-1)} \quad (2.19)$$

gde je:

$$\delta_{jk}^{(l)} = \frac{\partial e_k}{\partial x_{jk}^{(l)}} \quad (2.20)$$

Parcijalni izvodi $\delta_{jk}^{(l)}$ za izlazni sloj, tj. kada je $l=N_L$, određuju se diferenciranjem izraza (2.16) i (2.15):

$$\delta_{jk}^{(N_L)} = (o_{jk} - t_{jk}) g_j^{(N_L)'}(x_{jk}^{(N_L)}) \quad (2.21)$$

$\delta_{jk}^{(l)}$ za skrivene slojeve se određuje na malo kompleksniji način:

$$\delta_{jk}^{(l)} = \frac{\partial e_k}{\partial v_{jk}^{(l)}} \frac{\partial v_{jk}^{(l)}}{\partial x_{jk}^{(l)}} = \frac{\partial e_k}{\partial v_{jk}^{(l)}} g_j^{(l)'}(x_{jk}^{(l)}) = g_j^{(l)'}(x_{jk}^{(l)}) \sum_{s=1}^{N_{l+1}} \frac{\partial e_k}{\partial x_{sk}^{(l+1)}} w_{js}^{(l+1)} \quad (2.22)$$

Imajući u vidu (2.20) i (2.22) parcijalni izvod $\delta_{jk}^{(l)}$ je u stvari jednak:

$$\delta_{jk}^{(l)} = g_j^{(l)'}(x_{jk}^{(l)}) \sum_{s=1}^{N_{l+1}} \delta_{sk}^{(l+1)} w_{js}^{(l+1)} \quad (2.23)$$

Izrazi (2.19), (2.21) i (2.23) omogućavaju da se parcijalni izvodi funkcije greške računaju rekurzivno. Da bi se izračunali izvodi greške po težinama neurona iz sloja l , neophodno je poznavanje stanja izlaza neurona iz prethodnog sloja, kao i parcijalnih izvoda $\delta_{jk}^{(l+1)}$ iz narednog. Zato je backpropagation organizovan u dve faze. U prvoj fazi, na ulaz mreže se dovodi signal i_k nekog od trening uzoraka p_k . Taj signal se prostire do izlaza, to jest sekvensijalno se računaju odzivi neurona počev od onih u nultom sloju. Ova faza je poznata kao faza prostiranja unapred ili forward faza. Nakon ove faze, poznati su odzivi svih neurona u mreži. U sledećoj fazi se vrši modifikacija težina. Prvo se izračunaju parcijalni izvodi greške po težinama neurona, a iste težine se modifikuju po pravilu gradijentnog spusta:

$$w_{ij}^{(l)} = w_{ij}^{(l)} - \eta \frac{\partial e_k}{\partial w_{ij}^{(l)}} \quad (2.24)$$

Ova faza se odvija takođe po slojevima, a iz pomenutih razloga počinje od izlaznog sloja. Dakle, ovde se signal greške prostire od izlaza ka ulazu, pa se ovaj proces naziva fazom prostiranja unazad, odnosno backward fazom. Naravno, faze prostiranja napred i unazad se obavljaju sekvencialno za sve uzorke trening skupa. Ciklus obrade svih uzorka iz trening skupa naziva se epoha.

Izrazi (2.21) i (2.23) pokazuju da backpropagation zahteva diferencijabilne aktivacione funkcije neurona. Taj uslov zadovoljavaju linearna funkcija i sigmoidne funkcije. Osim ovoga, izvod ovih funkcija se računa vrlo lako. Na primer, izvod logističke funkcije:

$$y = g(x) = \frac{1}{1 + e^{-x}} \quad (2.25)$$

je

$$g'(x) = \frac{dg(x)}{dx} = y(1 - y) \quad (2.26)$$

Za tangens hiperbolički:

$$y = g(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.27)$$

izvod glasi:

$$g'(x) = \frac{dg(x)}{dx} = 1 - y^2 \quad (2.28)$$

Na osnovu ovoga, za neurone sa logističkom aktivacionom funkcijom, izrazi (2.21) i (2.23) postaju:

$$\delta_{jk}^{(N_L)} = o_{jk}(1 - o_{jk})(o_{jk} - t_{jk}) \quad (2.29)$$

$$\text{i} \quad \delta_{jk}^{(l)} = v_{jk}^{(l)}(1 - v_{jk}^{(l)}) \sum_{s=1}^{N_{l+1}} \delta_{sk}^{(l+1)} w_{js}^{(l+1)} \quad (2.30)$$

Isti izrazi za neurone sa tangens hiperbolički aktivacionom funkcijom jednaki su:

$$\delta_{jk}^{(N_L)} = (1 - o_{jk}^2)(o_{jk} - t_{jk}) \quad (2.31)$$

$$\text{i} \quad \delta_{jk}^{(l)} = (1 - v_{jk}^{(l)2}) \sum_{s=1}^{N_{l+1}} \delta_{sk}^{(l+1)} w_{js}^{(l+1)} \quad (2.32)$$

2.3.2 Poboljšanja backpropagation algoritma

Kod ovako definisanog backpropagation algoritma modifikacija težina se obavlja nakon prezentacije svakog trening uzorka. Bez obzira na jednostavnost, u algoritmu su prisutna dva problema koji ga u nekim realnim primenama mogu učiniti neupotrebljivim. Pre svega, algoritam koristi metod gradijentnog spusta, optimizacionu tehniku sa stepenom konvergencije jedan, pa je učenje sporo. S obzirom da backpropagation uči višeslojne mreže, gde se bar u jednom sloju nalaze neuroni sa nelinearnim aktivacionim funkcijama,

zavisnost greške odziva mreže je nelinearna funkcija težina. Zato, u opštem slučaju funkcija greške poseduje lokalne minimume tako da konačni ishod učenja zavisi od početnih vrednosti težina. Zbog toga će nadalje biti posvećena pažnja metodima za ubrzanje algoritma i rešavanju problema lokalnih minimuma.

Sami autori algoritma su predložili varijantu backpropagation algoritma sa momentom [Ru86] koja je značajno brža od osnovne verzije. Ako sa $\Delta w_{ij}^{(l)}(t)$ označimo promenu težine $w_{ij}^{(l)}$ u t -toj prezentaciji, na osnovu (2.24) ona iznosi:

$$\Delta w_{ij}^{(l)}(t) = -\eta \frac{\partial e_k}{\partial w_{ij}^{(l)}} \quad (2.33)$$

gde je e_k greška u odzivu mreže za trening uzorak p_k koji je u tom trenutku prezentiran mreži. Jedan od načina da se poveća brzina učenja jeste uvođenje momentnog člana, tako da promena težina u trenutku t zavisi i od promene u prethodnom trenutku:

$$\Delta w_{ij}^{(l)}(t) = -\eta \frac{\partial e_k}{\partial w_{ij}^{(l)}} + \alpha \Delta w_{ij}^{(l)}(t-1) \quad (2.34)$$

Koeficijent α definiše uticaj prethodnih na sadašnju promenu i obično ima vrednost između 0 i 1. Na ovaj način je uvedena izvesna inercija u promeni pravca i brzine spusta niz površ greške u prostoru težina, koja povećava brzinu učenja naročito u slučajevima kada funkcija greške ima široke oblasti sa malim nagibom, što je obično slučaj u okolini minimuma. Osim ovoga, prisustvo inercije obezbeđuje i preskakanje malih lokalnih minimuma, pa je izvršeno filtriranje visoko frekventnih varijacija funkcije greške.

Jedan od interesantnijih načina za ubrzanje učenja jeste primena optimizacionih tehnika sa višim stepenom konvergencije, kakvi su na primer Quazi-Newton-ovi metodi ili metod konjugovanih gradijenata [Pr88]. Ovi metodi pre svega minimiziraju grešku odziva mreže za ceo trening skup, to jest:

$$e = \sum_{k=1}^{N_p} e_k \quad (2.35)$$

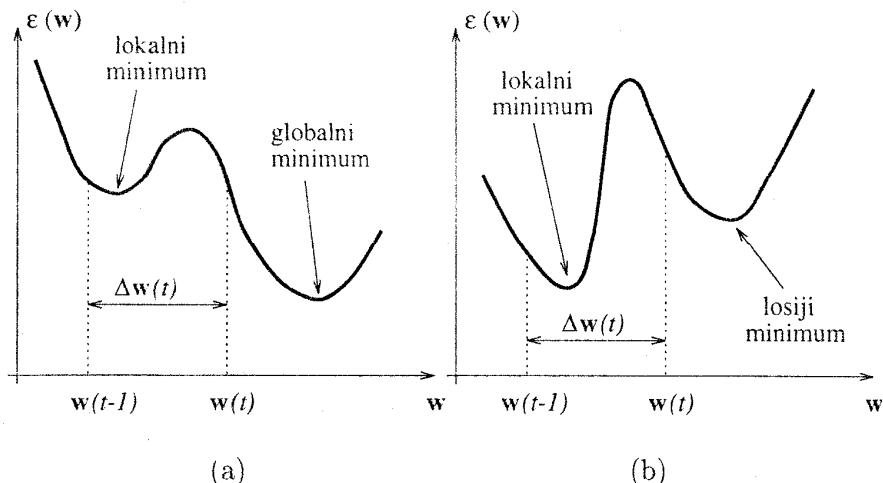
U [Sm94] je dat pregled ovih algoritama i upoređene su njihove osobine sa osobinama obe varijante backpropagation algoritma. Naravno, prednost je na strani učenja sa optimizacionim tehnikama višeg reda. Međutim, optimizacione tehnike sa višim stepenom konvergencije nisu pogodne za realizaciju u paralelnoj distribuiranoj arhitekturi kakva je neuronska mreža, s obzirom da su vezani za manipulaciju matricama parcijalnih izvoda drugog reda. Zato je njihova primena moguća samo u laboratorijskom, to jest off line učenju.

Ubrzanje backpropagation algoritma se može postići i pažljivim izborom parametara η i α iz (2.34). Jasno je da ovi parametri definisu veličinu pomeraja duž optimizacionog pravca. Quazi-Newton-ovi metodi za njihovo određivanje koriste adaptivne tehnike, kakva je na primer Brent-ova optimizacija duž pravca [Pr88]. Ovakav način se međutim ne može primeniti u originalnom backpropagation algoritmu. Kao i kod Widrow-Hoff-ovog pravila, optimizacija greške odziva mreže za jedan trening uzorak do konvergencije nema smisla, jer bi takva optimizacija dovela do gubljenja informacija o prethodno prezentiranim uzorcima. U praksi se uglavnom koriste intuitivna pravila. Na početku učenja je optimizacioni proces daleko od minimuma, pa izvodi funkcije greške odziva mreže imaju velike vrednosti. Tada je poželjno da η i α imaju male vrednosti. Pri kraju optimizacije izvodi greške odziva mreže su mali pa je moguće povećati η i α bez opasnosti od divergencije.

Postoji više načina i za rešavanje problema lokalnih minimuma funkcije greške odziva mreže. Kako je već rečeno, osnovni backpropagation algoritam, kao i njegova verzija sa momentom već imaju ugrađen mehanizam koji može smanjiti verovatnoću konvergencije ka lokalnom minimumu. Naime, u t -toj iteraciji backpropagation algoritma, vektor nepoznatih težina se dobija tako što se težinama iz iteracije ($t-1$) doda priraštaj koji se računa na ranije opisani način, to jest:

$$w(t) = w(t-1) + \Delta w(t) \quad (2.36)$$

Pri tome se ne upoređuju greške odziva mreže sa težinama $w(t)$ i $w(t-1)$. Modifikacija vektora nepoznatih težina bez poređenja grešaka može omogućiti beg iz lokalnog minimuma, kako je to ilustrovano na Sl. 2.14a. Međutim, isti mehanizam može imati i suprotan efekat. Može se desiti da se iz lokalnog minimuma pređe u oblast čiji je lokalni minimum lošiji od prethodnog, Sl. 2.14b. U nekim slučajevima ovo može izazvati i divergenciju procesa učenja.



Sl. 2.14 a) Prelaz iz lokalnog u bolji, i b) prelaz u lošiji minimum

Posledica postojanja lokalnih minimuma u funkciji greške odziva jeste da krajnje rešenje zavisi od početnih vrednosti težina. Jedan od pristupa za rešavanje problema lokalnih minimuma zasniva se upravo na pažljivom biranju početnih vrednosti težina. Obično se na početku učenja težine inicijalizuju slučajnim vrednostima. U [Za94] je opisan sličan pristup, s tom razlikom što je ovde raspodela generisanih slučajnih vrednosti težina kontrolisana na osnovu praćenja kvaliteta odziva inicijalnih mreža. Još jedan interesantan predlog rešenja ovog problema je dat u [De93]. Ovde je razmatrana inicijalizacija učenja troslojnih mreža. Inicijalizacija težina se ovde obavlja tako što se iz trening skupa bira N uzoraka, gde je N broj neurona u skrivenom sloju, i od njih se formira skup prototip uzoraka. Inicijalne težine se određuju tako da mreža daje korektan odziv za sve uzorke iz prototip skupa. Ova faza ne zahteva iterativni postupak, već se može obaviti analitički. Ako su prototip uzorci izabrani pažljivo, onda mreža koja daje korektan odziv za ove uzorke predstavlja izuzetno dobro početno rešenje za učenje na celom trening skupu.

Dobro početno rešenje u optimizaciji nelinearnih funkcija može se dobiti i rešavanjem linearizovanog problema. Jedna takva ideja primenjena na učenje neuronskih

mreža data je u [Ya93]. Za sve neurone sa nelinearnom aktivacionom funkcijom koristi se modifikovana aktivaciona funkcija sledećeg oblika:

$$g_\lambda(x) = \lambda x + (1 - \lambda)\sigma(x) \quad (2.37)$$

gde je $\sigma(x)$ originalna aktivaciona funkcija neurona, recimo sigmoidna. Parametar λ kontroliše nelinearnost ove funkcije. Ako je $\lambda=1$, onda (2.37) predstavlja linearu aktivacionu funkciju, a za $\lambda=0$ sigmoidnu. Proces učenja počinje sa $\lambda=1$ i u toku učenja se λ smanjuje postepeno tako da na kraju ima vrednost 0.

U [Br89] je problem postojanja lokalnih minimuma funkcije greške podrobnije ispitivan. Pokazano je, na vrlo jednostavnim linearno separabilnim primerima, da funkcija greške oblika (2.16) poseduje lokalne minimume koji ne klasifikuju ispravno trening skup. Takođe je pronađeno nekoliko primera gde ni globalni minimum ove funkcije ne daje ispravnu klasifikaciju. Imajući u vidu da se radi o linearno separabilnim trening uzorcima kada perceptron algoritam uspešno rešava problem, i da su višeslojne mreže i backpropagation uvedeni upravo zbog rešavanja problema prisutnih kod perceptron algoritma, posumnjalo se da li se backpropagation uopšte može smatrati rešenjem perceptron problema. Uvođenje takozvane pragovske funkcije greške [So91] izjednačilo je kvalitet backpropagation i perceptron algoritma u dvoslojnim neuronskim mrežama. Korišćenje pragovske funkcije greške u višeslojnim mrežama smanjuje verovatnoću konvergencije ka lokalnom minimumu, šireći oblasti kontrakcije globalnih minimuma.

2.4 Veštačke neuronske mreže kao univerzalni aproksimatori funkcija

Najvažnije svojstvo neuronskih mreža je njihova sposobnost aproksimacije. Poznato je da VNM sa dva sloja, tj. mreža bez skrivenih slojeva, nema sposobnost aproksimacije nelinearne kontinualne funkcije. Mreže sa četiri ili više slojeva se retko koriste u praksi, a dokaz da su one univerzalni aproksimatori je vrlo jednostavan [Sc98].

U ovom radu se razmatraju samo mreže sa tri sloja sa sigmoidnom aktivacionom funkcijom u skrivenom sloju, pa sledi diskusija o njihovim sposobnostima aproksimacije, uz pokazivanje nekih teorema.

Pitanje aktivacione funkcije u skrivenom sloju je od suštinskog značaja, i treba zapravo pokazati uslove koje neka funkcija treba da ispuni kako bi bila aktivaciona. Dokazano je [Ho89], na primer, da svaka ograničena nekonstantna kontinualna funkcija može da bude aktivaciona. Isto tako, uz neka ograničenja amplituda kontinualne funkcije blizu beskonačnosti, svaka nepolinomska funkcija može da bude aktivaciona [Mh92].

Mnogi autori su tvrdili da mreža sa sigmoidnom aktivacionom funkcijom u skrivenom sloju može da aproksimira kontinualnu funkciju ili druge vrste funkcija definisane na kompaktnom skupu u R^n , pri čemu je sigmoidna funkcija kontinualna ili monotona. Teoreme 1-4 pokazuju da je baš ograničenost sigmoidne funkcije glavni razlog zbog koga je ona izabrana za aktivacionu funkciju u skrivenom sloju [Ch90], [Ch95a], pri čemu monotonost funkcije nije neophodan uslov.

Najpre su predstavljene osnovne definicije.

Definicija 1: Funkcija $\sigma: R \rightarrow R$ je sigmoidna funkcija, ako zadovoljava:

$$\begin{cases} \lim_{x \rightarrow -\infty} \sigma(x) = 0, \\ \lim_{x \rightarrow \infty} \sigma(x) = 1. \end{cases}$$

Skup C^1 je skup kontinualnih funkcija u R^1 .

Definicija 2: Ako je kontinualna funkcija definisana u R^n , i postoji $\lim_{|x| \rightarrow \infty} f(x)$, onda je $f(x)$ kontinualna funkcija u proširenom prostoru R^n (označena sa \bar{R}^n), a skup svih kontinualnih funkcija definisanih u proširenom prostoru R^n se piše kao $C(\bar{R}^n)$, naime:

$$C(\bar{R}^n) = \left\{ f \in C(\bar{R}^n) : \lim_{|x| \rightarrow \infty} f(x) \text{ postoji} \right\}$$

$C_b^1 \subset C^1$ je potprostor, tj. skup ograničenih elemenata iz skupa C^1 . U sledećem tekstu koriste se dve različite metrike:

$$d_\infty(f, g) = \sup_{x \in R} |f(x) - g(x)|$$

$$d_C(f, g) = \sum_{n \in N} 2^{-n} \min \left\{ \sup_{x \in R} |f(x) - g(x)|, 1 \right\}$$

Prostor $\bar{C}^1 \subset C^1$ je skup kontinualnih funkcija koje imaju realne granice u $\pm \infty$.

Prostor $\overset{o}{C}^1 \subset C^1$ je skup kontinualnih funkcija koje imaju istu granicu u $\pm \infty$.

Prostor M^1 je skup merljivih funkcija u R^1 . $M_b^1 \subset M^1$ je skup ograničenih elemenata iz skupa M^1 .

Prostor $\bar{M}^1 \subset M^1$ je skup merljivih funkcija koje imaju realne granice u $\pm \infty$.

Prostor $\overset{o}{M}^1 \subset M^1$ je skup merljivih funkcija koje imaju istu granicu u $\pm \infty$.

Definicija 3: Za $g \in M^1$, S_g^1 označava skup neuronskih mreža sa jednim skrivenim slojem u R^1 , zasnovan na aktivacionoj funkciji g .

Definicija 4: Za $S, C \subset M^1$ i za metriku d u M^1 , S je d -izvan gust za C ako d -opseg od S sadrži C , i S je d -unutar gust za C ako d -opseg od $S \cap C$ sadrži C .

Definicija 5: Funkcija $\bar{M}_b^1 \setminus \overset{o}{M}_b^1$ je generalizovani sigmoid; funkcija $\bar{C}^1 \setminus \overset{o}{C}^1$ je kontinualni generalizovani sigmoid.

Definicija 6: Za $C \subset M^1$ i za metriku d u M^1 , neuronske mreže sa jednim skrivenim slojem zasnovane na g su d -izvan guste (respektivno d -unutar guste) za C za ograničenim težinama ako d -opseg od $S_g^1(l)$ (respektivno, $S_g^1(l) \cap C$) sadrži C za svaki neprazan skup iz R^2 .

Teoreme 1 i 2 [Ch95a] pokazuju da ako je $\sigma(x)$ ograničena sigmoidna funkcija, onda je skup $\sum_{i=1}^N c_i \sigma(y_i \cdot x + \theta_i)$ gust u $C(\bar{R}^n)$ i u $C(K)$, gde je K kompaktni skup u R^n .

Teorema 1: Ako je $\sigma(x)$ ograničena sigmoidna funkcija, a $f(x)$ je kontinualna funkcija na $(-\infty, \infty)$, za koju $\lim_{|x| \rightarrow -\infty} f(x) = A$ i $\lim_{|x| \rightarrow \infty} f(x) = B$, gde su A, B konstante, onda za svako $\varepsilon > 0$, postoji N, c_i, y_i, θ_i tako da:

$$\left| f(x) - \sum_{i=1}^N c_i \sigma(y_i \cdot x + \theta_i) \right| < \varepsilon$$

važi za sve $x \in (-\infty, \infty)$.

Teoreme 1a i 1b [St99] predstavljaju proširenje Teoreme 1, jer opisuju aktivacione funkcije koje aproksimiraju funkcije u R^1 , a koje mogu da budu i neograničene. Teorema 1c [St99] detaljnije opisuje aktivacione funkcije koje ne podležu ovoj karakterizaciji, odnosno da neuronske mreže sa jednim skrivenim slojem sa aktivacionom funkcijom u $M_b^{o^1}$ ne mogu uniformno da aproksimiraju ništa izvan $M_b^{o^1}$, tj. ništa u $\overline{C}^1 \setminus C^{o^1}$.

Teorema 1a: S_g^1 je d_∞ -unutar gusta za \overline{C}^1 ako i samo ako S_g^1 sadrži kontinualni, generalizovani sigmoid.

Teorema 1b: S_g^1 je d_∞ -unutar gusta za \overline{C}^1 ako i samo ako d_∞ -opseg od S_g^1 sadrži kontinualni, generalizovani sigmoid.

Teorema 1c: Ako je $g \in M_b^{o^1}$ (respektivno C^{o^1}), onda je d_∞ -opseg od S_g^1 podskup od $M_b^{o^1}$ (respektivno \overline{C}^{o^1}).

Teorema 2: Prepostavimo da $g: R^1 \rightarrow R^1$ zadovoljava uslov da su sve linearne kombinacije $\sum_{i=1}^N c_i g(y_i \cdot x + \theta_i)$ guste u $C(\overline{R}^1)$, onda su sve linearne kombinacije $\sum_{i=1}^N c_i g(y_i \cdot x + \theta_i)$ guste u $C(\overline{R}^n)$, gde je $y_i \cdot x$ unutrašnji proizvod y_i i x .

Prema Teoremi 2, da bismo dokazali sposobnost aproksimacije neuronske mreže u n -dimenzionalnom prostoru, potrebno je samo dokazati sposobnost aproksimacije za jednodimenzionalni slučaj.

Nasuprot Teoremi 2, Teoreme 2a i 2b [St90] pokazuju da se uslovi aproksimacije dosta razlikuju za slučaj $n \geq 2$, odn. za višedimenzionalne prostore.

Definicija 7: Za $g \in M^1, S_g^n$ označava skup neuronskih mreža sa jednim skrivenim slojem u R^n , zasnovan na aktivacionoj funkciji g .

Teorema 2a: Za svako $n \geq 2$, ako $g \in \overline{C}^1 \setminus C^{o^1}$, onda je $S_g^n \setminus C^{o^n}$ podskup konstantnih funkcija.

Teorema 2b: Za svako $n \geq 2$ d_∞ -opseg od S_g^1 koji sadrži generalizovani sigmoid je dovoljan, ali ne i neophodan uslov za S_g^n da bude d_∞ -izvan gust za \overline{C}^{o^n} .

Teoreme 3 [St90] i 4 [Ch95a] razmatraju aproksimaciju u L^p normi. Kako konačna suma $\sum_{i=1}^N c_i \sigma(y_i \cdot x + \theta_i)$ ne pripada $L^p(\mathbb{R}^n)$, razmatra se aproksimacija u $L^p(K)$, gde je K neki kompaktni skup u \mathbb{R}^n .

Teorema 3: Prepostavimo da $g \in L^p_{loc}(\mathbb{R}^1) \cap L^1(\mathbb{R}^1)$ i $\int_{\mathbb{R}^1} g(x)dx \neq 0$, onda su linearne kombinacije $\sum_{i=1}^N c_i g(y_i \cdot x + \theta_i)$ guste u $L^p(K)$, gde je K kompaktni skup u \mathbb{R}^n .

Uslovi za funkciju g su dosta ograničavajući, jer nijedna sigmoidna funkcija ne zadovoljava uslov $\sigma \in L^1(\mathbb{R}^1)$, odnosno ne može da bude aktivaciona funkcija. Teorema 4 pokazuje da bilo koja funkcija iz L^p_{loc} može da bude aktivaciona funkcija u L^p aproksimaciji.

Teorema 4: Prepostavimo da $g: \mathbb{R}^1 \rightarrow \mathbb{R}^1$ zadovoljava $g \in L^p_{loc}(\mathbb{R}^1)$ i $\sum_{i=1}^N c_i g(\lambda_i \cdot x + \theta_i)$ su guste u svakom $L^p[a, b]$, onda je $\sum_{i=1}^N c_i g(y_i \cdot x + \theta_i)$ gusta u svakom $L^p(K)$, gde je K kompaktni skup u \mathbb{R}^n .

Kako je za sigmoidnu funkciju pokazano da može da bude aktivaciona funkcija u skrivenom sloju, Teoreme 5-9 [Ch95b] bave se uslovima koje jedna funkcija treba da ispunjava da bi bila aktivaciona, i ispituju se mogućnosti aproksimacije nelinearnih funkcionala definisanih na nekom kompaktnom skupu u Banahovom prostoru.

Najpre je predstavljena notacija i osnovne definicije.

K - neki kompaktni skup u Banach-ovom prostoru

$C(K)$ - Banach-ov prostor svih kontinualnih funkcija definisan nad K

$S(\mathbb{R}^n)$ - Schwartz-ove funkcije u teoriji raspodele, tj. brzo-rastuće i beskonačno diferencijabilne funkcije

$S'(\mathbb{R}^n)$ - Linearni kontinualni funkcionali definisani nad $S(\mathbb{R}^n)$

$C^\infty(\mathbb{R}^n)$ - Beskonačno diferencijabilne funkcije

$C_C^\infty(\mathbb{R}^n)$ - Beskonačno diferencijabilne funkcije sa kompaktnim nosačem u \mathbb{R}^n

$C_p[-1, 1]^n$ - Sve periodične funkcije sa periodom dva u odnosu na svaku promenljivu x_i , $i=1, \dots, n$.

Definicija 8: Ako funkcija $g: R \rightarrow R$ (kontinualna ili prekidna) zadovoljava uslov da su sve linearne kombinacije $\sum_{i=1}^N c_i g(\lambda_i x + \theta_i)$, $\lambda_i \in R$, $\theta_i \in R$, $c_i \in R$, $i = 1, 2, \dots, N$, guste u svakom $C[a, b]$, onda je g Tauber-Wiener-ova funkcija (TW).

Definicija 9: Prepostavimo da je X Banach-ov prostor, $V \subseteq X$ je kompaktni skup u X , ako za svaki niz $\{x_n\}_{n=1}^\infty$ tako da $x_n \in V$, postoji podniz $\{x_{n_k}\}$, koji konvergira nekom elementu $x \in V$.

Teorema 5: Prepostavimo da je g kontinualna funkcija, i $g \in S'(\mathbb{R}^1)$, onda $g \in (TW)$, ako i samo ako g nije polinom.

Teorema 6: Ako je σ ograničena sigmoidna funkcija, onda $\sigma \in (TW)$.

Teorema 7: Prepostavimo da je K kompaktni skup u R^n , U je kompaktni skup u $C(K)$, $g \in (TW)$, tada za svako $\varepsilon > 0$, postoji pozitivni ceo broj N , realni broj θ_i , vektori $\omega_i \in R^n$, $i=1, \dots, N$, koji su nezavisni od $f \in C(K)$ i konstante $c_i(f)$, $i=1, \dots, N$ koje zavise od f , kao:

$$\left| f(x) - \sum_{i=1}^N c_i(f) g(\omega_i \cdot x + \theta_i) \right| < \varepsilon$$

važi za svako $x \in K$ i $f \in U$. Svaki $c_i(f)$ je linearni kontinualni funkcional definisan nad U .

Teorema 7 pokazuje da ukoliko želimo da neka funkcija bude aktivaciona funkcija, dovoljan uslov je da pripada klasi TW funkcija.

Sledeće dve teoreme razmatraju problem aproksimacije nelinearnih kontinualnih funkcionala i operatora upotreboom neuronskih mreža.

Teorema 8: Prepostavimo da $g \in (TW)$, X je Banach-ov prostor, $K \subseteq X$ je kompaktni skup, V je kompaktni skup u $C(K)$, f je kontinualni funkcional definisan nad V , za bilo koje $\varepsilon > 0$ postoji pozitivan ceo broj N , m tačaka $x_1, \dots, x_m \in K$, i realne konstante c_i, θ_i, ξ_{ij} , $i=1, \dots, N, j=1, \dots, m$, tako da

$$\left| f(u) - \sum_{i=1}^N c_i g\left(\sum_{j=1}^m \xi_{ij} u(x_j) + \theta_i\right) \right| < \varepsilon$$

važi za sve $u \in V$.

Teorema 9: Prepostavimo da $g \in (TW)$, X je Banach-ov prostor, $K_1 \subseteq X$, $K_2 \subseteq R^n$ su dva kompaktna skupa u X i R^n , respektivno, V je kompaktni skup u $C(K_1)$, G je nelinearni kontinualni operator, koji se preslikava u $C(K_2)$, onda za svako $\varepsilon > 0$, postoje pozitivni celi brojevi M, N, m , konstante $c_i^k, \zeta_i^k, \xi_{ij}^k \in R$, tačke $\omega_k \in R^n$, $x_j \in K_1$, $i=1, \dots, M$, $k=1, \dots, N, j=1, \dots, m$, tako da

$$\left| G(u)(y) - \sum_{k=1}^N \sum_{i=1}^M c_i^k g\left(\sum_{j=1}^m \xi_{ij}^k u(x_j) + \theta_i^k\right) \cdot g(\omega_k \cdot y + \zeta_k) \right| < \varepsilon$$

važi za sve $u \in V$ i $y \in K_2$.

U mnogim dokazima koji se tiču neuronskih mreža sa jednim skrivenim slojem, težine veza između ulaznih i skrivenih neurona mogu da budu proizvoljno velike. Njih je teško hardverski implementirati, tako da one nisu zapravo od interesa. Mreže koje imaju ograničene težine je i lakše implementirati, i dobro modeluju prirodne procese.

Teorema 10 [St99] pokazuje da je moguće koristiti veoma ograničene skupove težina između ulaznih i skrivenih neurona.

Teorema 10: Ako je $g \in C^1$ analitička funkcija, onda su neuronske mreže sa jednim skrivenim slojem zasnovane na g d_C -unutar guste za C^1 sa ograničenim težinama ako i samo ako g nije polinom.

Teorema 11: Ako $g \in \overline{M}^1$, onda neuronske mreže sa jednim skrivenim slojem zasnovane na g nikad nisu d_C -izvan guste za \overline{C}^1 sa ograničenim težinama.

Teorema 11 [St99] ne pokazuje šta je moguće, već šta je nemoguće.

Ovi rezultati pokazuju da neuronske mreže sa jednim skrivenim slojem zasnovane na generalizovanim sigmoidima nisu pogodne za aproksimaciju funkcija sa ograničenjima u \overline{C}^1 . Slični rezultati važe i za višedimenzionalne prostore.

Prethodne teoreme odnose se na aproksimaciju nepolinomskih funkcija. Pokazano je [Ch92b] da se polinomi mogu aproksimirati ako se razlože na sumu “ridge” funkcija (funkcija oblika $r(x_1 \cos \theta + x_2 \sin \theta)$). U tom slučaju su “ridge” funkcije kvadrati linearnih kombinacija ulaza, a dokazano je da je svaki homogeni polinom stepena r od d promenljivih linearne kombinacije od $N = \binom{r+d-1}{d-1}$ funkcija. Još nekoliko autora predlaže različite transformacije polinomskih funkcija kako bi se one razložile i aproksimirale.

Dokaz da se polinomi mogu aproksimirati do željene preciznosti neuronском mrežom sa fiksним brojem skrivenih neurona dat je u [Sc98]. Dokaz se sastoji iz dva dela. Najpre se funkcija razlaže na sumu “ridge” funkcija u odnosu na konačan broj pravaca. Svaka “ridge” funkcija se onda aproksimira linearnom kombinacijom pomeranja aktivacionih funkcija. Razvijeni su i algoritmi koji određuju broj skrivenih neurona za mrežu sa sigmoidnom aktivacionom funkcijom za zadatu tačnost. Algoritmi su tako napravljeni da se ne javljaju problemi lokalnih minimuma.

Sledeće pitanje kojim su se bavili mnogi autori je pitanje specifikacije potrebnog broja skrivenih neurona da bi se funkcija aproksimirala sa tačno zadatom greškom. U [Mh92] je opisana aproksimacija funkcije i dat je proračun greške. Međutim, izrazi za proračun su isuviše složeni i sadrže implicitne konstante da bi se iz njih izvele eksplisitne jednačine iz kojih se može izračunati stvarna vrednost greške.

Teoreme koje daju eksplisitne jednačine za specifikaciju broja skrivenih neurona i eksplisitne formule za proračun greške aproksimacije prikazane su u [Su98]. Te teoreme se odnose na neuronske mreže sa trigonometrijskom, segmentno linearном i sigmoidnom aktivacionom funkcijom, a aproksimiraju se 2π -periodične Lebesgue-integrabilne funkcije p -tog reda iz R^m u R^n za $p \geq 1$ u $L_{2\pi}^p$ -normi. Predstavljeni metod aproksimacije opisuje novu mrežu samo na osnovu višedimenzionalnih Furjeovih koeficijenata, što je veoma praktično i jednostavno.

Kako je tema ovog rada primena neuronskih mreža za modelovanje elektronskih kola, date su samo osnovne teoreme bez dokaza koje pokazuju da su neuronske mreže zaista univerzalni aproksimatori funkcija, tako da rezultati prikazani u narednim poglavljima imaju teorijsku osnovu.

3 Opis rešenja

Dokazano je da su veštačke neuronske mreže vrlo pogodne za aproksimaciju kada se koristi pristup "crna kutija". Prvi primer primene VNM za modelovanje elektronskih komponenata predstavljen je u [Li92], gde je prikazano modelovanje karakteristika MOS tranzistora. Naime, tada korišćeni model MOS tranzistora u programu SPICE imao je prekidne izvode, tj. postojao je problem pri modelovanju prelaza iz omske oblasti u oblast zasićenja, i prelaza između pretpragovske i oblasti zasićenja. Neuronskom mrežom modelovana su samo otporna svojstva tranzistora, tako da se kapacitivnosti dodaju kasnije spolja, kao kod svakog drugog modela. Odziv neuronske mreže je funkcija sa neprekidnim izvodom, a sve oblasti rada tranzistora opisane su samo jednom funkcijom.

Posle objavljinjanja ovog rezultata, veštačke neuronske mreže bile su više puta upotrebljene za modelovanje elektronskih komponenata. U svim ovim primenama modelovana su samo otporna svojstva komponenata.

Prvi pokušaj primene VNM za modelovanje nelinearnih reaktivnih dvopola opisan je u [Li97]. Modelovane su nelinearne magnetne karakteristike elektromagneta sa pokretnom kotvom. Sistem je, ustvari, mikro-elektr-magneto-mehanički, tako da je veoma složen i vrlo je teško ustanoviti sve fizičke procese koji se tu dešavaju. Vrednost magnetnog fluksa kroz kalem je funkcija struje kroz kalem i položaja kotve u odnosu na jezgro, tj. $\Psi = f(i, x)$. Fluks zavisi i od oblika delova elektromagneta, njihovih uzajamnih položaja, od karakteristika materijala, pa bi tačan fizički model morao da obuhvati sva ova svojstva. Položaj elektromagneta, prikazanog na Sl. 3.1, određuje se iz jednakosti mehaničke i magnetne sile: $F_{mag} = F_{mech}$, pri čemu se magnetna sila izračunava kao:

$$F_{mag}(i, x) = g(i, x) = \frac{\partial E_{mag}}{\partial x} = \frac{\partial}{\partial x} \int_0^i \Psi \cdot di \quad (3.1)$$

gde je E_{mag} elektromagnetna energija u vazdušnom procepu.

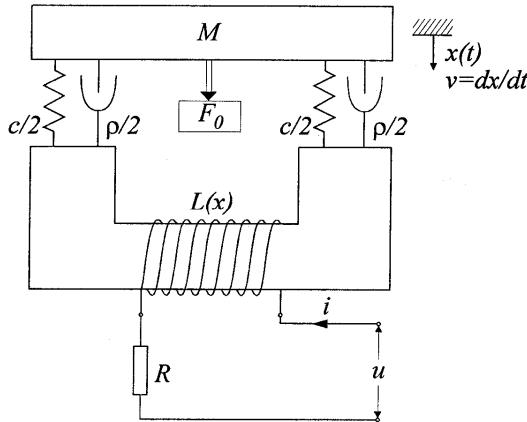
Električna ravnoteža u kolu iskazana je sa:

$$u = R \cdot i + \frac{d\Psi}{dt} \quad (3.2)$$

Ukupna mehanička sila koja deluje na kotvu je zbir sile inercije, sile trenja, sile sabijanja opruga i sile teže:

$$F_{mech} = M \frac{dv}{dt} + \rho \cdot v + c \int v dt + F_0 \quad (3.3)$$

gde je M masa, ρ koeficijent trenja, a c je koeficijent sabijanja.



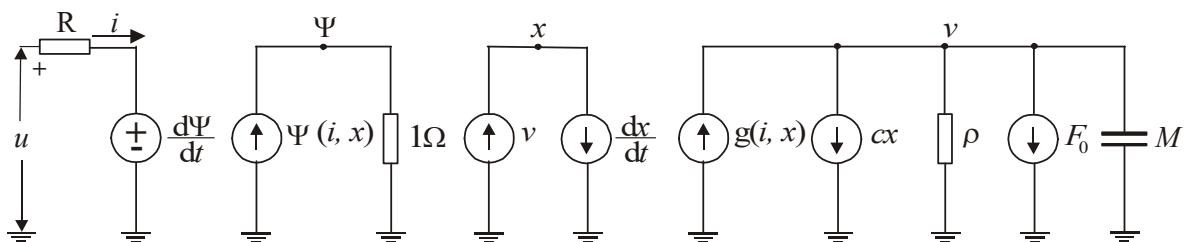
Sl. 3.1 Elektromagnet

Ravnoteža u kolu može se sada opisati sledećom jednačinom:

$$g(i, x) = M \frac{d^2 x}{dt^2} + \rho \frac{dx}{dt} + cx + F_0 \quad (3.4)$$

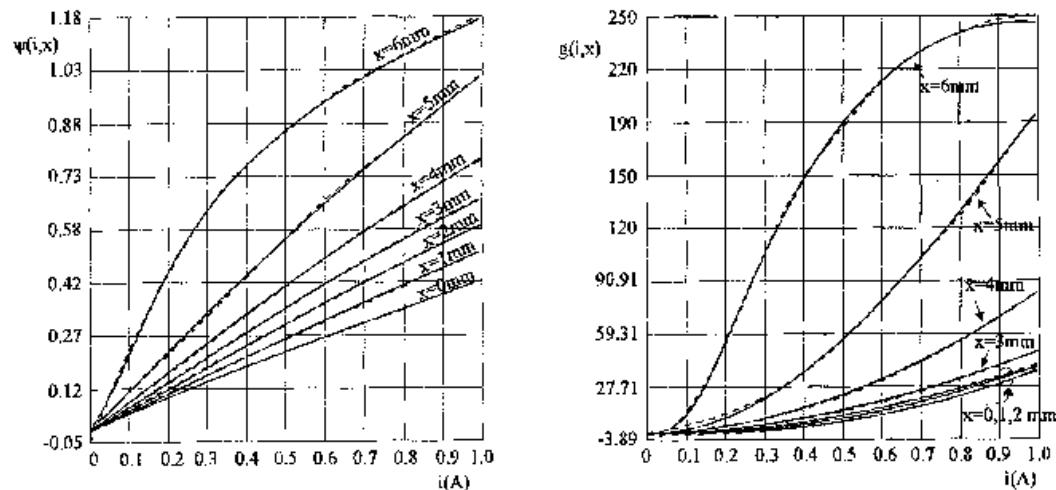
Jednačine (3.2) i (3.4) predstavljaju model magneta. Funkcija koja predstavlja fluks se vrlo teško dobija u zatvorenom obliku, pa se ne može odrediti analitički oblik magnetne sile. Kontinualna i diferencijabilna funkcija $f(i, x)$ može se dobiti aproksimacijom merene karakteristike polinomom, pri čemu je u literaturi pokazano da je mnogo jednostavnije aproksimirati $i(\Psi, x)$ nego $f(i, x)$. Ako i kada bi se napravila tačna aproksimacija ovih zavisnosti, model ne bi bio odgovarajući za simulaciju sistema. Problem je zato što funkciju $f(i, x)$ treba integraliti kako bi se dobila zavisnost $g(i, x)$. Ovo je moguće ako se direktno primene numeričke metode kako bi se implicitno izračunalo $g(i, x)$, ali bi onda implementacija modela bila složenija, a simulacija sistema bi trajala dugo zbog numeričke integracije u svakoj iteraciji.

Neuronska mreža je najpogodnije rešenje u ovakvoj situaciji, i njom je modelovana zavisnost magnetnog fluksa i magnetne sile od struje i vazdušnog procepa, a dinamički model mehaničke sile predstavljen je analitički, jednom jednačinom. Pri tome, model predstavljen neuronskom mrežom je kvazi-dinamički, tj. modelovana su samo otporna svojstva komponente na osnovu modela nelinearnog magneta koji je prethodno razvijen [Li00], i prikazan na Sl. 3.2.



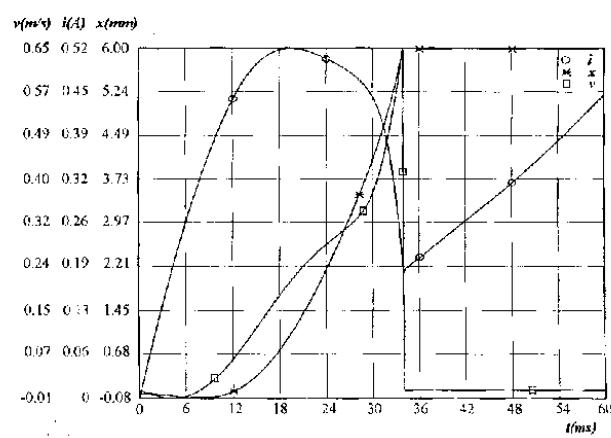
Sl. 3.2 Električna šema modela magneta sa pokretnom kotvom

Na Sl. 3.3 prikazani su rezultati simulacije. Upoređene su merene karakteristike i karakteristike modela, i vidi se da model može tačno da prikaže ponašanje sistema.

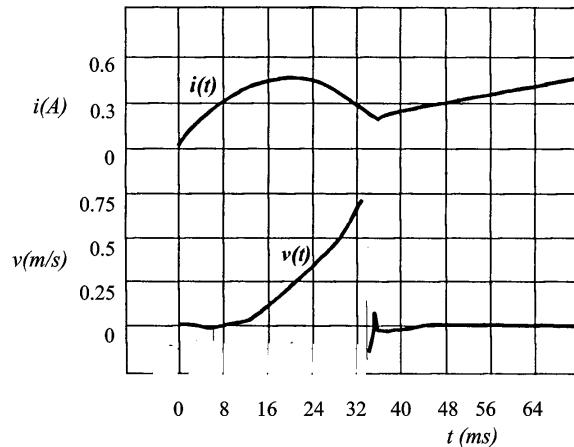


Sl. 3.3 Merene (puna linija) i naučene (isprekidana linija) karakteristike

Za implementaciju modela elektromagneta je korišćen funkcionalni simulator, pa su rezultati simulacije dati na Sl. 3.4.



a)



b)

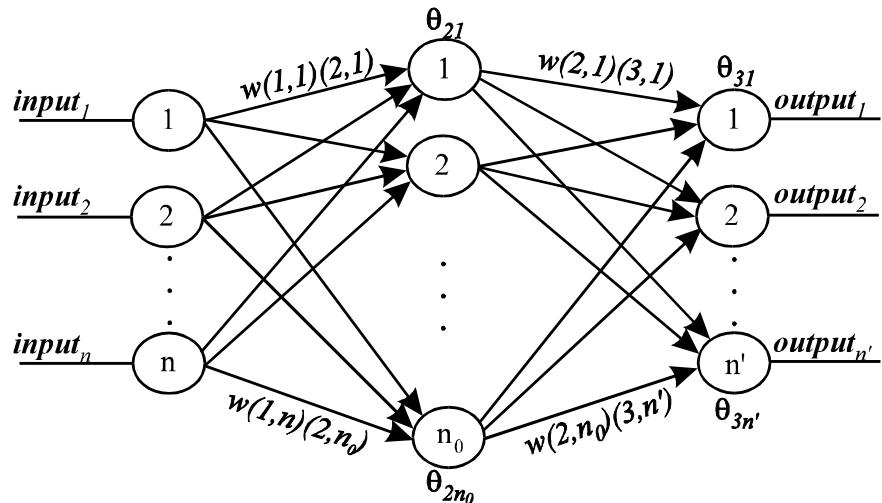
Sl. 3.4 a) Rezultati simulacije kada se koristi model, b) Merene karakteristike

Kada se radi o modelovanju nelinearnih dinamičkih dvopola primenom VNM, prvi rezultati su zasnovani na spektralnoj analizi tako da se aproksimacija obavlja u frekvencijskom domenu [Ci99]. Učenjem se minimizira razlika između spektra podataka za obučavanje i spektra dobijenog na izlazu mreže koja se obučava.

Kao što je već navedeno, neuronske mreže su univerzalni aproksimatori funkcija, pa su u daljem radu predložena rešenja koja se ostvaruju u vremenskom domenu, i koja mogu da iskoriste ova svojstva VNM-a. Najpre treba razmotriti sledeće osnovne probleme:

1. Sinteza talasnog oblika pobudnog signala
2. Sinteza topologije mreže
3. Određivanje složenosti mreže

Pre nego što pokušamo da damo odgovore na gornje probleme biće opisana nerekurentna neuronska mreža koja će služiti kao jezgro modela koje ćemo kasnije uvoditi. Primer jedne nerekurentne neuronske mreže [He89] dat je na Sl. 3.5. Ova mreža je potpuno povezana, sadrži jedan skriveni sloj, a signali se prostiru samo u jednom smeru.



Sl. 3.5 Nerekurentna neuronska mreža sa jednim skrivenim slojem

n , n_0 i n' predstavljaju broj neurona u ulaznom, skrivenom i izlaznom sloju, respektivno. θ_{ji} je prag i -tog neurona u j -tom sloju, a $w(p, j)(q, i)$ je težina veze između j -tog neurona sloja p i i -tog neurona iz sloja q . Neuroni u skrivenom sloju aktiviraju se sigmoidnom funkcijom:

$$z_i = \frac{1}{1 + e^{-\lambda_1 \cdot s_i}} \quad (3.5)$$

Za neurone u izlaznom sloju koristi se linearna funkcija:

$$y_i = \lambda_2 \cdot q_i \quad (3.6)$$

Parametri λ_1 i λ_2 u izrazima (3.5) i (3.6) su konstantni koeficijenti, a z_i i y_i su ulazi u skriveni i izlazni sloj, respektivno. Sume s_i i q_i dobijaju se prema formulama (3.7) i (3.8):

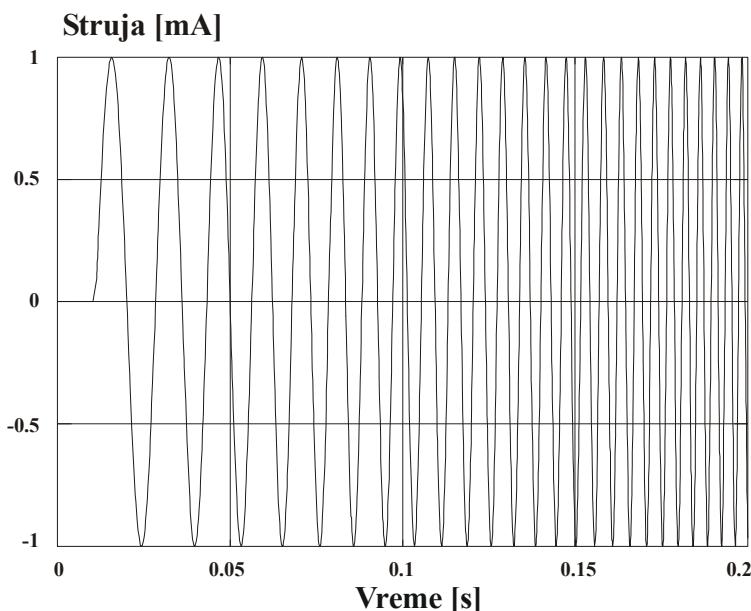
$$s_i = \sum_{j=1}^n w(1,j)(2,i) \cdot x_j + \theta_{2i} \quad (3.7)$$

$$q_i = \sum_{j=1}^{n_0} w(2,j)(3,i) \cdot z_j + \theta_{3i} \quad (3.8)$$

Iz jednačina (3.7) i (3.8) se vidi da svi izlazi iz prethodnog sloja doprinose sumi. x_j je izlazna vrednost j -tog neurona iz ulaznog sloja, z_j je izlazna vrednost j -tog neurona iz skrivenog sloja.

3.1. Sinteza talasnog oblika

Sinteza signala koji pobuđuje mrežu od velikog je značaja. Signal treba da bude takav da tokom simulacije u potpunosti aktivira ponašanje predmeta modelovanja, a da pri tome zahteva minimalno vreme simulacije i da se odlikuje jednostavnosću, odnosno da se iskazuje sa što je moguće manje parametara. Kada se radi o statičkoj karakteristici, na primer, treba da po amplitudi obuhvata celokupnu dinamiku signala kako bi se aktivirala eventualna nelinearnost komponente. S druge strane, da bi se modelovale reaktivne osobine, spektar pobudnog signala treba da bude takav da pokriva celokupni "propusni opseg" komponente koja se modeluje. Naravno, komponenta može da ima i dinamičke nelinearnosti. Zato je potrebno da se amplituda signala prilagođava tako da se i one aproksimiraju sa željenom tačnošću.



Sl. 3.6 Frekvencijski modulisana sinusoida koja se koristi kao pobuda mreže koja se obučava

Za ovu namenu koristi se sinusoida sa monotono rastućom frekvencijom u opsegu od interesa, tj. frekvencijski modulisana sinusoida [Il00]. Jedan ovakav signal prikazan je na Sl. 3.6.

Frekvencija se može menjati na više načina. Neki od njih su:

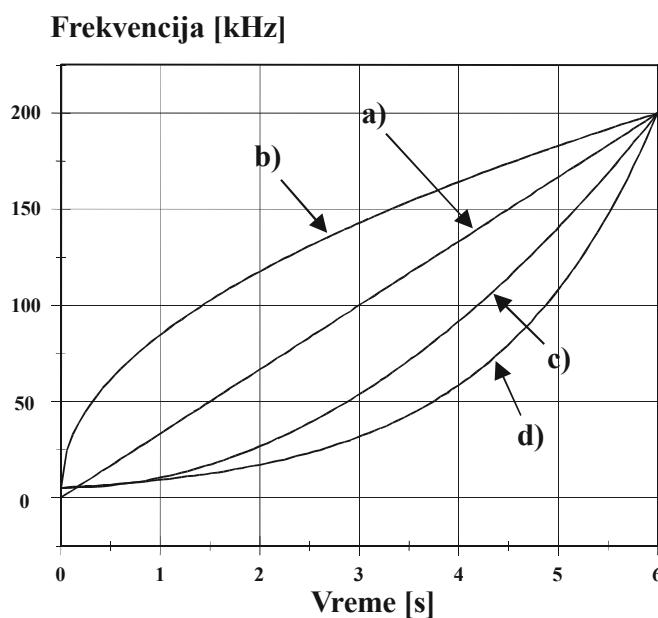
a) $f_0 + k_1 t$

b) $f_0 + k_2 \sqrt{t}$

c) $f_0 + k_3 t^2$

d) $f_0 \cdot e^{k_4 t}$

f_0 je najniža frekvencija u opsegu od interesa, t je tekući vremenski trenutak, a k_1, k_2, k_3, k_4 su konstantni koeficijenti. Promena frekvencije, analitički prikazana izrazima a)-d), grafički je predstavljena na Sl. 3.7.



Sl. 3.7 Promena frekvencije signala sa Sl. 3.6 u funkciji vremena

Signal sa linearnom promenom frekvencije, prikazan pod a), brzo dostigne visoke frekvencije, pa ukoliko neuronska mreža treba da nauči svojstva koja dolaze do izražaja na niskim frekvencijama, signal treba menjati sporo, odnosno k_1 treba da bude malo. Slično važi i za funkciju prikazanu pod b), kada frekvencija zavisi od kvadratnog korena vremena. Funkcije prikazane pod c) i d), kada je signal direktno proporcionalan kvadratu vremena, odnosno eksponentu vremena, respektivno, imaju sporiju promenu na niskim frekvencijama, tako da simulacija viših frekvencija kraće traje.

Svaka od ovih promena ima svoje prednosti i nedostatke, i koju od njih ćemo koristiti, zavisi isključivo od karakteristika električnog kola koje modelujemo. Najvažnije je analizirati dovoljan broj uzoraka po periodi i za najviše frekvencije. Zato treba izabrati

dovoljno sporu promenu frekvencije da bismo imali informaciju o svim mogućim slučajevima, ali i dovoljno brzu kako ne bismo dobili preveliki broj uzoraka za obučavanje. U narednim primerima uglavnom koristimo linearnu promenu frekvencije, tj. promenu a), pa ulazni signal dobija oblik (3.9). Ukoliko se frekvencija menja po nekom drugom zakonu, biće eksplicitno naglašeno.

$$i(t) = I_0 \cdot \sin(2\pi \cdot (f_0 + k \cdot t) \cdot t) \quad (3.9)$$

k se izračunava na osnovu trajanja simulacije (t_{final}) i najviše frekvencije iz željenog opsega (f_{high}) kao:

$$k = \frac{f_{high} - f_0}{2 \cdot t_{final}} \quad (3.10)$$

Iz (3.10) sledi da je opseg frekvencija od interesa f_0 do f_{high} .

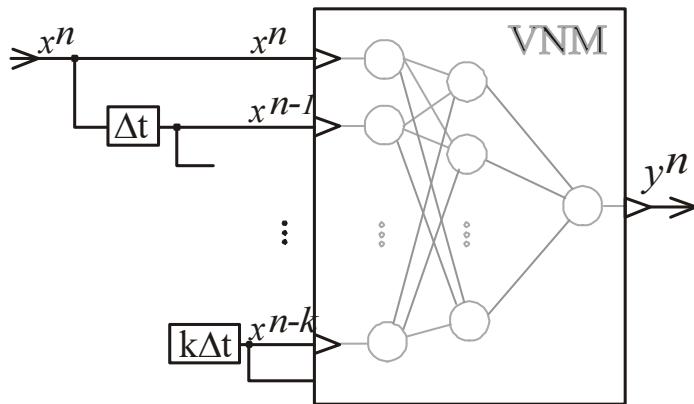
Kao što smo rekli, vremenski korak simulacije treba da bude dovoljno mali da bi na najvišim frekvencijama periode sinusoide sadržale dovoljan broj analiziranih tačaka. Ovde se smatra da je deset tačaka po periodi dovoljan broj.

3.2. Sinteza topologije mreže

Optimalna topologija mreže nikada nije poznata unapred tako da osobine sintetizovane mreže zavise od iskustva projektanta i od dostupne literature.

Mreže koje se koriste u primerima prikazanim u ovom radu su, pored nerekurentne mreže sa Sl. 3.5, Neuronska mreža sa vremenskim kašnjenjem (Time-Delay Neural Network -TDNN) i Rekurentna neuronska mreža sa vremenskim kašnjenjem (Recurrent Time-Delay Neural Network).

Neuronska mreža sa vremenskim kašnjenjem je prvi put predstavljena u [Wa89], i korišćena je za prepoznavanje fonema. Kao što je prikazano na Sl. 3.8, izlaz mreže, označen kao y^n , zavisi od ulaza mreže u tekućem trenutku i od ulaza mreže u prethodnim trenucima.



Sl. 3.8 Neuronska mreža sa vremenskim kašnjenjem

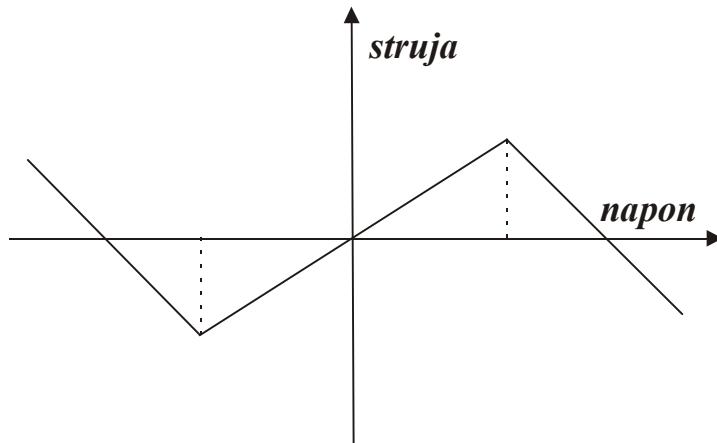
Radi sticanja osećaja o potrebi dovođenja pobudnog signala iz više prethodnih vremenskih trenutaka, poslužićemo se sledećim primerom. Grana sa kondenzatorom u vremenskom domenu, može biti opisana kao:

$$i_C = C \frac{dv_C}{dt} \quad (3.11)$$

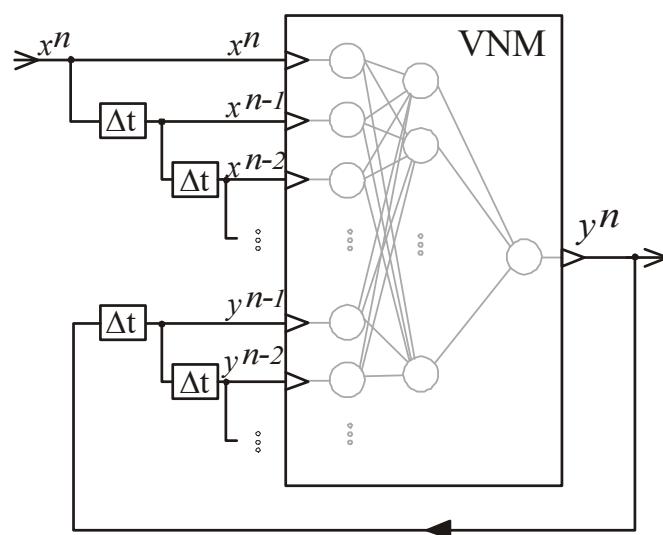
gde je v_C napon na kondenzatoru, a i_C je struja kroz granu u kojoj se nalazi kondenzator. Primenom Ojlerovog inverznog pravila, ova jednačina može biti diskretizovana kao [Li97]:

$$i_C^n = G_C^{n-1} \cdot v_C^n + i_{Cs}^{n-1} \quad (3.12)$$

gde $n-1$ i n označavaju prošli i tekući vremenski trenutak, respektivno, $G_C^{n-1} = C/h^{n-1}$, $i_{Cs}^{n-1} = -Cv_C^{n-1}/h^{n-1}$, a $h^{n-1} = t^n - t^{n-1}$ je vremenski korak. Sada vidimo da je odziv u sadašnjem trenutku funkcija pobude iz sadašnjeg i prethodnog trenutka.



Sl. 3.9 Primer višeznačne funkcije



Sl. 3.10 Rekurentna neuronska mreža sa vremenskim kašnjenjem

Neuronska mreža sa vremenskim kašnjenjem se takođe koristi kada želimo da modelujemo komponentu opisanu višezačnom funkcijom. Ako razmotrimo funkciju prikazanu na Sl. 3.9, postoji više vrednosti napona za istu vrednost struje, što znači da moramo da upamtimo neke prethodne vrednosti struje da bismo opisali određenu koordinatu.

Topologija Rekurentne neuronske mreže sa vremenskim kašnjenjem prikazana je na Sl.3.10 [Il00], [Be94]. U slučaju mreže sa Sl. 3.10, kašnjenja se odnose samo na neurone u ulaznom sloju. Topologije kod kojih se kašnjenje odnosi na neurone u skrivenom sloju prikazane su u [Cl97].

Izlaz mreže, predstavljen kao y^n , zavisi od ulaza mreže u tekućem trenutku, ulaza mreže u prethodnim trenucima, kao i od izlaza mreže u prethodnim trenucima.

Ukoliko se modeluje komponenta sa memorijskim svojstvima, rekurentna mreža je očigledan izbor.

3.3. Složenost mreže

Topologije sa Sl. 3.8 i 3.10 treba prilagoditi konkretnom problemu, tj. za jezgro sa Sl. 3.10 treba odrediti broj skrivenih slojeva i broj neurona u svakom sloju. Takođe, što je još značajnije za samo obučavanje mreže, treba odrediti broj uzoraka ulaznog i izlaznog signala koji služe kao skup podataka za obučavanje.

Pokazano je da ne postoji teorijski razlog za korišćenje više od dva skrivena sloja. Kada se koristi više skrivenih slojeva, proces učenja traje mnogo duže, a broj lokalnih minimuma funkcije greške (odstupanja tekućeg od željenog odziva) se znatno povećava [Ma93]. Isto tako, dodatni sloj kroz koji funkcija greške pravi dodatno kašnjenje stvara nagib koji je nestabilniji ukoliko je broj slojeva veći. Za većinu praktičnih problema nije potrebno koristiti više od jednog skrivenog sloja. Mrežu sa dva skrivena sloja treba koristiti samo kada funkcija ima diskontinuitete.

Intuitivno se nameće zaključak da će broj neurona odnosno odgovarajući broj slobodnih parametara raspoloživih za optimizaciju zavisiti od konkretnog problema koji se razmatra. Sam problem aproksimacije, međutim, iskazan je skupom parova pobuda-odziv koji je (merenjem ili na drugi način) generisan radi obučavanja mreže.

Potrebni broj parova ulaz-izlaz koji se koriste kao skup podataka za obučavanje, na žalost, takođe nije unapred poznat. Kada je taj skup previše mali, ne nosi dovoljno informacija o ponašanju originalnog kola, tako da VNM ne može da bude dobro obučena. Kada je taj skup previše veliki, proces učenja može biti predug, ali može doći i do efekta zasićenja mreže [Ma93]. Sticajem okolnosti problem broja uzoraka potrebnih za obučavanje u slučaju modelovanja nelinearnih reaktivnih dvopola rešen je izborom pobudnog signala. Naime, rečeno je da je radi dobre aproksimacije pobudnog signala potrebno da korak diskretizacije bude deset puta manji od najmanje periode u pobudnom signalu. Pošto je perioda sinusoide sa najvećom frekvencijom, $T_{\min} = 1/f_{\max}$ onda je ukupni broj uzoraka N_{uzoraka} :

$$N_{\text{uzoraka}} = \frac{(t_{\text{final}} - t_0)}{T_{\min}} = (t_{\text{final}} - t_0) \cdot f_{\max} \quad (3.13)$$

gde je t_0 vremenski trenutak kada frekvencija počne da se menja.

Kada se koriste topologije sa Sl. 3.8 i Sl. 3.10, treba uzeti konstantni vremenski korak, što znači da je h konstantno u vremenu. Postoji ideja o modelovanju vremena, gde bi vremenski korak bio novi ulaz u mrežu. Tako bi informacija o vremenu bila implementirana u samu neuronsku mrežu, pa bi u tom slučaju bilo moguće koristiti promenljiv vremenski korak. Ovo bi povećalo broj ulaza mreže i vreme obučavanja, ali bi s druge strane, broj uzoraka mogao biti smanjen, jer se niže frekvencije ne bi modelovale velikim brojem tačaka.

Granični uslovi za broj uzoraka za mrežu sa dva skrivena sloja dati su u [Me91], ali kako se ovde razmatra mreža sa samo jednim skrivenim slojem, rezultat nije od interesa.

Najpre treba odrediti broj ulaznih priključaka koji se pobuduju ulaznim signalom i, ukoliko postoji povratna sprega, broj ulaznih priključaka koji je čine. Zatim, potrebno je odrediti broj neurona u skrivenom sloju. Ovaj broj suštinski utiče na dobrotu aproksimacije naročito kada se modeluju nelinearni sistemi. Najzad, broj izlaznih neurona je ovde određen brojem izlaznih signala tako da se usvaja jedan neuron.

Izbor broja ulaznih priključaka mreže sa Sl. 3.5, u konfiguracijama sa Sl. 3.8 i Sl. 3.10, suštinski određuje mogućnosti modelovanja dinamičkih svojstava mreže. Ako pobuda sadrži veliki broj "događaja" odnosno ako su izvodi višeg reda ulaznog signala veliki treba uzeti više uzoraka ulaznog signala radi bolje aproksimacije pobude. Slično, ako su memorijска svojstva mreže izražena, treba takođe uzeti više uzoraka izlaznog signala.

Broj neurona u skrivenom sloju je od izrazitog značaja [Am94]. Mali broj neurona u skrivenom sloju dovodi do mreže koja nije dobro obučena odnosno ne može da aproksimira svojstva kola koje se modeluje. Preveliki broj neurona uslovjava predugo vreme obučavanja, a može da dovede i do prezasićenja mreže [Ma93]. Tako se dobija mreža koja je naučila nebitna svojstva originalnog kola i koja će dati izvrsne rezultate kada se pobudi skupom podataka kojim je obučavana, ali vrlo loše kada problem treba generalizovati. To se dešava zato što mreža podjednako razmatra nebitna svojstva, kao i svojstva koja opisuju opšte karakteristike kola. Zbog ovoga je važno koristiti minimalni broj neurona koji dovodi do željenog rezultata. Mnoge praktične realizacije su u skladu sa pravilom piramide, prema kome broj neurona opada od ulaza ka izlazu. Za mrežu za jednim skrivenim slojem minimalni broj skrivenih neurona je:

$$n_0 = \sqrt{n \cdot n'} \quad (3.14)$$

Ovo pravilo naravno ne važi za kompleksne probleme gde postoji mali broj ulaza i izlaza. Ako, na primer, aproksimiramo složenu funkciju sa samo jednim ulazom i izlazom, koristićemo veliki broj skrivenih neurona. I suprotno, ako je problem jednostavan, biće dovoljno samo nekoliko skrivenih neurona.

Ukoliko želimo da aproksimiramo funkciju opisanu sa N uzoraka tako da greška aproksimacije bude nula, a aktivaciona funkcija u skrivenom sloju je proizvoljna ograničena nelinearna funkcija, maksimalni broj neurona u skrivenom sloju je N [Hu98].

Najbolji pristup je početi sa vrlo malim brojem neurona, obučiti mrežu, i onda pokušati da ispitamo kako ona radi. Ako ne radi dobro, lagano povećavamo broj neurona, testiramo ponovo, i tako dalje. Ovo se dešava sve dok povećanje broja neurona ne vodi značajnjem napretku, a zadovoljni smo odzivom mreže.

4 Primena neuronskih mreža u modelovanju

4.1 Modelovanje otpornih mreža

4.1.1 Modelovanje MOS tranzistora

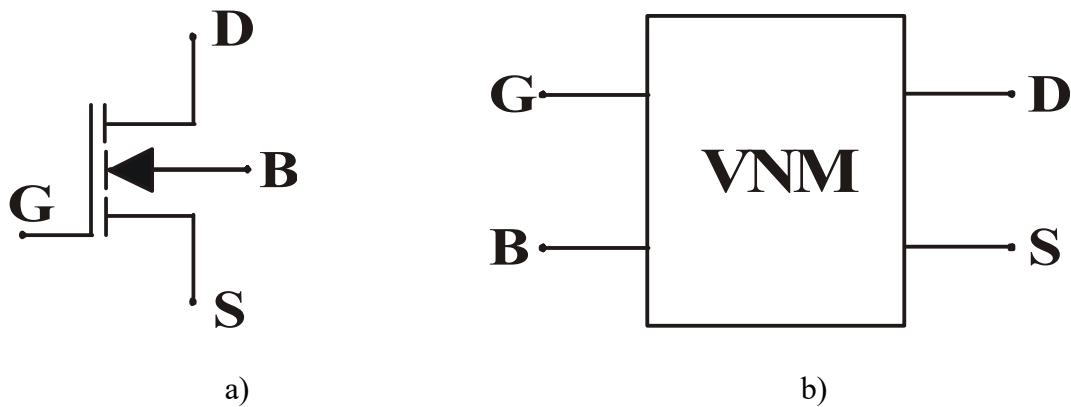
Prvi model MOS tranzistora, tzv. "Level1" model, koji je ugrađen u prvu verziju programa SPICE, bio je vrlo jednostavan. Sa napretkom tehnologije, stalno su razvijani novi modeli od kojih se očekivalo da obuhvate što više različitih efekata, pa su modeli postajali sve složeniji. Prvi modeli su dimenzije ugrađivali direktno u jednačine i smatrali ih nezavisnim promenljivima, što je često dovodilo do znatnih neslaganja sa stvarnim karakteristikama. Poboljšanje je uvedeno kroz BSIM model, kod koga postoji nova zavisnost parametara modela od dimenzija. Kako je i ovaj model imao svoje nedostatke, izvršena je korekcija, i ona je sada raspoloživa u BSIM3v3 modelu.

Sa stalnim napredovanjem tehnologije i alata za simulaciju, potrebno je u model uključiti što je više fizičkih efekata i tehnoloških unapređenja. To dovodi do stalnog proširivanja modela dodatnim matematičkim izrazima, koji često unose i nove parametre. Današnji model MOS tranzistora je veoma složen i ima veoma veliki broj parametara. Pokazuje se da se broj parametara udvostručava svakih deset godina [Li00].

Kada koristimo pristup crne kutije, ne interesuje nas fizika MOS tranzistora, i ne moramo čak da znamo sve njegove parametre. Jedina stvar koju treba uraditi je izmeriti ulazno-izlazne zavisnosti, i onda napraviti aproksimaciju te funkcije, korišćenjem neuronske mreže, naravno. Moguća je i parametrizacija, zato što možemo da koristimo pojedinačni ulaz za svaki parametar, i onda u procesu učenja mreži predstavljamo odgovarajuće podatke. Na taj način, može se uzeti u obzir temperatura ili neki drugi parametar iz okruženja. Nedostatak ovog metoda je zato što kada se model napravi jednom, njegovi parametri (težine i pragovi) se ne mogu više menjati.

U narednom primeru, modelovan je MOS tranzistor sa četiri kraja, Sl. 4.1. U ovom slučaju, struja drejna I_d je funkcija tri promenljive: V_{ds} , V_{gs} , V_{bs} .

Neuronska mreža koja će biti korišćena u ovom primeru je nerekurentna mreža sa jednim skrivenim slojem, tri ulaza (tekuće vrednosti napona drejn-sors, gejt-sors, balk-sors) i jednim izlazom (tekuća vrednost struje drejna). U skrivenom sloju je deset neurona. Tabela 4.1 sadrži težine i pragove svih neurona.



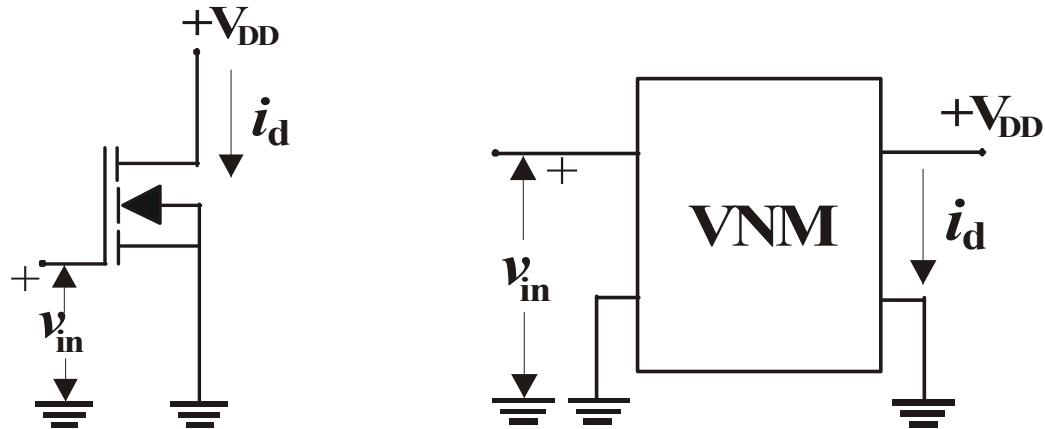
Sl. 4.1 a) MOS tranzistor kao komponenta sa četiri kraja, b) VNM model

Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)	Izlazni neuron (prvi broj označava skriveni neuron)	Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)
1	$w^1(1,1) = 1.53868$ $w^1(2,1) = 2.20026$ $w^1(3,1) = -0.00905447$ $\square^1_1 = -4.64392$	$w^2(1,1) = 4.37141$ $w^2(2,1) = 1.5486$ $w^2(3,1) = 0.964383$ $w^2(4,1) = -0.607057$ $w^2(5,1) = 2.71858$ $w^2(6,1) = 5.94644,$ $w^2(7,1) = -1.56371,$ $w^2(8,1) = -2.13011,$ $w^2(9,1) = 2.49422,$ $w^2(10,1) = -2.51413$ $\square^2_1 = -0.214408$	6	$w^1(1,6) = 2.11242$ $w^1(2,6) = 0.00445756$ $w^1(3,6) = -27.88$ $\square^1_6 = 4.82314$
2	$w^1(1,2) = -26.3385$ $w^1(2,2) = 3.99511$ $w^1(3,2) = -0.0594976$ $\square^1_2 = 1.09692$		7	$w^1(1,7) = -27.88$ $w^1(2,7) = 4.89198$ $w^1(3,7) = -0.0519583$ $\square^1_7 = 0.974386$
3	$w^1(1,3) = 0.626896$ $w^1(2,3) = 5.49623$ $w^1(3,3) = 0.0155087$ $\square^1_3 = 0.0544511$		8	$w^1(1,8) = 0.809658$ $w^1(2,8) = 1.74255$ $w^1(3,8) = -0.0117334$ $\square^1_8 = -1.72154$
4	$w^1(1,4) = 0.288131$ $w^1(2,4) = 9.72067$ $w^1(3,4) = 0.0219793$ $\square^1_4 = -0.496011$		9	$w^1(1,9) = 14.9849$ $w^1(2,9) = -1.12421$ $w^1(3,9) = -0.0202694$ $\square^1_9 = -8.72095$
5	$w^1(1,5) = 0.632619$ $w^1(2,5) = 2.60009$ $w^1(3,5) = -0.0125483$ $\square^1_5 = -2.33687$		10	$w^1(1,10) = 14.8753$ $w^1(2,10) = -1.12863$ $w^1(3,10) = -0.0198736$ $\square^1_{10} = -8.65099$

Tabela 4.1

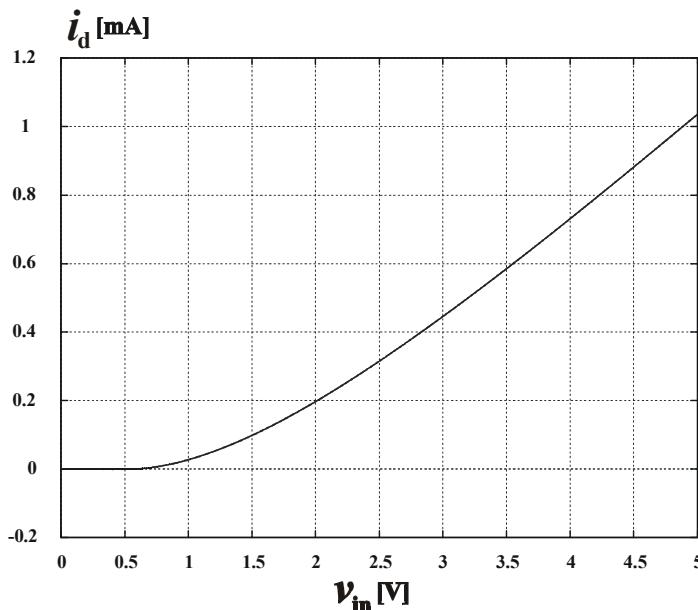
Veoma važno je odrediti signale za pobudu, jer postoji tri različita ulaza, a poželjno je napraviti što više ulaznih kombinacija, kako bi se pokrili svi režimi rada tranzistora. U ovom primeru, sva tri ulaza su pobuđivana naponom u opsegu od $0 \div 5V$.

Verifikacija topologije i složenosti mreže postiže se priključivanjem linearno rastućeg signala na ulaz mreže-gejt ($0\div 5V$), i napona napajanja ($5V$) na priključak drejna (Sl. 4.2).



Sl. 4.2 MOS tranzistor i njegov model

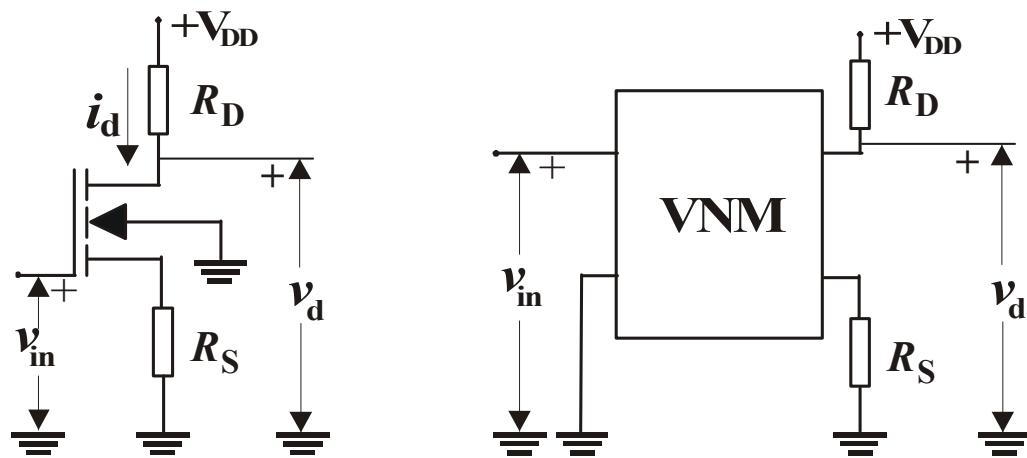
Odzivi originalnog kola i njegovog modela dati su na Sl. 4.3. Karakteristike se preklapaju u svim oblastima rada tranzistora.



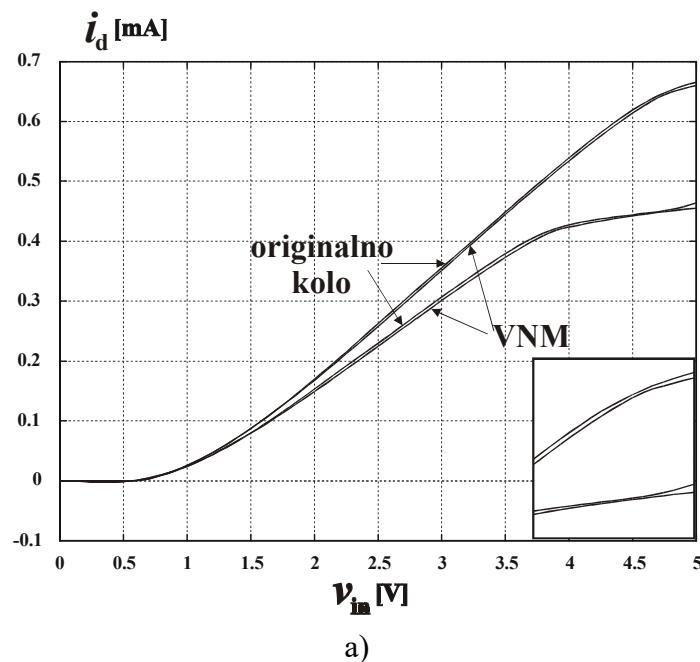
Sl. 4.3 Odzivi originalnog kola i njegovog modela sa Sl. 4.2

Da bi ovako napravljen model tranzistora imao svoju primenu, treba ga koristiti u simulatoru elektronskih kola koji je profesionalno razvijen za simulaciju velikih kola sa različitim tipovima elemenata. Ukoliko želimo da implementiramo neuronsku mrežu u simulator, to treba da bude funkcionalni simulator. U ovom i svim narednim primerima koristi se simulator Alecsis [Gl96].

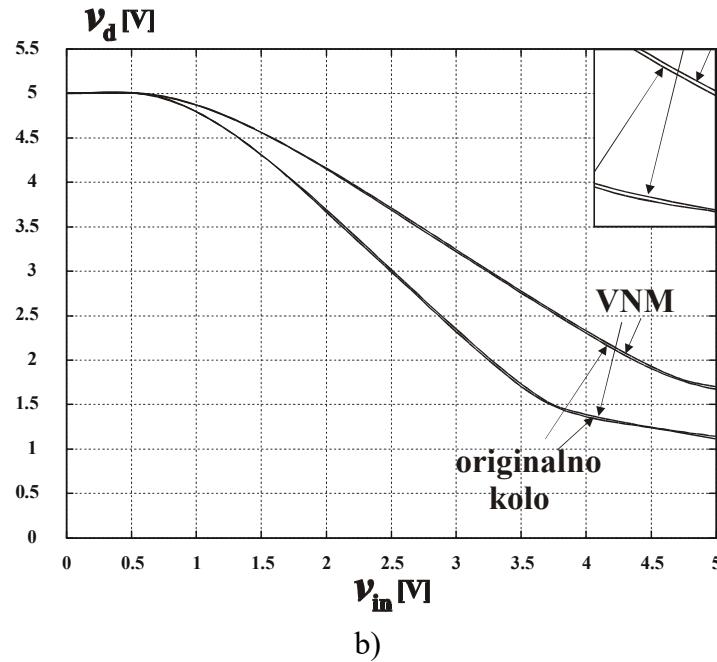
VNM model MOS tranzistora je implementiran u kolo, kao što je prikazano na Sl. 4.4, i prenosne karakteristike obe mreže date su na Sl. 4.5. Prenosne karakteristike su za dve različite vrednosti otpornika R_S and R_D .



Sl. 4.4 MOS tranzistor i njegov model implementirani u električno kolo

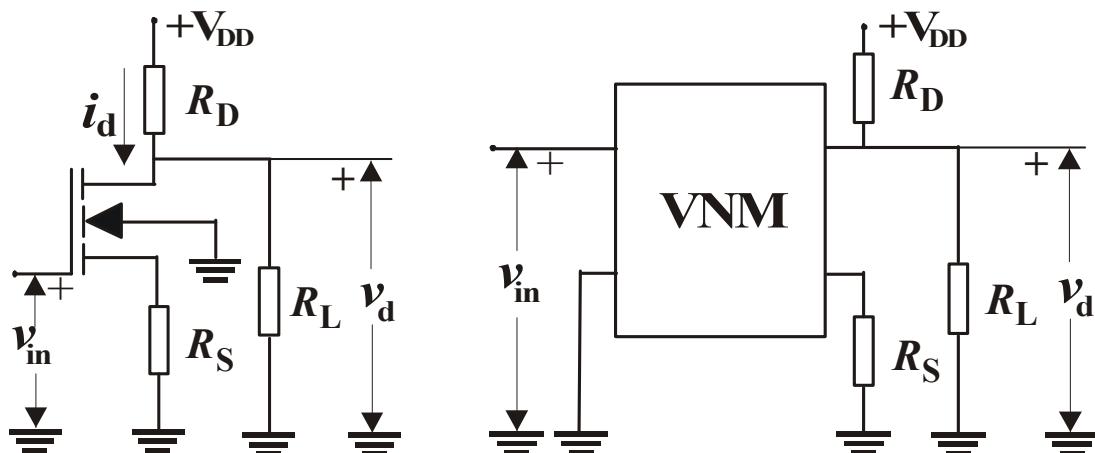


a)

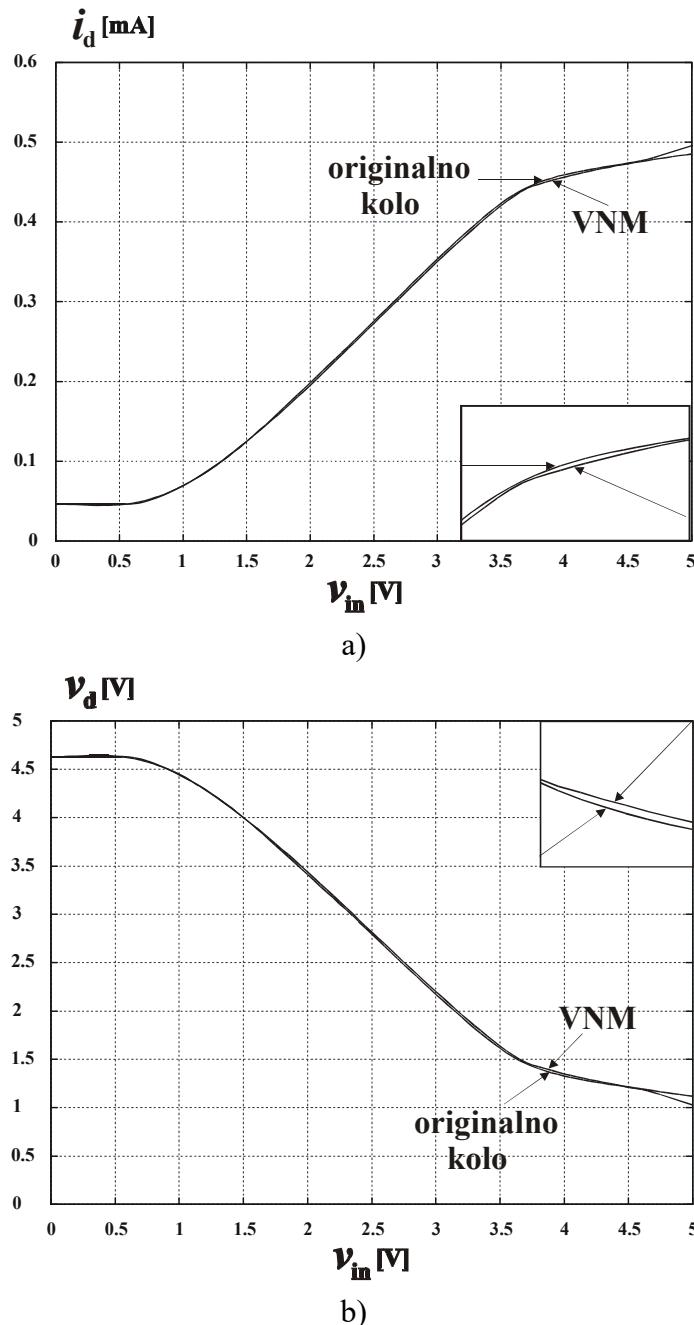


Sl. 4.5 Prenosne karakteristike originalnog kola i njegovog modela sa Sl. 4.4 za dve različite vrednosti otpornika R_S i R_D
a) naponsko-strujna karakteristika, b) naponsko-naponska karakteristika

Još jedna implementacija VNM modela MOS tranzistora prikazana je na Sl. 4.6. MOS tranzistor i njegov model opterećeni su otpornikom. Pokazano je da ovaj model može biti implementiran u složeno kolo, jer može biti opterećen i povezan sa drugim elementima kola. Prenosne karakteristike prikazane su na Sl. 4.7.



Sl. 4.6 MOS tranzistor i njegov model sa otpornikom kao opterećenjem



Sl. 4.7 Odzivi originalnog kola i njegovog modela sa Sl. 4.6
a) naponsko-strujna karakteristika, b) naponsko-naponska karakteristika

4.1.2 Modelovanje nelinearnih otpornih dvoprilaznih elemenata sa karakteristikom koja menja znak nagiba

Chua-ovo kolo je standardni primer za proučavanje pojava haosa. Zapravo, to je jedan od vrlo retkih fizičkih sistema za koji postoji dokaz o postojanju haosa, i kod koga se teorijski, eksperimentalni i rezultati simulacije savršeno slažu [Cr92]. To je haotični atraktor koji sadrži samo jedan nelinearni element, segmentno-linearni otpornik. Kada je kolo priključeno na spoljnu periodičnu pobudu, pokazuje mnoštvo sekvenci bifurkacije, kao što su udvostručavanje periode, dodavanje periode u režimu haosa [Cr92].

U narednom primeru koristićemo VNM za modelovanje nelinearnog otpornika u Chua-ovom kolu. [to se tiče te otpornosti, poznata nam je veza struja-napon, što znači da je struja funkcija kontrolisućeg napona. Za modelovanje ove zavisnosti korišćen je simulator za segmentno-linearnu analizu kola u [Ch88]. Kako ovo nije simulator opšte namene, poželjnije je korišćenje SPICE-like simulatora. Ovde ćemo predstaviti VNM model za ovu segmentno-linearnu karakteristiku. Za novi model, opisan analitičkom funkcijom, više nam nije potreban PWLSPICE.

Kolo prikazano na Sl. 4.8a se zove Chua-ovo kolo. Opisano je sledećim jednačinama:

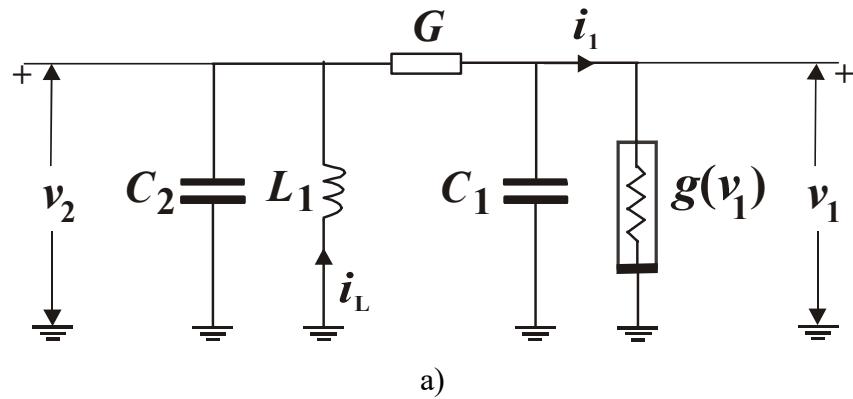
$$C_1 \frac{dv_1}{dt} = G(v_2 - v_1) - g(v_1) \quad (4.1a)$$

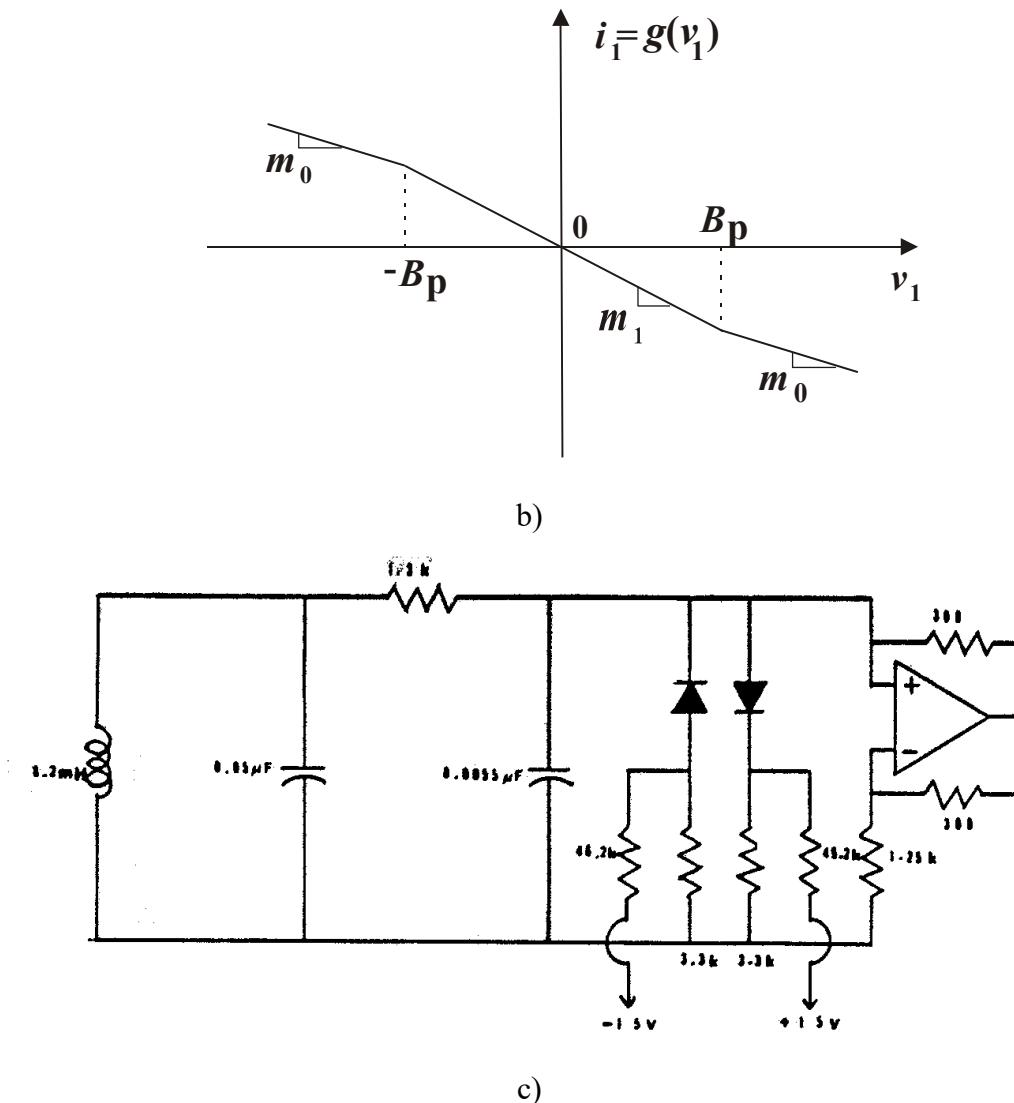
$$C_2 \frac{dv_2}{dt} = G(v_1 - v_2) + i_L \quad (4.1b)$$

$$L_1 \frac{di_L}{dt} = -v_2 \quad (4.1c)$$

gde v_1 , v_2 i i_L označavaju napon na kondenzatoru C_1 , napon na kondenzatoru C_2 i struju kroz kalem L_1 , respektivno, i $g(v_1)$ je segmentno-linearna funkcija sa Sl. 4.8b:

$$g(v_1) = m_0 v_1 + 0.5(m_1 - m_0) |v_1 + B_p| + 0.5(m_0 - m_1) |v_1 - B_p| \quad (4.2)$$





Sl. 4.8 a) Chua-ovo kolo, b) Karakteristika nelinearnog otpornika,
c) Chua-ovo kolo sa realizacijom negativnog otpornika

Prethodno opisano kolo, sa karakteristikom nelinearnog otpornika prikazanom na Sl. 4.8b, poznato je kao "double scroll" atraktor, jer se sastoji od dve ravni uvijene u spiralu sa beskonačno mnogo rotacija [Ma85].

Ovo kolo se ponaša kao haotični atraktor samo ako tačno specificiramo vrednosti parametara ($C_1, C_2, L_1, G, m_0, m_1, B_p$). Jednačina (4.1) sa specificiranim parametrima ima tri ravnotežna položaja. Svaki ravnotežni položaj ima jednu realnu i dve kompleksne karakteristične vrednosti.

Tipična putanja u atraktoru rotira oko jednog od dva ravnotežna položaja [Ma85], prepostavimo oko gornjeg, u smeru suprotnom kazaljki na satu u odnosu na koordinatni sistem sa levom orijentacijom. Nakon svake rotacije putanja se udaljava od ravnotežnog položaja do određenog vremena nakon koga postoje dve mogućnosti: 1) putanja se vraća u položaj bliži ravnotežnom položaju i ponavlja sličan proces, 2) putanja se ne vraća nazad u tačku blisku ravnoteži već se spušta nadole po spiralnoj putanji i "silazi" u niži deo atraktora. Tačka u koju se spušta je blizu donjeg ravnotežnog položaja i onda počinje rotacija u smeru suprotnom kazaljki na satu oko donjeg kruga. Nakon ovoga, ponašanje je

slično onom u gornjem delu atraktora, osim što nakon nekoliko rotacija oko donjeg ravnotežnog položaja počinje “penjanje”.

Teorijski prikaz haotičnog ponašanja dat je u [Ma85]. Paralelna veza C_2 and L_1 formira mehanizam oscilatora bez gubitaka u (v_2 - i_L)-ravni, gde odvodnost G obezbeđuje interakciju između (C_2 , L)-oscilatorne komponente i aktivnog otpornika zajedno sa C_1 . Aktivni otpornik je odgovoran za haotično ponašanje kola. Da je otpornik pasivan, sva rešenja bi se približila globalnom stabilnom ravnotežnom položaju. Kako je $g(v_1)$ aktivno, ono stalno daje energiju spoljnem kolu. Haotične putanje imaju svojstvo privlačenja zbog snage koja se troši na pasivnom elementu.

Postoji mnogo problema vezanih za realizaciju Chua-ovog atraktora zbog nelinearne, negativne otpornosti prikazane na Sl. 4.8b. U literaturi je prikazano mnogo različitih realizacija, koje obično sadrže operacione pojačavače [Ma85], negativne konvertore impedanse [Ba88], CMOS kola [Cr92], itd. Jedna od realizacija prikazana je na Sl. 4.8c [Ma85].

Osnovni problem je realizovati segmentno-linearnu karakteristiku otpornika. U stvari, u ponuđenim rešenjima kriva je glatka u okolini tačaka gde se nagib menja (B_p , $-B_p$). Ovde ćemo prikazati novu aproksimaciju zasnovanu na veštačkim neuronskim mrežama.

Chua-ovo kolo je već modelovano neuronskom mrežom [Ca98]. U tom slučaju je neuronskom mrežom modelovano celo kolo, uključujući sve elemente (C_1 , C_2 , L_1 , G). To znači da su vrednosti elemenata fiksne za određenu mrežu. Isto tako, ulazi i izlazi mreže su naponi i struje kola, pa je datu ćeliju vrlo teško implementirati u mrežu koja se sastoji od više takvih ćelija.

U rešenju predstavljenom u narednom primeru [Li02b], modelovana je samo negativna otpornost. U tom slučaju možemo da menjamo vrednosti elemenata kola i dobijemo različite tipove orbita, stabilne ili nestabilne [Ma85], i različite tipove atraktora.

Kada modelujemo karakteristiku sa Sl. 4.8a, moramo da odredimo topologiju, složenost mreže, i da pronađemo parametre neuronske mreže koja treba da se ponaša isto kao negativni otpornik. Takođe, moramo da odredimo signal za pobudu otpornika, jer su nam potrebni ulazno-izlazni parovi za obučavanje mreže.

Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)	Izlazni neuron (prvi broj označava skriveni neuron)
1	$w^1(1,1) = 1.39225$ $\square^1_1 = -2.09186$	$w^2(1,1) = 8.97551$ $w^2(2,1) = 2.35162$ $w^2(3,1) = 4.6271$ $w^2(4,1) = 5.43947$ $\square^2_1 = -9.22116$
2	$w^1(1,2) = -4.56027$ $\square^1_2 = 0.348709$	
3	$w^1(1,3) = -3.72735$ $\square^1_3 = 3.65705$	
4	$w^1(1,4) = 0.531847$ $\square^1_4 = 0.467806$	

Tabela 4.2

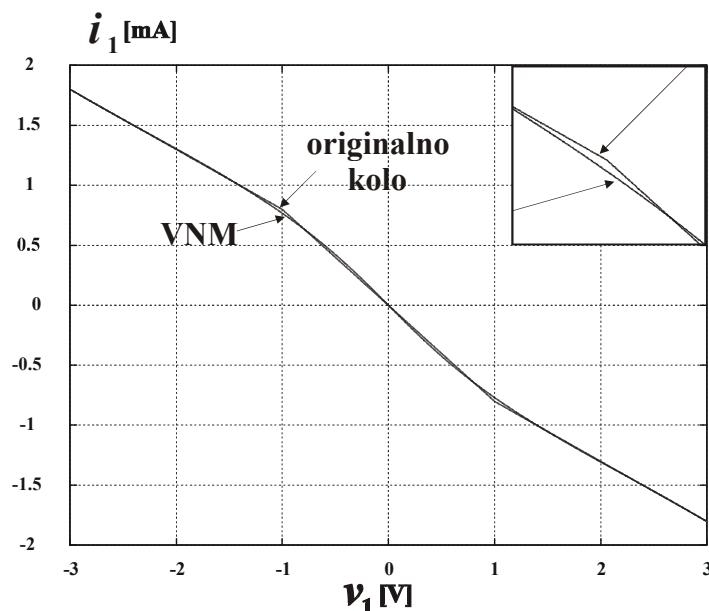
Kako je karakteristika otporna, koristimo nerekurentnu mrežu sa jednim skrivenim slojem. Struja je nelinearna funkcija kontrolišućeg napona, $i_1=g(v_1)$, pa se uzima linearna promena pobudnog napona, kako bi se opisalo ponašanje otpornosti.

Parametri korišćeni u relaciji (4.2) za segmentno-linearnu karakteristiku su:

$$m_0 = -5 \cdot 10^{-4}, \quad m_1 = -8 \cdot 10^{-4}, \quad B_p = 1$$

Najpre se simulira negativni otpornik. Za opis karakteristike (4.2) potreban je funkcionalni simulator. Promena napona je linearna, kao što je već napomenuto, u opsegu $-3V \div 3V$. Za dati primer je bio potreban jedan ulazni, četiri skrivena i jedan izlazni neuron. Tabela 4.2 sadrži težine i pragove svih neurona.

Zavisnost napon-struja modela prikazana je na Sl. 4.9 zajedno sa originalnom zavisnošću napon-struja koja je korišćena pri obučavanju. Zapaža se odlično poklapanje dobijenih karakteristika.

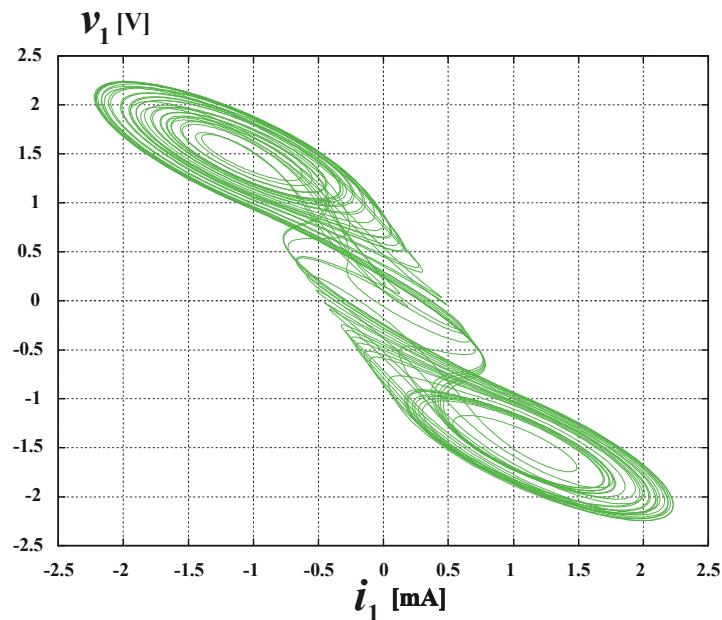


Sl. 4.9 Karakteristika nelinearnog otpornika sa Sl. 4.8 opisana u funkcionalnom simulatoru i VNM model

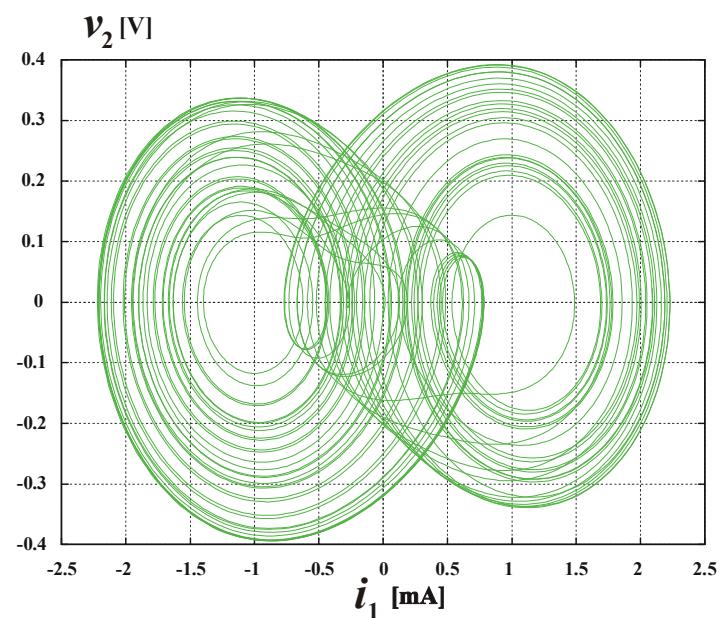
Da bismo pokazali dobrotu aproksimacionog postupka i sposobnost generalizacije modela, VNM je implementirana u "double scroll" kolo sa sledećim skupom parametara: (Sl. 4.8a):

$$C_1 = 0.0055\mu F, \quad L_1 = 7.07mH, \quad C_2 = 0.0495\mu H, \quad G = 7mS.$$

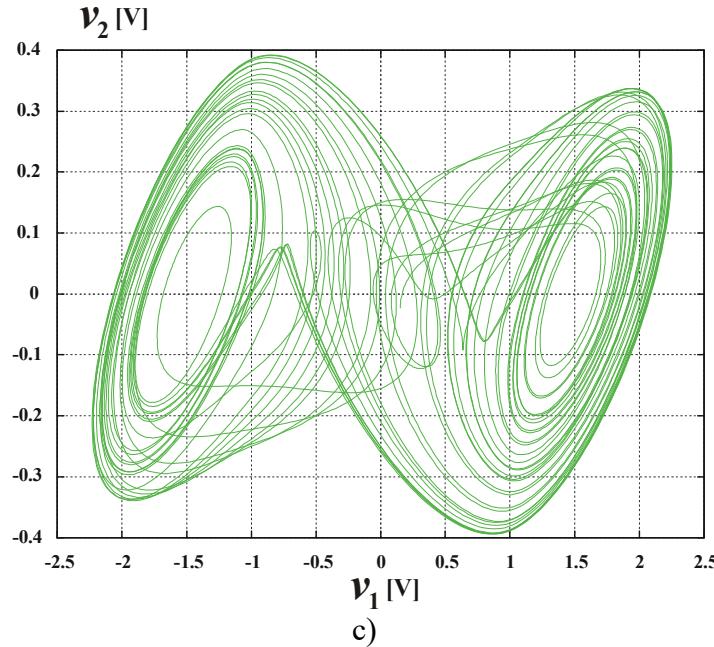
Projekcije u tri različite ravni prikazane su na Sl. 4.10.



a)



b)



Sl. 4.10 “Double scroll” atraktor sa VNM modelom koji se ponaša kao negativni otpornik
 a) Projekcija u ($i_1 - v_1$) -ravni, b) Projekcija u ($i_1 - v_2$) - ravni,
 c) Projekcija u ($v_1 - v_2$) - ravni

Ako promenimo vrednosti elemenata u sistemu (4.1), dobijamo potpuno različit skup parametara ($C_1, C_2, L_1, G, m_0, m_1, B_p$), koji zajedno sa istom karakteristikom (4.2) čini novi atraktor sa tri realne karakteristične vrednosti. Ovaj atraktor je poznat kao “double hook” atraktor [Ba88]. Ime “double hook” je izabранo kako bi skrenulo pažnju na geometrijsku strukturu preseka, koji liči na dve suprotno usmerene kuke, spojene sa jedne strane.

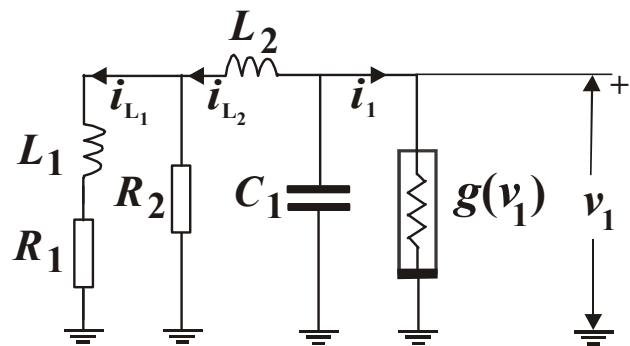
Jedna realizacija “double hook” atraktora data je na Sl. 4.11a [Ba88], a karakteristika nelinearnog otpornika je na Sl. 4.11b. Na Sl. 4.11c prikazana je detaljna realizacija negativnog otpornika [Ba88]. Ovaj atraktor je dobijen definisanjem novih promenljivih i novih parametara, pa je kolo opisano sa (4.3):

$$C_1 \frac{dv_1}{dt} = -i_{L2} - g(v_1) \quad (4.3a)$$

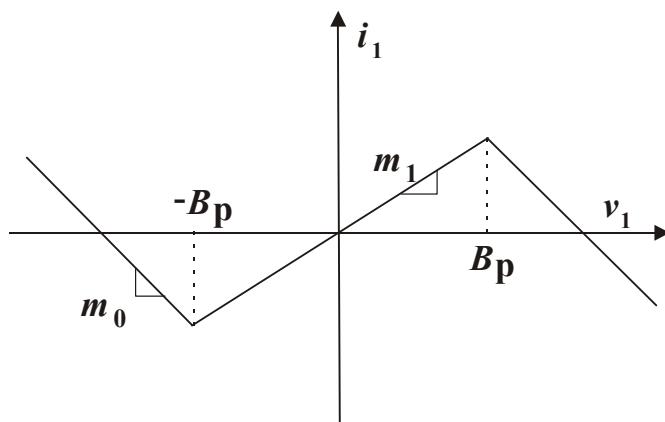
$$L_2 \frac{di_{L2}}{dt} = v_1 - R_2 \cdot (i_{L2} - i_{L1}) \quad (4.3b)$$

$$L_1 \frac{di_{L2}}{dt} = R_2 \cdot (i_{L2} - i_{L1}) + R_1 \cdot i_{L1} \quad (4.3c)$$

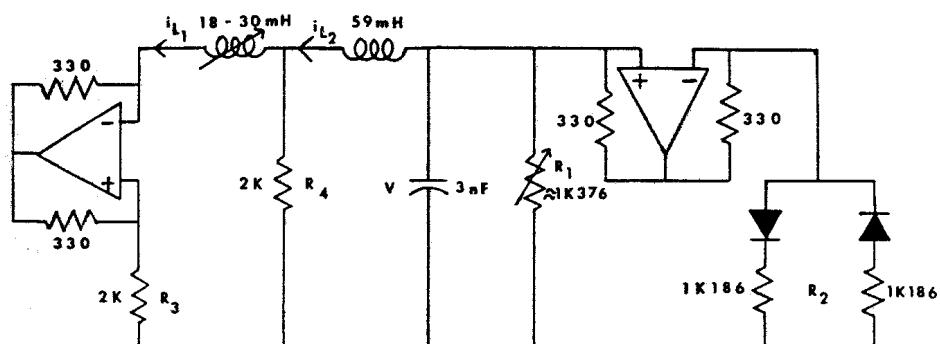
Karakteristika nelinearnog otpornika u “double hook” atraktoru se razlikuje od one kod “double scroll” atraktora, jer je u jednom delu negativna, a u drugom pozitivna. Postoji više vrednosti napona za istu vrednost struje, tj. funkcija je višeznačna, pa treba da upamtimo i neke prethodne vrednosti struje kako bismo specificirali određenu koordinatu. Zato moramo da koristimo nerekurentnu mrežu sa vremenskim kašnjenjem kada modelujemo ovakvu karakteristiku.



a)



b)



c)

Sl. 4.11 a) "Double hook" kolo, b) Karakteristika nelinearnog otpornika,
c) "Double hook" kolo sa realizovanim negativnim otpornikom

Stvarne vrednosti parametara korišćene u opisu segmentno-linearne karakteristike su:

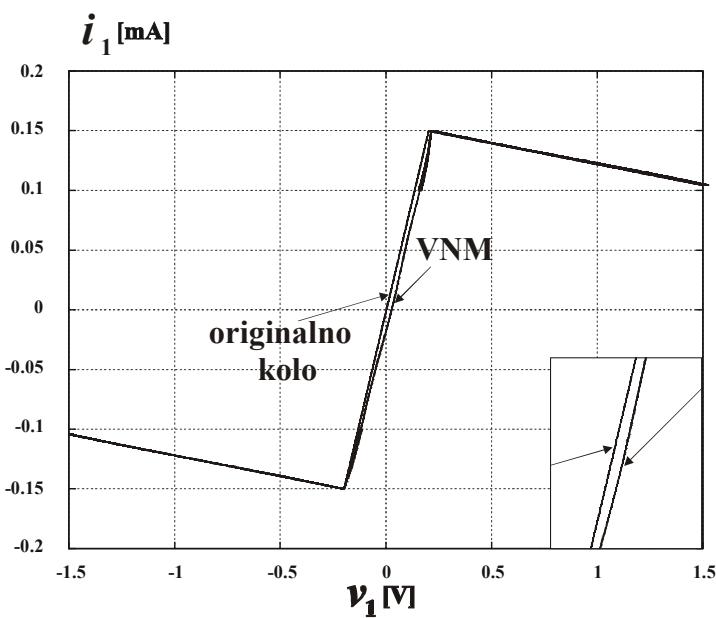
$$m_0 = -0.035 \cdot 10^{-3}, \quad m_1 = 0.75 \cdot 10^{-3}, \quad B_p = 0.2$$

Za ovaj primer, uzeto je tri neurona u ulaznom sloju (tekuća vrednost struje i vrednosti struje iz dva prethodna vremenska trenutka), pet neurona u skrivenom sloju i jedan izlazni neuron. Tabela 4.3 sadrži težine i pragove svih neurona.

Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)	Izlazni neuron (prvi broj označava skriveni neuron)
1	$w^1(1,1) = 607.03$ $w^1(2,1) = -32.4388$ $w^1(3,1) = -570.743$ $\square \square^1_1 = -2.36108$ $w^2(1,1) = 41.0536$ $w^2(2,1) = -10.0293$ $w^2(3,1) = -42.1979$ $w^2(4,1) = -40.916$ $w^2(5,1) = 31.9345$ $\square \square^2_1 = 10.4297$	
2	$w^1(1,2) = 1926.41$ $w^1(2,2) = 307.328$ $w^1(3,2) = -2237.15$ $\square \square^1_2 = -0.140066$	
3	$w^1(1,3) = -583.389$ $w^1(2,3) = -130.72$ $w^1(3,3) = 717.496$ $\square \square^1_3 = -1.31136$	
4	$w^1(1,4) = 545.736$ $w^1(2,4) = 62.5043$ $w^1(3,4) = -603.066$ $\square \square^1_4 = -3.64036$	
5	$w^1(1,5) = -647.999$ $w^1(2,5) = 19.4936$ $w^1(3,5) = 633.8$ $\square \square^1_5 = -3.30543$	

Tabela 4.3

Promena napona je linearna, kao što je već spomenuto, a napon se menja u opsegu $-1.5V \div 1.5V$. Karakteristika napon-struja modela prikazana je na Sl. 4.12 zajedno sa originalnom karakteristikom korišćenom pri obučavanju. Odlično slaganje karakteristika je dobijeno, bez glatkih prelaza na mestima gde se nagib menja.

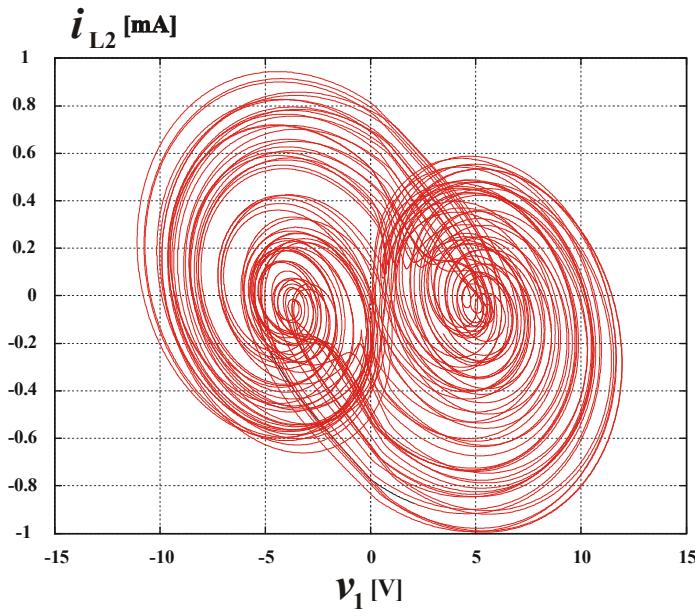


Sl. 4.12 Karakteristika nelinearnog otpornika sa Sl. 4.11 opisana u funkcionalnom simulatoru i VNM model

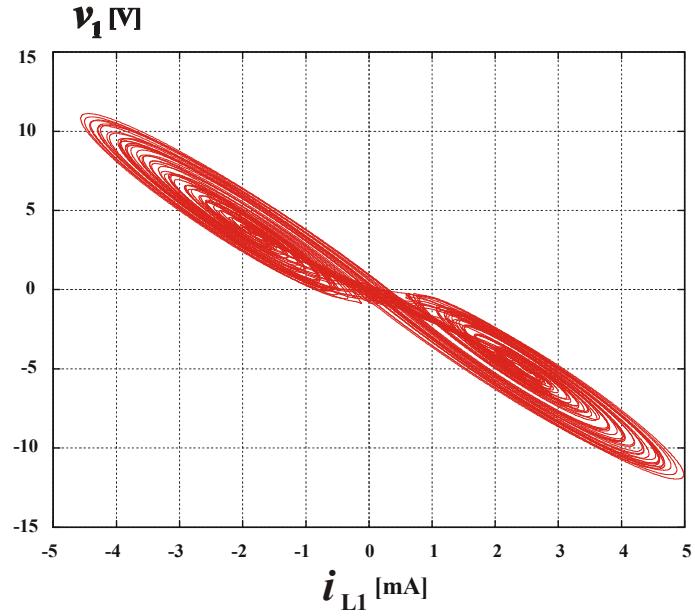
Dobrota aproksimacije i mogućnosti generalizacije mreže pokazane su tako što je ona implementirana u “double hook” kolo sa sledećim skupom parametara:

$$C_1 = 3nF, L_1 = 16.2mH, L_2 = 59mH, R_1 = -2k\Omega, R_2 = 2k\Omega$$

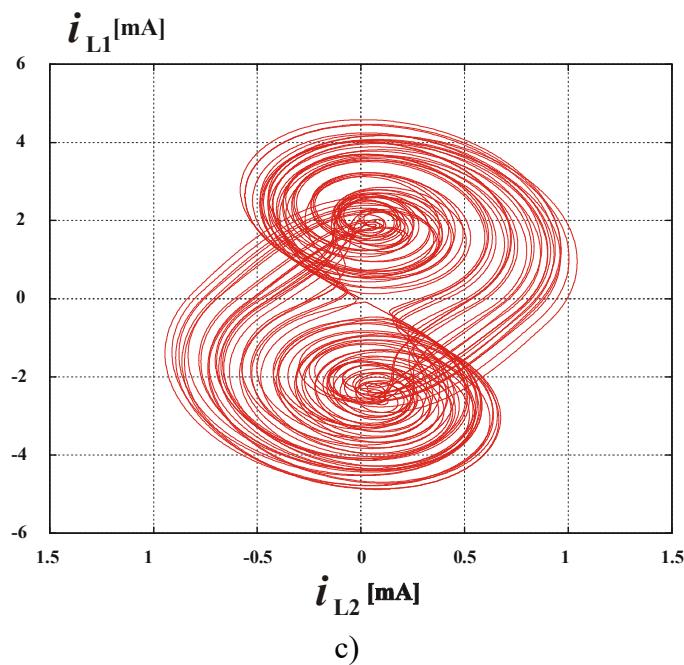
Projekcije u tri različite ravni prikazane su na Sl. 4.13.



a)



b)



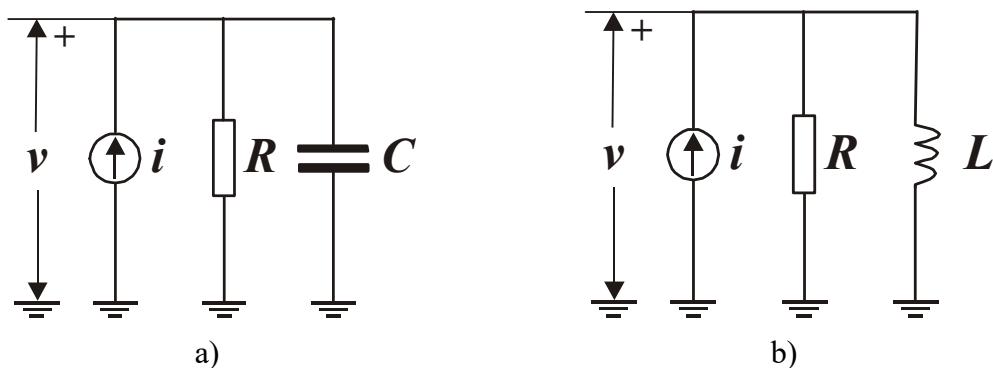
Sl. 4.13 "Double hook" atraktor sa VNM modelom koji se ponaša kao negativni otpornik
a) Projekcija u ($v_1 - i_{L2}$) -ravni,
b) Projekcija u ($i_{L1} - v_1$) - ravni,
c) Projekcija u ($i_{L2} - i_{L1}$) ravni

4.2 Modelovanje linearnih dinamičkih kola

U prethodnim primerima modelovana su otporna svojstva elektronskih kola. Generisanjem modela za linearna dinamička kola verifikovaćemo postupak modelovanja, i proveriti topologiju i složenost neuronske mreže. Ukoliko modeli pokazuju dobra svojstva, iskustva i rezultati biće upotrebljeni za modelovanje nelinearnih dinamičkih kola.

Neuronske mreže su prvi put korišćene za modelovanje linearnih, dinamičkih, dvoprilaznih mreža u [Il00]. Opisana je ideja modelovanja, i kao primer razmatrani su filter propusnik niskih frekvencija (Sl. 4.14a), filter propusnik opsega (Sl. 4.17) i filter propusnik visokih frekvencija (Sl. 4.14b).

I u ovom slučaju treba rešiti probleme vezane za topologiju i složenost mreže i za sintezu pobudnog signala.



Sl. 4.14 a) Nisko-propusni filter, b) Visoko-propusni filter

Dinamička kola sa Sl. 4.14. imaju memoriska svojstva, pa se modeluju rekuretnom neuronskom mrežom. Vremenska analiza dinamičkih kola podrazumeva da su vrednosti napona i struja u kolu zavisni od prethodnih vremenskih trenutaka. Zato koristimo mrežu sa vremenskim kašnjenjem. Imajući u vidu složenost kola, dovoljna su samo tri ulaza: tekuća vrednost ulaznog signala, i vrednosti ulaznog i izlaznog signala iz prethodnog trenutka.

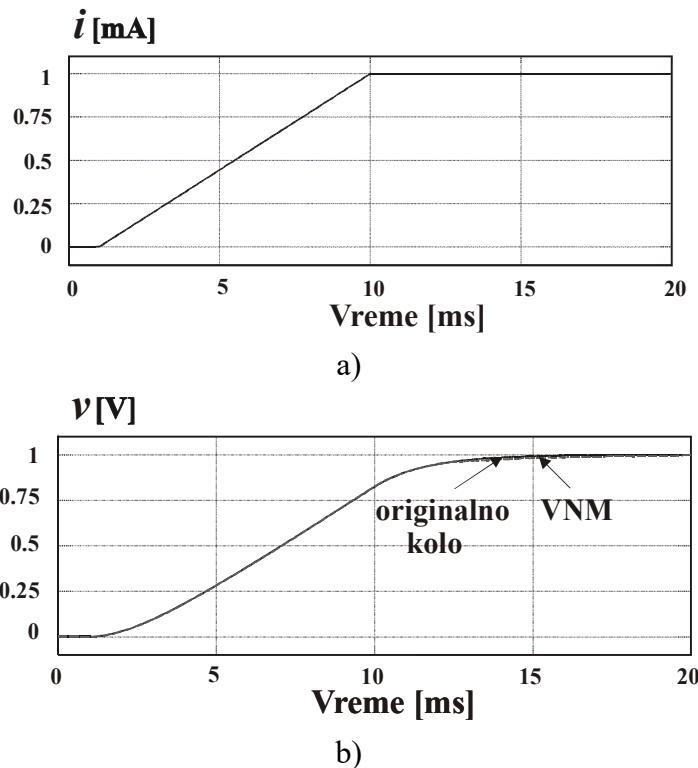
Pobudni signal treba da obuhvati ponašanje kola u frekvencijskom opsegu od interesa. Kao što je već razmotreno, frekvencijski modulisana sinusoida je pogodna za ovu svrhu. Signal koji se koristi u ovim primerima je:

$$i(t) = \sin[2\pi(f_0 + k \cdot \exp(t)) \cdot t] \quad (4.4)$$

Eksponencijalna promena frekvencije je pogodna u nekim situacijama kada je potrebna sporija promena na nižim frekvencijama.

Kao prvi primer, modelovano je kolo sa Sl. 4.14a. Pobuda je strujna, a odziv kola je napon na paralelnoj RC grani. Vrednosti elemenata kola su: $R = 1\Omega$; $C = 1.59\text{mF}$. Frekvencija sinusoide je menjana u opsegu 5Hz - 1kHz. Ostale frekvencije su van propusnog opsega kola, pa zato i nisu od interesa.

Dobijena neuronska mreža se testira tako što se koristi signal kojim mreža nije obučavana. Jedan takav signal je linearno rastući signal. Pobuda i odziv mreže i originalnog kola u tom slučaju prikazani su na Sl.4.15.

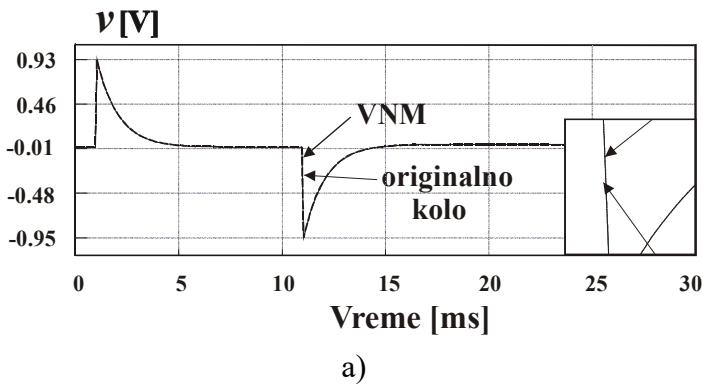


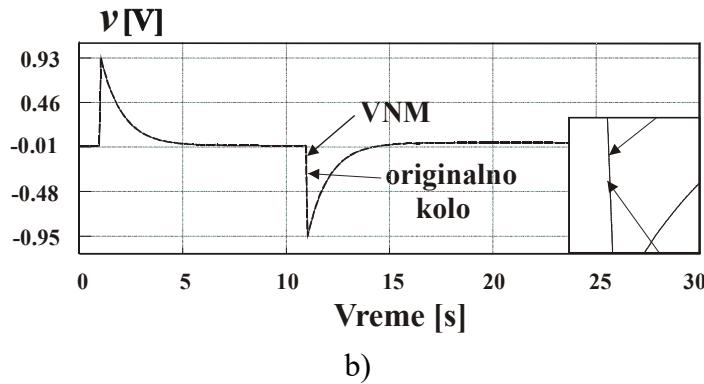
Sl. 4.15 a) Pobudni signal b) Odziv kola
sa Sl. 4.14a i odziv modela

Primećuje se da je maksimalno neslaganje odziva u onim vremenskim trenucima kada je ulazni signal konstantan u vremenu. U tom slučaju izlazni signal zavisi samo od svojih prethodnim vrednostima. To nam ukazuje da bismo dobili bolje slaganje odziva ukoliko bismo koristili više ulaza u mrežu, tj. izlazne signale većeg broja prethodnih vremenskih trenutaka.

Naredni primer pokazuje postupak modelovanja filtra propusnika visokih frekvencija, Sl. 4.14b. I u ovom slučaju pobuda je strujna, a napon na paralelnoj RL grani je odziv kola. Vrednosti elemenata kola su: $R = 1\Omega$; $L = 1\text{mH}$.

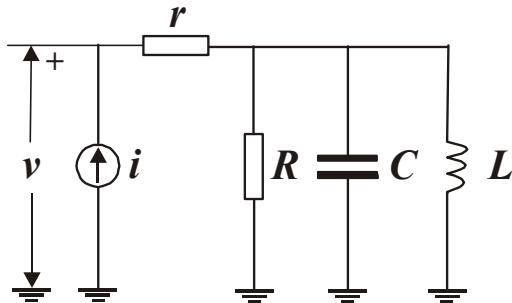
U ovom slučaju neuronska mreža je testirana dovođenjem pravougaonog impulsa na ulaz kola. Pobuda i odziv neuronske mreže i originalnog kola prikazani su na Sl. 4.16. Očigledno je da je maksimalno neslaganje odziva originalnog kola i neuronske mreže na oštrim ivicama ulaznog signala, i ovo neslaganje se iskazuje kao kašnjenje izlaznog signala.





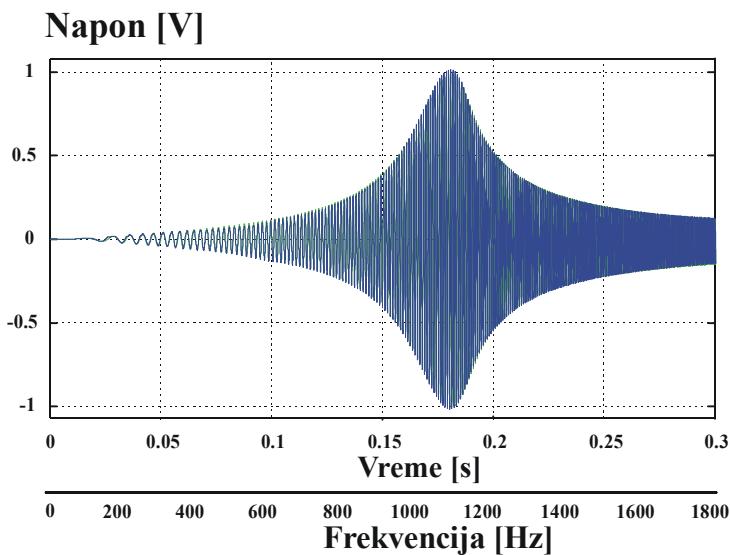
Sl. 4.16 a) Pobudni pravougaoni signal b) Odziv kola sa Sl. 4.14b i odziv modela

Modelovanje antirezonantnog kola (Sl. 4.17) je još jedan primer modelovanja linearnih dinamičkih kola, u ovom slučaju, to je modelovanje kola propusnika opsega frekvencija [An02].



Sl. 4.17 Antirezonantno kolo

Za ovaj primer, uzeto je pet neurona u ulaznom sloju jer je kolo složenije, a i da bi se dobila manja greška aproksimacije (tekuća vrednost ulaznog signala, i vrednosti ulaznog i izlaznog signala iz dva prethodna trenutka), četiri neurona u skrivenom sloju i jedan izlazni neuron.

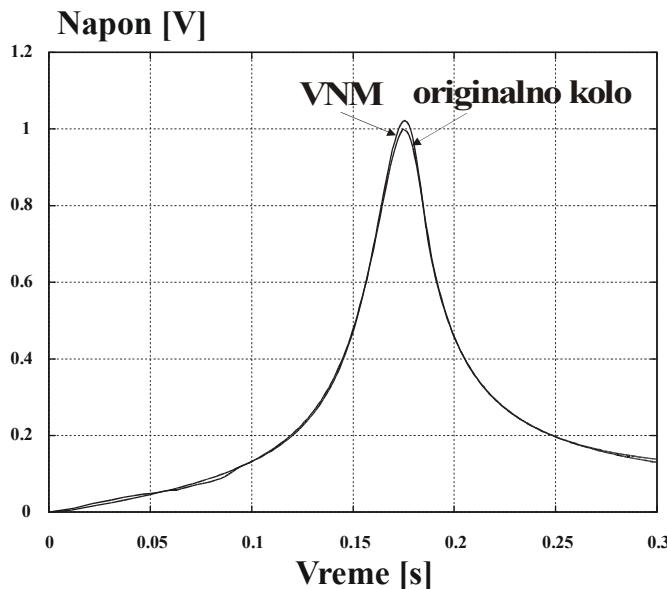


Sl. 4.18 Odzivi originalnog kola sa Sl. 4.17 i VNM modela

Tabela 4.4 sadrži težine i pragove svih neurona. U ovom primeru, pobudni strujni signal ima linearnu promenu frekvencije, u opsegu 0Hz-1.8kHz. Rezonantna frekvencija kola je 1kHz. Elementi kola su: $R=1k\Omega$; $C=1\mu F$, $L=25.3mH$, $r=1\Omega$.

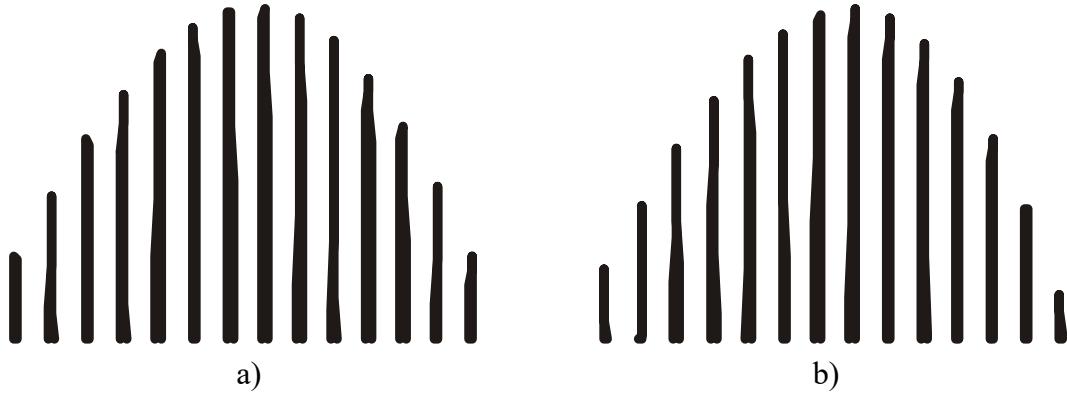
Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)	Izlazni neuron (prvi broj označava skriveni neuron)
1	$w^1(1,1) = 1.32001$ $w^1(2,1) = -2.41539$ $w^1(3,1) = 1.11798$ $w^1(4,1) = 0.579169$ $w^1(5,1) = -0.062461$ $\square \square^1_1 = 0.305361$	$w^2(1,1) = 9.24176$ $w^2(2,1) = 0.00588212$ $w^2(3,1) = -2.2333$ $w^2(4,1) = 0.722262$ $\square \square^2_1 = -4.08596$
2	$w^1(1,2) = 6.8985$ $w^1(2,2) = -1.51301$ $w^1(3,2) = -6.56289$ $w^1(4,2) = 5.10446$ $w^1(5,2) = -1.79725$ $\square \square^1_2 = 0.13046$	
3	$w^1(1,3) = 3.70202$ $w^1(2,3) = -6.43451$ $w^1(3,3) = 2.8142$ $w^1(4,3) = -1.03855$ $w^1(5,3) = 1.47191$ $\square \square^1_3 = 0.293946$	
4	$w^1(1,4) = -12.0013$ $w^1(2,4) = 24.2824$ $w^1(3,4) = -12.3424$ $w^1(4,4) = 2.81037$ $w^1(5,4) = -1.24556$ $\square \square^1_4 = -2.77371$	

Tabela 4.4



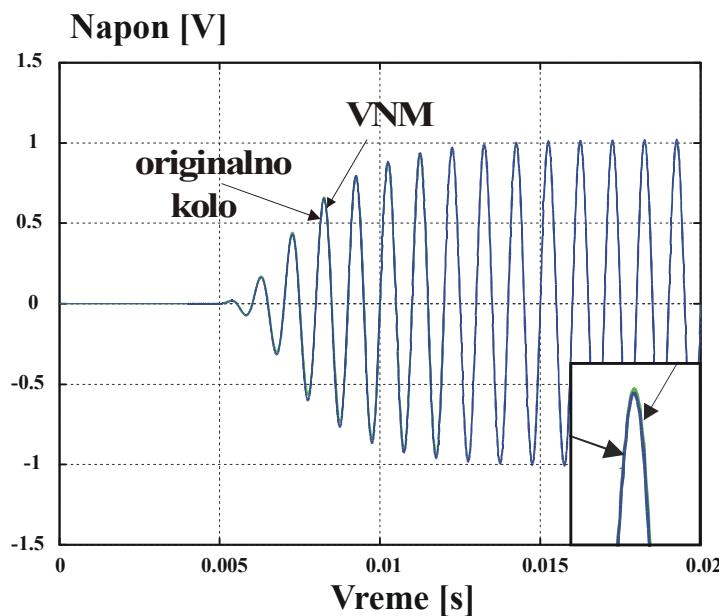
Sl. 4.19 Odzivi originalnog kola sa Sl. 4.17 i VNM modela (prikazane su samo envelope pozitivnih poluperioda)

Kako je ovo kolo složenije, prvo treba verifikovati sintezu topologije i složenosti mreže, i to tako što ćemo neuronsku mrežu pobuditi signalom koji je korišćen u procesu obučavanja. Odzivi originalnog kola i modela su na Sl. 4.18. Da bismo bolje uočili rezultate, Sl 4.19 prikazuje samo anvelope pozitivnih poluperioda, dok Sl 4.20 prikazuje same vrhove sinusoida u okolini rezonantne frekvencije.



Sl. 4.20 Odzivi originalnog kola sa Sl. 4.17 a), i VNM modela b)
za frekvencije bliske rezonantnoj (prikazani su samo vrhovi pozitivnih poluperioda)

Mogućnosti generalizacije ove mreže testirane su tako što je ona pobuđena signalom koji nije korišćen u procesu njenog obučavanja. Poželjno je da testni signal ima spektralne komponente i van spektra signala koji je korišćen za obuku mreže. Jedan takav primer je sinusni signal amplitudski modulisan odskočnom (trapeznom) funkcijom u koju je ugrađeno kašnjenje. Odzivi originalnog kola i modela zasnovanog na VNM dati su na Sl. 4.21. Uočava se saglasnost odziva što ohrabruje da se pristup primeni i za modelovanje nelinearnih dvopola.

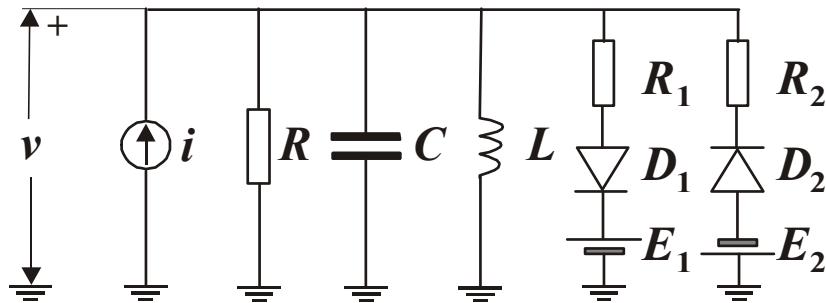


Sl. 4.21 Odzivi originalnog kola sa Sl. 4.17 a), i VNM modela b)
na novu pobudu

4.3 Modelovanje nelinearnih dinamičkih kola

Kada modelujemo nelinearna kola, nikada nismo sigurni šta da očekujemo, tj. sa kojom vrstom nelinearnosti ćemo se suočiti. Tako se problemi povećavaju, jer je mnogo složenije odrediti topologiju i složenost neuronske mreže i pronaći signal za pobudu koji će obuhvatiti sve nelinearnosti komponente. Motivacija za istraživanje u ovoj oblasti vezana je za razvijanje modela i optimizaciju električnog okruženja aktuatora [Ba97]. Primena koncepta crne kutije pa time i VNM od posebnog je interesa za modelovanje senzora i aktuatora iz više razloga. Obično je situacija takva da nisu do detalja spoznati fizički fenomeni koji stoe u osnovi rada ovakvih dvopola, a u isto vreme, brzina izlaska na tržiste je imperativ za opstanak komponente. Zato se zahteva metod modelovanja koji će biti primjenjen odmah na bazi onih znanja koja su raspoloživa.

Međutim, da bismo objasnili sam princip modelovanja, biće prikazan primer kola sa poznatom strukturom, malo složenijeg od onog u prethodnim primerima. To je antirezonantno kolo (Sl. 4.22) paralelno vezano nelinearnom kolu (koje se sastoji od elemenata R_1 , D_1 , E_1 , R_2 , D_2 , E_2) čija je statička karakteristika prikazana na Sl. 4.23. Kolo je analizirano za struje u opsegu $-1\text{mA} \div 1\text{mA}$.

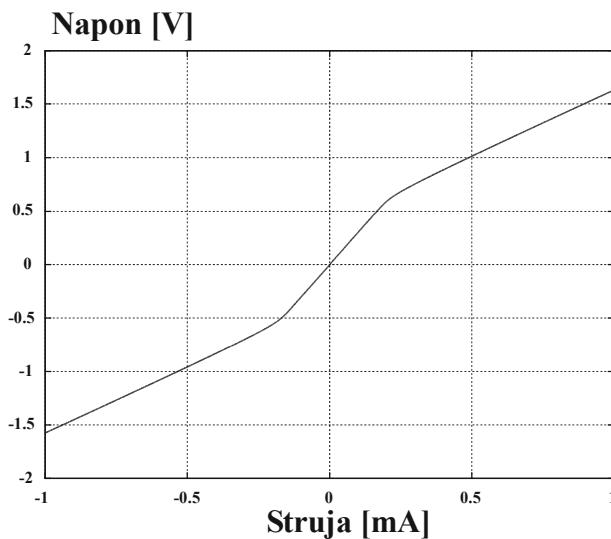


Sl. 4.22 Primer nelinearnog dinamičkog kola

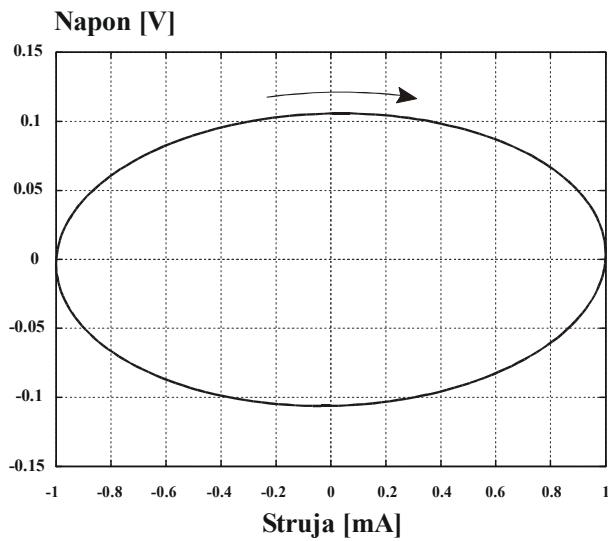
Da bismo u potpunosti shvatili prirodu problema koji se razmatra, ponavljamo da je modelovanje ovog kola u stvari aproksimacija zavisnosti struja-napon. To nije tako jednostavno kao što izgleda, pa su radi bolje predstave na Sl. 4.24 prikazane tri zavisnosti struja-napon kola za različite frekvencije.

Sl. 4.24a predstavlja zavisnost kada se $i(t) = (1\text{mA}) \cdot \sin((f_r / 2) \cdot t)$ koristi kao pobuda, pri čemu je $f_r = 1/2\pi\sqrt{LC}$. Na Sl. 4.24b pobuda je $i(t) = (1\text{mA}) \cdot \sin(f_r \cdot t)$, dok je na Sl. 4.24c frekvencija ponovo udvostručena: $i(t) = (1\text{mA}) \cdot \sin((2f_r) \cdot t)$. Na osnovu ovih zavisnosti vidimo da je problem aproksimacije teško tačno utvrditi, pa je zato potreban frekvencijski modulisani signal da bi obuhvatio sve zavisnosti struja-napon.

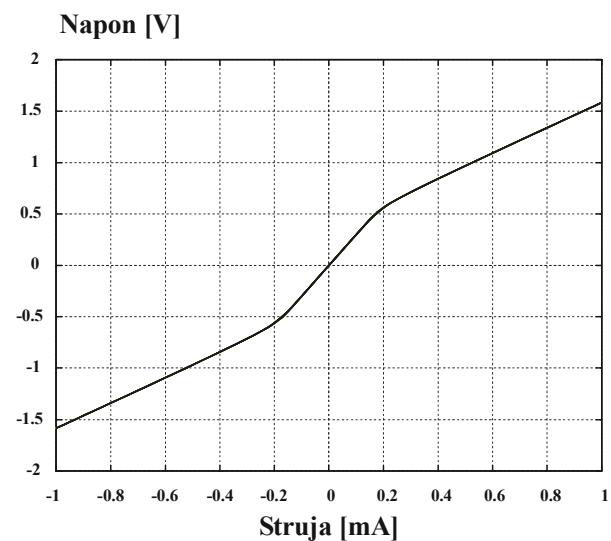
Primetimo da se na Sl. 4.24a smer poklapa sa smerom kazaljke na satu, dok je na Sl. 4.24c smer suprotan. Takođe, odziv prikazan na Sl. 4.24b je u stvari statička karakteristika dela kola sa Sl. 4.22, prikazana na Sl. 4.23.



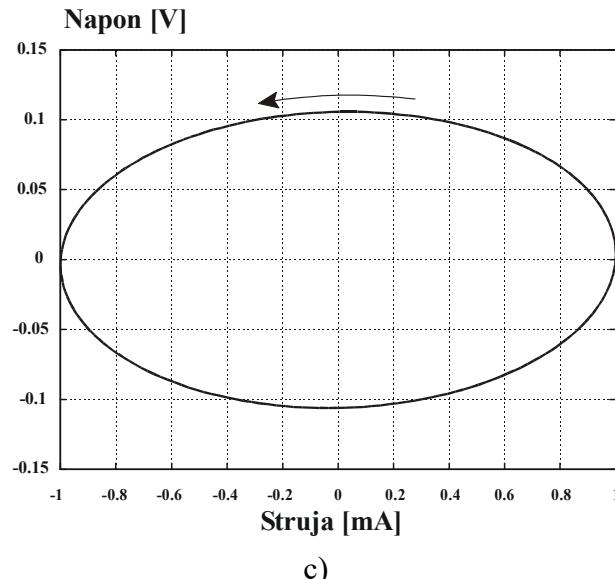
Sl. 4.23 Statička karakteristika dela kola sa Sl. 4.22 koje sadrži elemente $R_1, D_1, E_1, R_2, D_2, E_2$



a)



b)



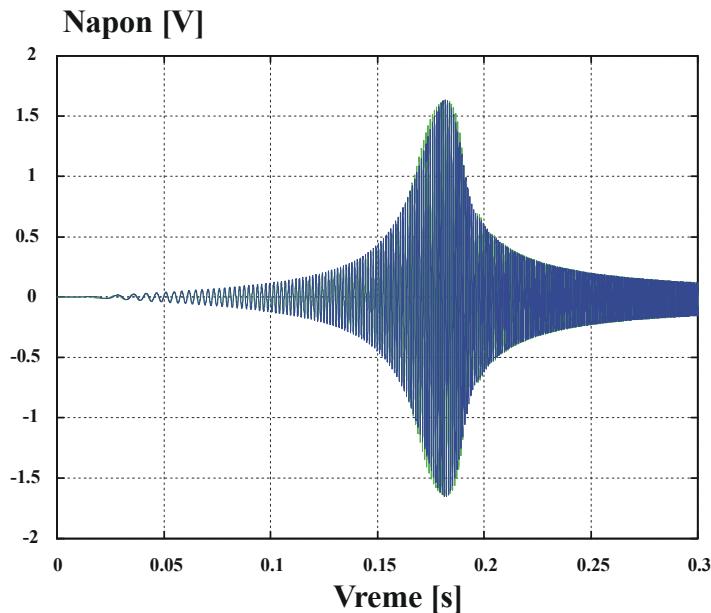
Sl. 4.24 Tri odziva kola sa Sl. 4.22 pobuđenog sinusoidom amplitude 1mA za tri različite frekvencije a) $f=f_r/2$, b) $f=f_r$, i c) $f=2f_r$.

Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)	Izlazni neuron (prvi broj označava skriveni neuron)
1	$w^1(1,1) = -2.97443$ $w^1(2,1) = 6.16141$ $w^1(3,1) = -3.19671$ $w^1(4,1) = -2.50772$ $w^1(5,1) = 1.18214$ $\square \square^1_1 = -1.97594$	$w^2(1,1) = 8.12689$ $w^2(2,1) = 3.16427$ $w^2(3,1) = 7.82068$ $w^2(4,1) = 7.25422$ $\square \square^2_1 = -11.4912$
2	$w^1(1,2) = -2.19356$ $w^1(2,2) = 4.47036$ $w^1(3,2) = -2.28704$ $w^1(4,2) = -2.17822$ $w^1(5,2) = 0.973924$ $\square \square^1_2 = -0.21222$	
3	$w^1(1,3) = 2.90535$ $w^1(2,3) = -5.98934$ $w^1(3,3) = 3.09462$ $w^1(4,3) = 2.5961$ $w^1(5,3) = -1.20532$ $\square \square^1_3 = 1.36558$	
4	$w^1(1,4) = 0.390025$ $w^1(2,4) = -0.789762$ $w^1(3,4) = 0.401649$ $w^1(4,4) = 1.48569$ $w^1(5,4) = -0.720238$ $\square \square^1_4 = -0.430438$	

Tabela 4.5

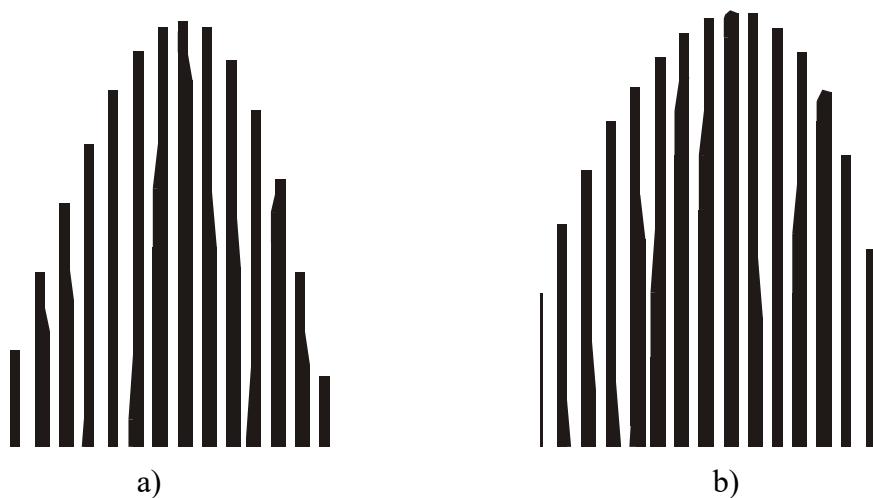
Pošto je kolo nelinearno (diode) i dinamičko (kondenzator i kalem), treba koristiti rekurentnu mrežu sa vremenskim kašnjenjem sa jednim skrivenim slojem, kako bismo napravili model kola. U datom primeru korišćeno je pet ulaza (tekuća vrednost ulaznog

signala, vrednosti ulaza i izlaza iz dva prethodna vremenska trenutka), četiri neurona u skrivenom sloju i jedan izlazni neuron. Tabela 4.5 sadrži težine i pragove svih neurona.



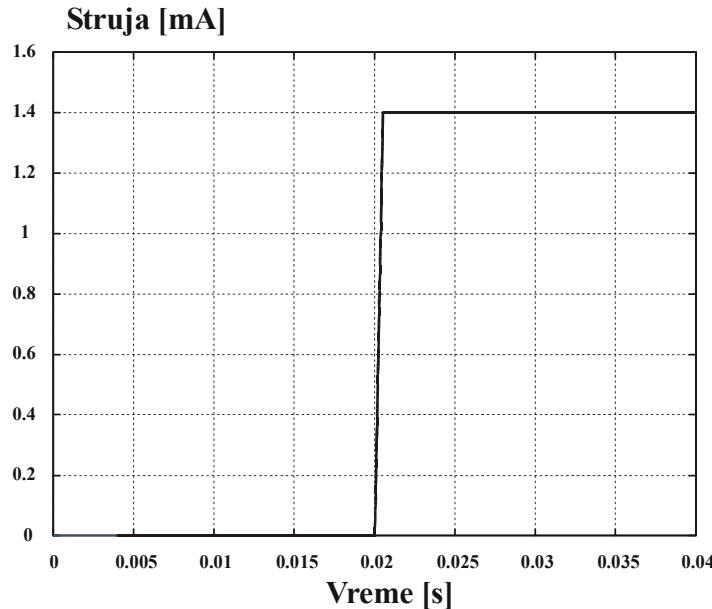
Sl. 4.25 Odzivi originalnog kola (Sl. 4.22) i modela na frekvencijski modulisano sinusoidu

Rezultati dobijeni kada je kolo pobuđeno frekvencijski modulisanom sinusoidom prikazani su na Sl. 4.25. Odzivi se preklapaju.

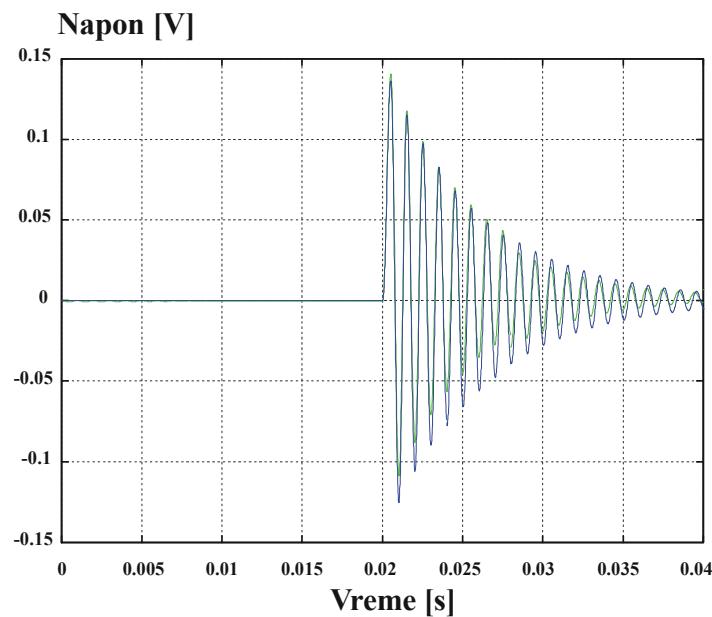


Sl. 4.26 Odzivi originalnog kola sa Sl. 4.22 a), i VNM modela b) za frekvencije bliske rezonantnoj (prikazani su samo vrhovi pozitivnih poluperioda)

Poređenjem odziva zaključujemo da je dobijena odlična aproksimacija. Da bismo proverili mogućnost generalizacije, koristimo signal suštinski različit od onoga koji je učestvovao u procesu obučavanja. To je pravougaoni signal sa Sl. 4.27. Odzvi originalnog kola i modela dati su na Sl. 4.28. Oni su ponovo preklopljeni. Veoma je zanimljivo i to što je amplituda pobudnog signala 1,4mA, a maksimalna amplituda u procesu obučavanja bila je 1mA. Mreža ima sposobnost generalizacije i po amplitudi.



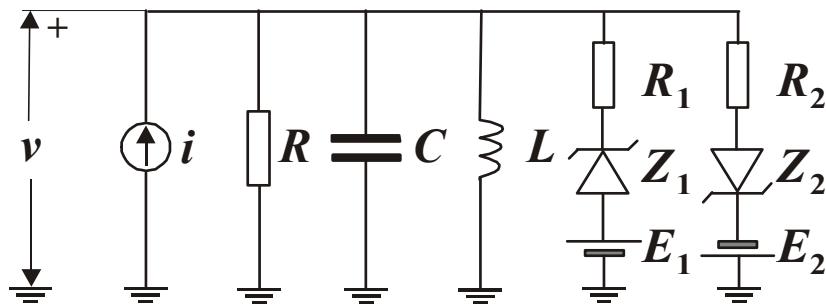
Sl. 4.27 Nova pobuda za originalno kolo (Sl. 4.22) i model



Sl. 4.28 Odzivi originalnog kola (Sl. 4.22) i modela na pravougaonu pobudu

Sledi još jedan primer modelovanja nelinearnog dinamičkog kola. Kolo (Sl. 4.29) je veoma slično prethodnom, imajući u vidu da su umesto običnih, sada Zener diode. Inverzno polarisane Zener diode u proboru imaju manju dinamičku otpornost, pa unose znatnu nelinearnost u kolo. Statička karakteristika onog dela kola koje unosi nelinearnosti (grane koje sadrže elemente $R_1, Z_1, E_1, R_2, Z_2, E_2$) prikazana je na Sl. 4.30. Nelinearnost koju unose Zener diode zapaža se tek za veće amplitude struje, pa je neuronska mreža obučavana strujom amplitude 3mA.

U datom primeru korišćena je rekurentna mreža sa vremenskim kašnjenjem sa pet ulaza (tekuća vrednost ulaznog signala, vrednosti ulaza i izlaza iz dva prethodna vremenska trenutka), četiri neurona u skrivenom sloju i jednim izlaznim neuronom. Tabela 4.6 sadrži težine i pragove svih neurona.

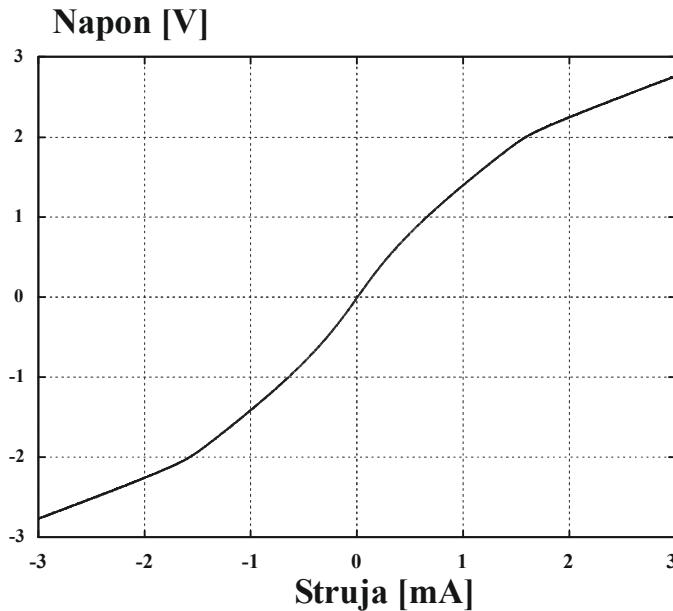


Sl. 4.29 Primer nelinearnog dinamičkog kola sa Zener diodama

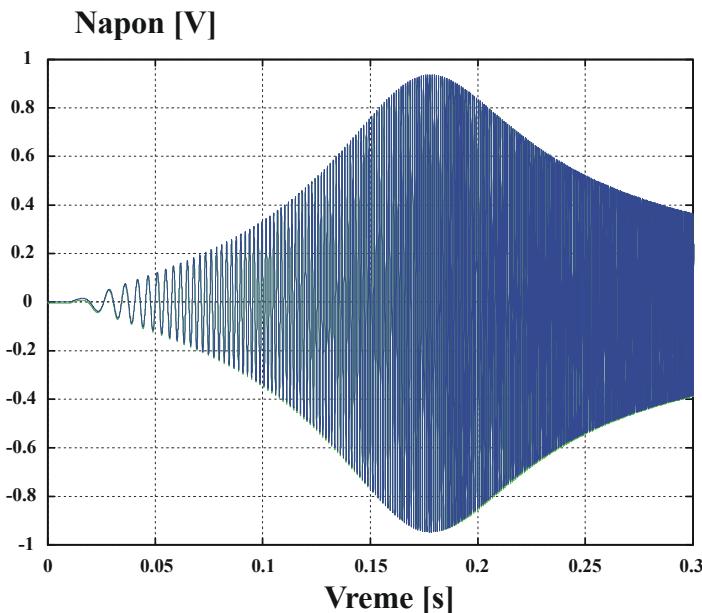
Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)	Izlazni neuron (prvi broj označava skriveni neuron)
1	$w^1(1,1) = 0.158784$ $w^1(2,1) = -1.16002$ $w^1(3,1) = 0.903595$ $w^1(4,1) = 0.208319$ $w^1(5,1) = -0.0221032$ $\square \square^1_1 = -0.0442703$	$w^2(1,1) = 8.60706$ $w^2(2,1) = -0.00000366408$ $w^2(3,1) = 16.9168$ $w^2(4,1) = -13.2363$ $\square \square^2_1 = -5.64382$
2	$w^1(1,2) = -0.0222882$ $w^1(2,2) = 2.14109$ $w^1(3,2) = 1.83841$ $w^1(4,2) = 2.93329$ $w^1(5,2) = -4.16222$ $\square \square^1_2 = -4.01651$	
3	$w^1(1,3) = -1.11553$ $w^1(2,3) = 3.26641$ $w^1(3,3) = -2.15929$ $w^1(4,3) = -0.0274823$ $w^1(5,3) = 0.122718$ $\square \square^1_3 = -0.043402$	
4	$w^1(1,4) = -1.33004$ $w^1(2,4) = 3.42645$ $w^1(3,4) = -2.17066$ $w^1(4,4) = 0.493863$ $w^1(5,4) = 0.435572$ $\square \square^1_4 = 0.0662899$	

Tabela 4.6

Odzivi originalnog kola i modela prikazani su na Sl. 4.31. Sl. 4.32. prikazuje samo vrhove pozitivnih poluperioda u okolini rezonantne frekvencije.

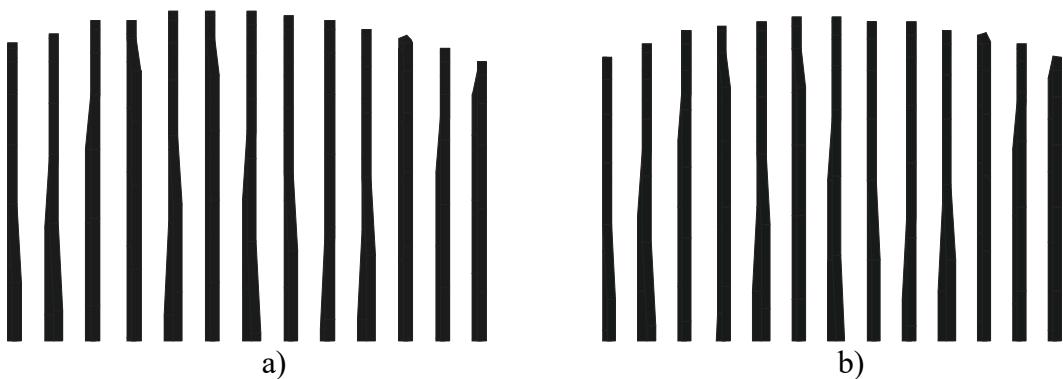


Sl. 4.30 Statička karakteristika dela kola sa Sl. 4.29 koje sadrži elemente $R_1, Z_1, E_1, R_2, Z_2, E_2$

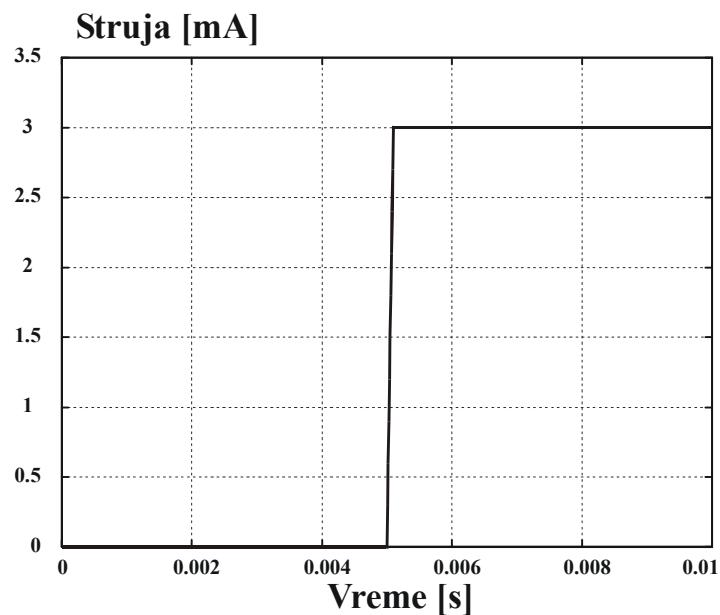


Sl. 4.31 Odzivi originalnog kola (Sl. 4.29) i modela na frekvencijski modulisani sinusoidu

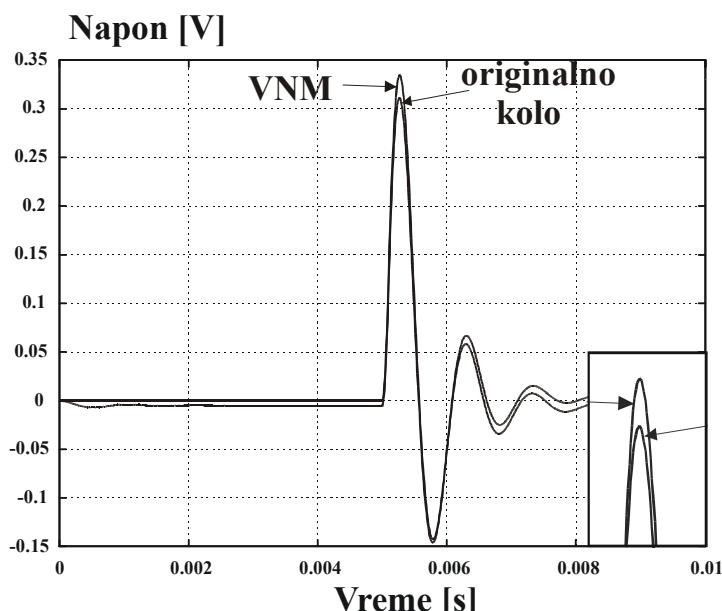
Kada razmotrimo rezultate sa Sl. 4.31 i Sl. 4.32 zaključujemo da model odlično aproksimira kada se koristi poznata pobuda. Sposobnost generalizacije modela testira se pobuđivanjem modela pravougaonom funkcijom. Ona ima različit spektar od one koja je korišćena u procesu obučavanja. Novi pobudni signal prikazan je na Sl. 4.33.



Sl. 4.32 Odzivi originalnog kola sa Sl. 4.29 a), i VNM modela b)
za frekvencije bliske rezonantnoj (prikazani su samo vrhovi pozitivnih poluperioda)



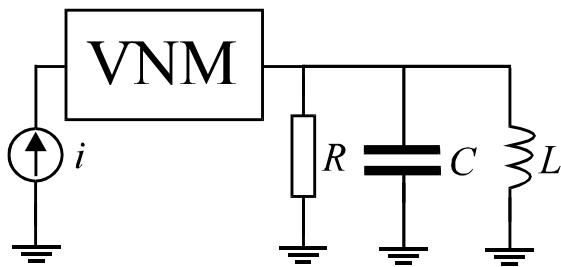
Sl. 4.33 Nova pobuda za originalno kolo (Sl. 4.29) i model



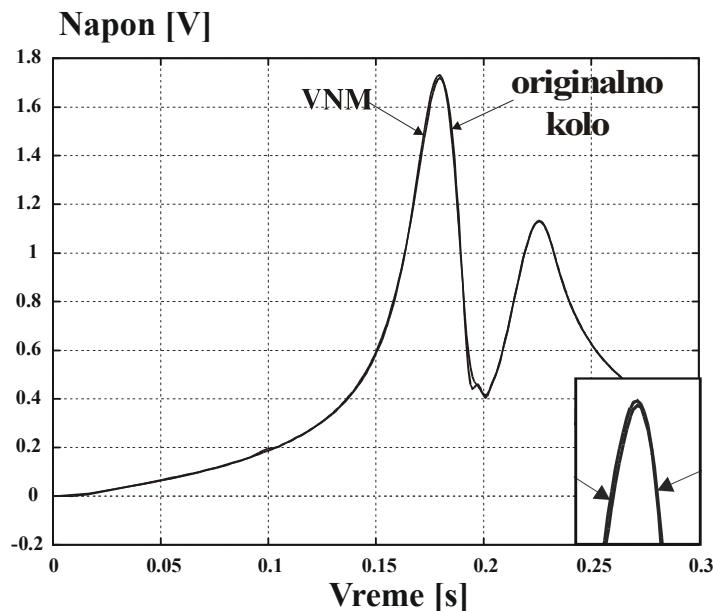
Sl. 4.34 Odzivi originalnog kola (Sl. 4.29) i modela na pravougaonu pobudu

I ovog puta je očigledno da je model uspešno obuhvatio svojstva kola, jer je razlika između odziva vrlo mala, a signal kojim je mreža pobuđena nije korišćen u procesu obučavanja, a po svom obliku je neprirodan za rad kola sa topologijom kao na Sl. 4.29.

Da bismo pokazali primer implementacije VNM modela u elektronsko kolo, iskoristili smo konfiguraciju sa Sl. 4.35. VNM je vezana na red sa običnim elektronskim kolom i ispitivano je kakav odziv daje ovakva struktura na frekvencijski modulisani sinusoidu. Envelope odziva se preklapaju. Prva je dobijena funkcionalnom simulacijom redne veze rezonantne grane i VNM modela, dok je druga rezultat simulacije iste rezonantne grane na red vezane sa kolom sa Sl. 4.22 (bez i).



Sl. 4.35 Model zasnovan na VNM implementiran u kolo



Sl. 4.36 Odzivi originalnog kola i modela (Sl. 4.35)

4.3.1 Modelovanje slušnog pomagala

Na svetu postoji oko 10 miliona ljudi [-02] sa ozbiljnim oštećenjem bilateralnog nerva za sluh koji nisu sposobni da normalno funkcionišu sa najmoderijim klasičnim slušnim pomagalima. Ozbiljnim oštećenjem sluha smatra se 55 do 90 decibela bilateralne neusklađenosti. Isto tako, u ozbiljne probleme ubrajaju se situacije kada osoba čuje zvuke niskog nivoa i visoke frekvencije.

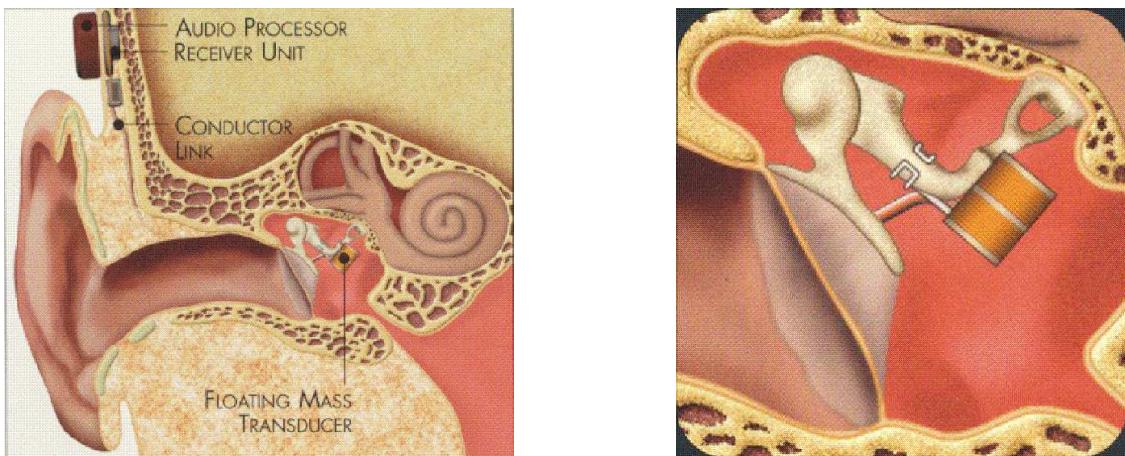
Dva osnovna tipa slušnih pomagala su konvencionalno slušno pomagalo i pomagala koja se delimično implantiraju. Iako konvencionalni slušni aparati omogućavaju pacijentu da čuje zvuke iz svog okruženja, on nije uvek u prilici da razume što je rečeno zbog distorzije zvuka koji prima. Slušna pomagala nude mnoge prednosti pacijentima koji ih nose, ali imaju i brojne nedostatke. Skupi su, nezgodni za nošenje, a sama upotreba i održavanje su komplikovani. Zato ih mnogi pacijenti uopšte i ne nose.

Od svih razmatranih pomagala koja se delimično implantiraju, jedino sistemi sa direktnom pobudom adekvatno sprežu mehaničku energiju sa vibrirajućom strukturom uha. Teoretski, oni predstavljaju idealno rešenje za pacijente sa bilateralnom neusklađenosti. U odnosu na uređaje sa konvencionalnom akustičkom pobudom imaju mnoge prednosti kao što su: veća sposobnost da signal maksimalnog kvaliteta i amplitute stigne do kohlee, bolja tačnost reprodukcije, eliminacija povratne sprege, veća udobnost za pacijenta, manja potreba za održavanjem, lepsi izgled pacijenta [Ba97].

Konvencionalni slušni aparati pojačavaju i uobičavaju akustičke signale uređajima koji se sastoje od mikrofona, pojačavača i prijemnika. Neki oblici modifikacije signala, kao što su distorzija zbog kućišta ili uticaj mehaničke interakcije prijemnika na oklop kućišta, su prirodni. Neki drugi oblici modifikacije signala, koji se javljaju zbog obrade signala u kohlei, su zbog specifičnih anatomskih uslova pojedinačnog pacijenta.

Nasuprot ovome, sistemi sa direktnom pobudom mogu da eliminišu mnoge faktore koji smanjuju kvalitet i amplitudu signala. Razvoju ovih sistema doprineli su i novi uređaji za precizno merenje vibracija srednjeg uha i softveri sa novim tehnikama za obradu podataka.

Primer implantiranog slušnog pomagala prikazan je na Sl. 4.37. (Symphonix Devices, Inc., San Jose, CA).

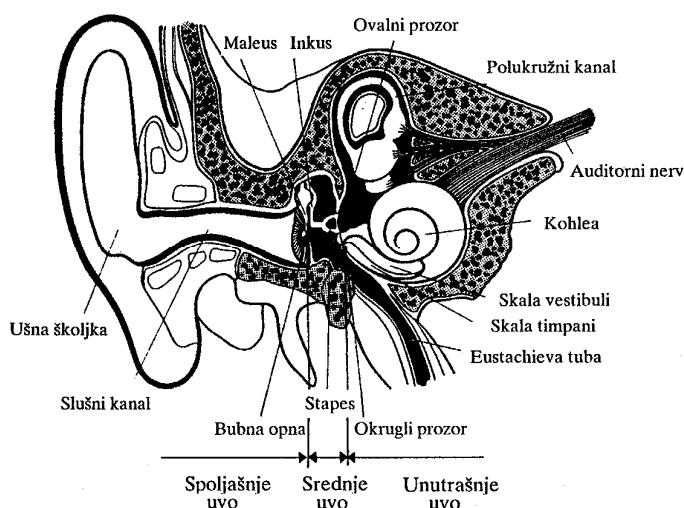


Sl. 4.37 Implantirano slušno pomagalo

Ono se sastoji od tri glavne komponente: Audio procesor, Telelink i Pretvarač sa pokretnom masom (Floating Mass Transducer). Telelink i pretvarač su implantirani, a audio procesor je pričvršćen magnetom. Audio procesor prima zvuk i konvertuje ga u električni signal koji se filtrira, pojačava i moduliše. Signal ide do telelinka, i tu se demodulacijom iz njega ekstrahuje informacija i pretvara se u pobudni signal, koji se prenosi do pretvarača. Pretvarač predaje vibracionu energiju srednjem uhu.

Da bi se bolje razumeli ovi procesi, poprečni presek ljudskog uha prikazan je na Sl. 4.38 [Jo99]. Razlikujemo tri osnovne celine: spoljašnje uho, srednje uho i unutrašnje uho.

Spoljašnje uho sačinjavaju ušna školjka i spoljašnji slušni kanal. Osnovna uloga slušne školjke je prikupljanje zvučne energije iz prostora i usmeravanje u slušni kanal, pa je u stvari njen krajnji efekat pojačanje zvučnog pritiska na bubnoj opni. Isto tako, ona doprinosi i boljoj lokalizaciji izvora zvuka u prostoru.

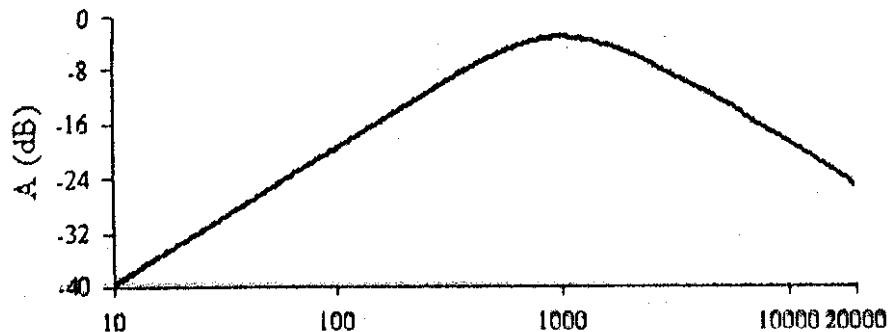


Sl. 4.38 Poprečni presek ljudskog uha

Srednje uho čine kompleksni sistem šupljina u slepoočnoj kosti, bubna opna, slušne koščice i prozori između srednjeg i unutrašnjeg uha. Osnovni zadatak srednjeg uha je prenos i pojačanje zvuka iz spoljašnjeg do unutrašnjeg uha, kao i zaštita osjetljivih delova unutrašnjeg uha od intenzivnog zvuka. Postoje dva prozora kao veza između srednjeg i unutrašnjeg uha: ovalni i okrugli prozor. Eustahijeva tuba je cev koja spaja šupljinu srednjeg uha sa nazofarinksom, a uloga joj je izjednačavanje vazdušnog pritiska sa obe strane bubne opne.

Najosetljiviji deo slušnog mehanizma je unutrašnje uho koje je smešteno duboko u slepoočnoj kosti. Anatomski je direktno povezano sa organom za ravnotežu, što objašnjava činjenicu povezanosti reakcije kretanja i ravnoteže sa slušom.

Prenosna karakteristika modela uha data je na Sl. 4.39.



Sl. 4.39 Prenosna karakteristika modela uha

Da bi se projektovalo pomagalo za korekciju frekvencijske karakteristike uha, potrebno je prvo imati informaciju o samom uhu kome treba korekcija, tj. potrebno je znati njegovu frekvencijsku karakteristiku. Implantirano slušno pomagalo treba da ima takvu frekvencijsku karakteristiku koja bi zajedno sa karakteristikom oštećenog uha formirala novu sveukupnu karakteristiku sa dovoljnim pojačanjem i odgovarajućim propusnim opsegom.

Problem pri projektovanju karakteristike pomagala je što ne postoji analitički izraz za frekvencijsku karakteristiku uha, već samo njegove merene karakteristike. Te merene karakteristike treba aproksimirati na neki način, pa je u sledećem primeru korišćena neuronska mreža za aproksimaciju funkcije uha.

Ideja [Za01] je zasnovana na projektovanju odgovarajućeg operacionog pojačavača spregnutog sa neuronskom mrežom koja predstavlja model frekvencijske karakteristike oštećenog uha, što čini veoma pogodan sistem za simulaciju, jer neuronsku mrežu smatramo elementom kola.

Jedno od rešenja koje se zasniva na korekciji delova frekvencijskog opsega, a upotrebom negativnih konvertora impedanse prikazano je u [Il02].

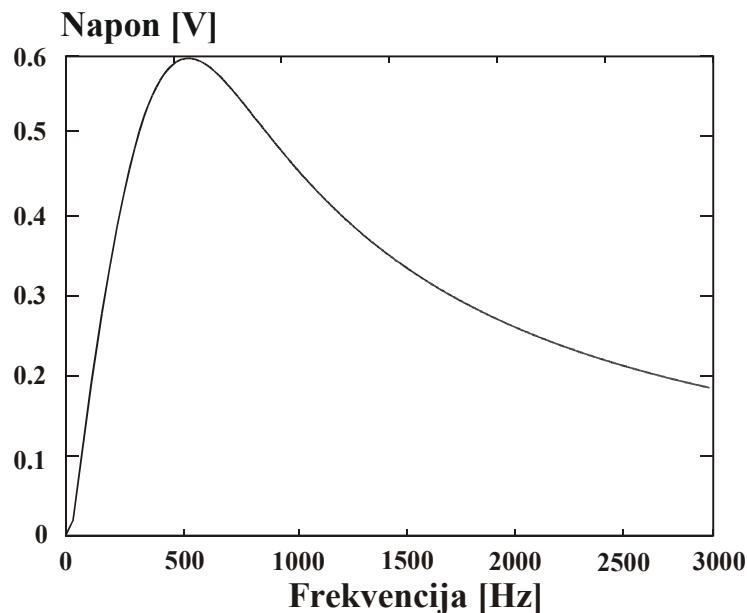
Dati problem se može postaviti na sledeći način. Naponski generator napaja elektronsko kolo (tj. operacioni pojačavač) na Sl. 4.40 koje je opterećeno dvoprilaznom mrežom. Prepostavimo da opterećenje u stvari ima prenosnu karakteristiku oštećenog uha, tj. to je dinamičko kolo čija struktura nam nije poznata. Poznata nam je jedino njegova frekvencijska karakteristika, koja se može predstaviti u obliku tabele parova ulaz-izlaz. Ta karakteristika bi trebalo da bude jedinstvena za određenu osobu.



Sl. 4.40 Operacioni pojavač opterećen mrežom sa dva prilaza (opterećenje)

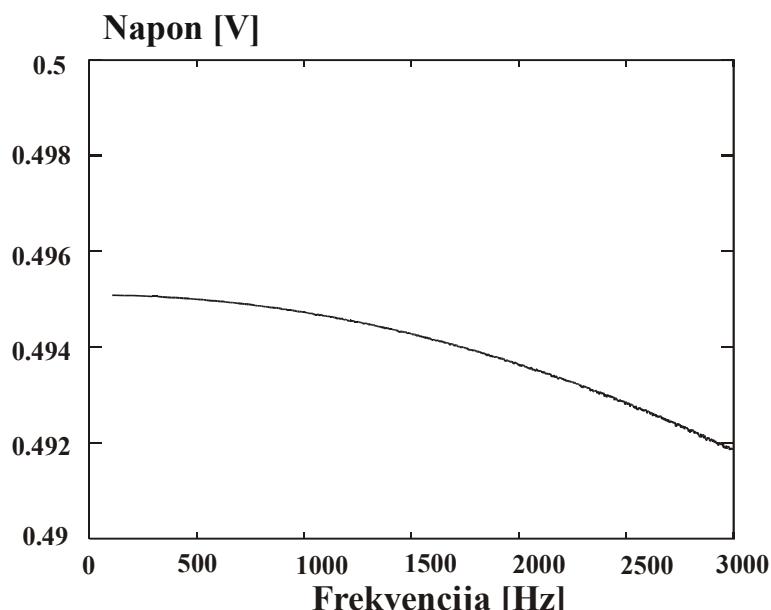
Sada je naš cilj projektovati operacioni pojačavač tako da se za dato opterećenje dobije najbolja sveukupna frekvencijska karakteristika. Slična optimizacija se može raditi u slučaju prigušenja ili distorzije.

Glavni problem je u tome što je karakteristika uha koja služi kao opterećenje merena, a ne analitički prikazana, tako da niti simulaciju, niti optimizaciju nije moguće izvesti direktno. Potreban nam je model uha. Imajući u vidu da struktura i čitav mehanizam rada nisu u potpunosti poznati, jedini pristup je modelovanje “crnom kutijom”.



Sl. 4.41 Merena frekvencijska karakteristika uha

Sledi princip rešenja. Na Sl. 4.41 predstavljena je frekvencijska karakteristika uha. Frekvencijski opseg je, bez smanjenja opštosti, do 3kHz iako bi realno trebalo da bude širi, ali metod modelovanja ostaje potpuno isti.

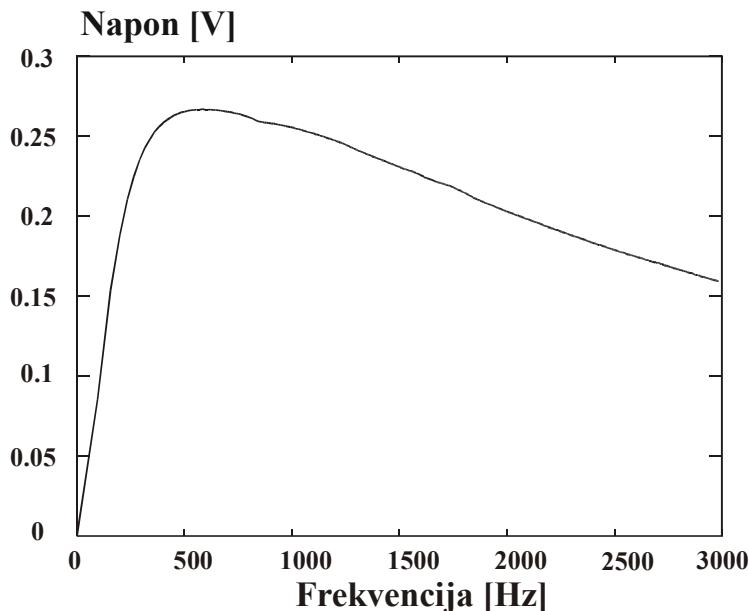


Sl. 4.42 Frekvencijski odziv operacionog pojačavača A1

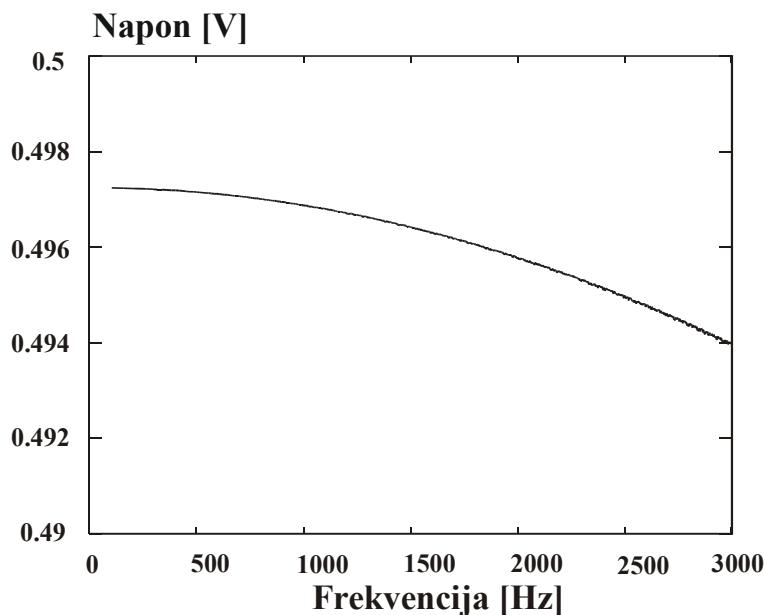
Sl. 4.41 predstavlja i odziv neuronske mreže, koja se koristi za aproksimaciju ponašanja uha. Ovi rezultati pokazuju da je ovo modelovanje sasvim moguće.

Sada ćemo pokazati kako je moguće iskoristiti ovaj rezultat. Sl. 4.42 prikazuje frekvencijski odziv operacionog pojačavača A1, koji je projektovan posebno za ovu svrhu.

Kada imamo model i funkcionalni simulator možemo simulirati čitavo kolo: operacioni pojačavač opterećen dvoprilaznim kolom. Sveukupni odziv dat je na Sl. 4.43.

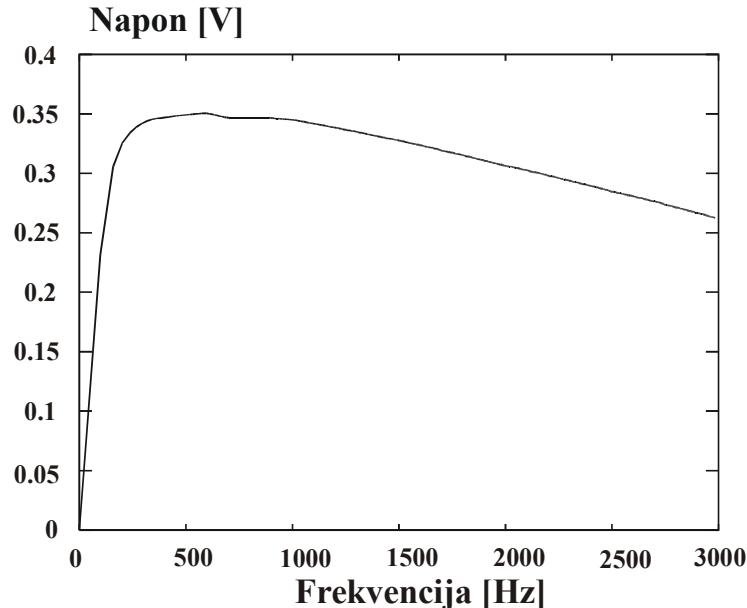


Sl. 4.43 Ukupni odziv pojačavača A1 opterećenog dvoprilaznim opterećenjem (VNM modelom korišćenim za simulaciju)



Sl. 4.44 Frekvencijski odziv operacionog pojačavača A2

Da bismo pokazali upotrebljivost dobijenog modela, ponovo smo projektovali operacioni pojačavač sa ciljem da dobijemo širu frekvencijsku karakteristiku sveukupnog odziva. Novi operacioni pojačavač je A2. Njegova frekvencijska karakteristika data je na Sl. 4.44, dok je na Sl. 4.45 prikazan poboljšani sveukupni frekvencijski odziv.

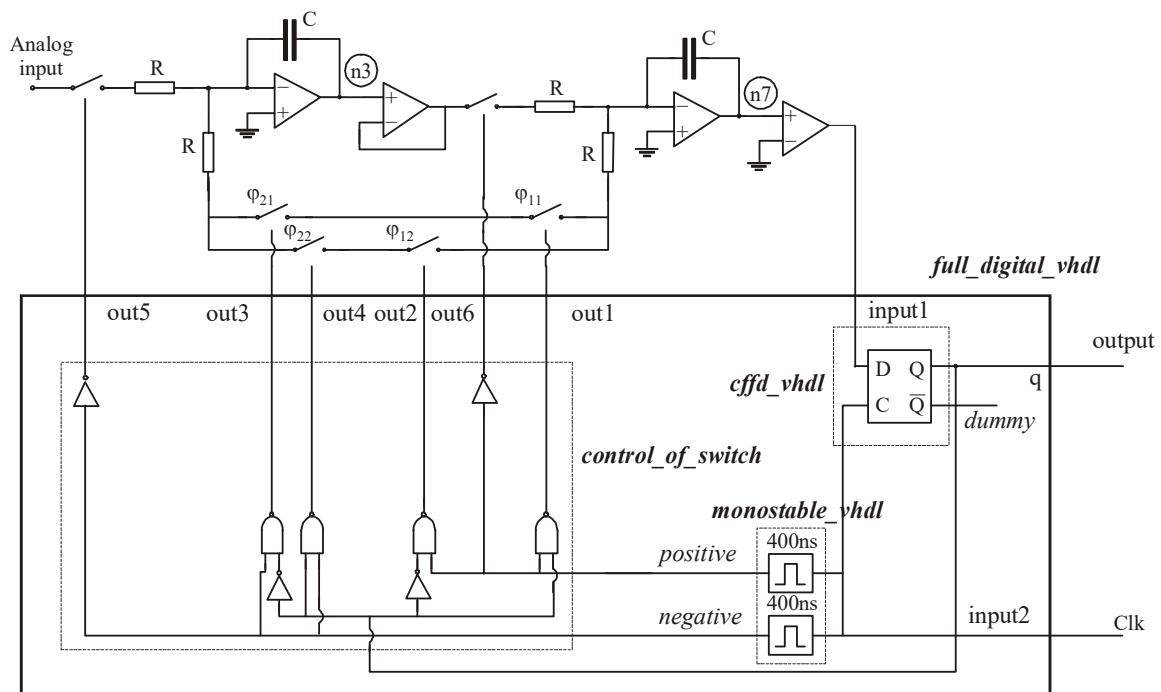


Sl. 4.45 Poboljšana sveukupna karakteristika kada je korišćen A2

Prva simulacija je pokazala da je sveukupni frekvencijski odziv nezadovoljavajući, što nas je uputilo ka ponovnom projektovanju operacionog pojačavača. Novi pojačavač je pokazao zadovoljavajući odziv u novoj simulaciji. Međutim, ovaj postupak se ne smatra optimizacijom operacionog pojačavača. Ipak, pošto je odziv neuronske mreže zasnovan na gradijentnim analitičkim metodama optimizacije, može se iskoristiti za dobijanje optimalnih parametara operacionog pojačavača.

4.3.2 Modelovanje A/D i D/A sprege za hibridnu funkcionalnu simulaciju

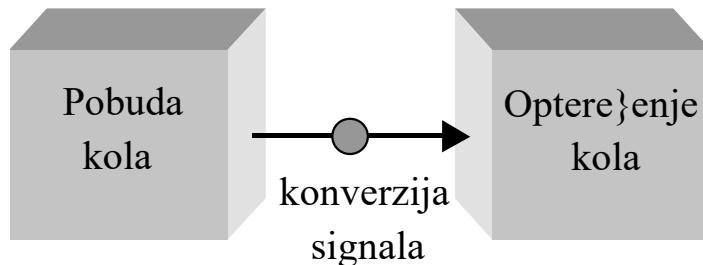
Projektovanje elektronskih i telekomunikacionih integrisanih kola je nesumnjivo suočeno sa simulacijom analognih podsistema čija složenost stalno raste, tako da nastaju sve složeniji hibridni sistemi koji sadrže i analogne i digitalne delove. Projektovanje ovakvih sistema zahteva alat za simulaciju koji je istovremeno i brz i precizan. Glavna prepreka pri ispunjavanju ovog zahteva vezana je za teškoće modelovanja analognog dela na visokom nivou, kao i za dovoljno precizno modelovanje digitalno-analogne (D/A) i analogno-digitalne (A/D) sprege koje se često sreću u ovakvim sistemima [Tr95], [Ku99].



Sl. 4.46 Sigma-delta modulator drugog reda

Ako razmotrimo sigma-delta modulator drugog reda sa Sl. 4.46, prepoznajemo sva tri osnovna tipa elemenata: analogne elemente (otpornici, kondenzatori, operacioni pojačavači), digitalne elemente (logička kola i flipflopovi) i impulsne elemente (analogne prekidače kontrolisane logičkim signalima). Kolo je sa stanovišta signala hibridno, i u njemu se pojavljuju analogni i logički signali. U kolu razlikujemo dve vrste sprege: kada analogni deo kola pobuduje digitalni (A/D sprega) i kada digitalni deo sistema pobuduje analogni (D/A sprega).

Generalizacija ovog sistema prikazana je na Sl. 4.47. Kod D/A sprege potrebno nam je električno kolo da bismo modelovali izlaz digitalnog dela, i tako istovremeno izveli D/A konverziju signala i omogućili električnu pobudu za analogno opterećenje. Zatim, kod A/D sprege, treba modelovati ulaznu impedansu digitalnog dela sistema da bismo dobili uslove za računanje napona i struja interfejsa. Ako imamo u vidu da se simulacija izvodi u vremenskom domenu, da radimo sa hibridnom simulacijom, kao i složenost i nelinearnost kola, potrebno je funkcionalno modelovanje.

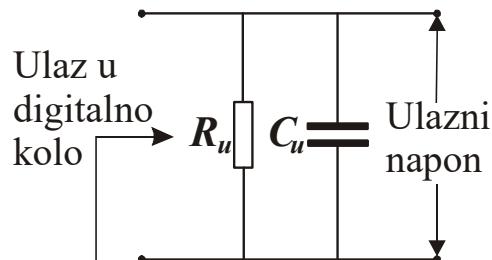


Sl. 4.47 Hibridni sistem

4.3.2.1 Modelovanje A/D sprege

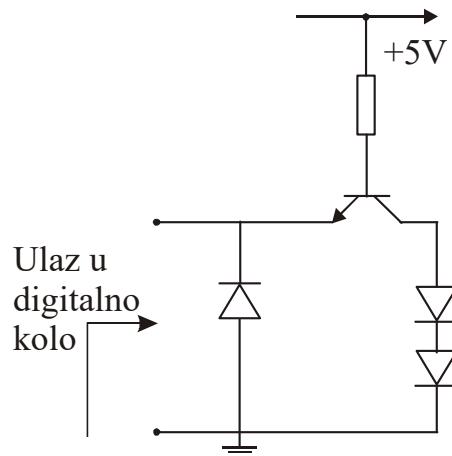
Kada je reč o A/D spregi, signal se prostire od električnog ka logičkom elementu, tako da pobuđuje logičko kolo i određuje logičko stanje signala na ulazu. Da bi se ta sprega razrešila, treba modelovati ulaznu impedansu logičkog elementa.

Na Sl. 4.48. prikazano je najjednostavnije kolo koje može da predstavlja ulaznu impedansu MOS logičkog kola. Kolo je linearno, sa konstantnim vrednostima elemenata, što predstavlja nedovoljno dobru aproksimaciju realne ulazne impedanse MOS ćelije.



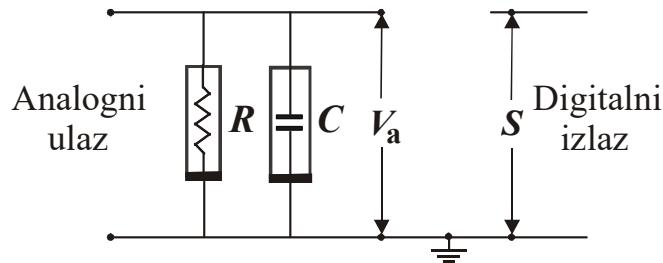
Sl. 4.48 RC ulazno kolo

Ulagna otpornost i kapacitivnost bipolarnih kola je nelinearna, pa bi najjednostavnije ulazno kolo u TTL logici bila dioda. Na Sl. 4.49 prikazano je jedno predloženo rešenje sa više dioda [Co88].



Sl. 4.49 Ulazno kolo pogodno za modelovanje TTL

Problem izlaza analognog kola može se generalno rešiti paralelnim vezivanjem nelinearne otpornosti i nelinearne kapacitivnosti čije su vrednosti kontrolisane naponom na analognom delu A/D čvora, kao što je prikazano na Sl. 4.50 [Pe92].

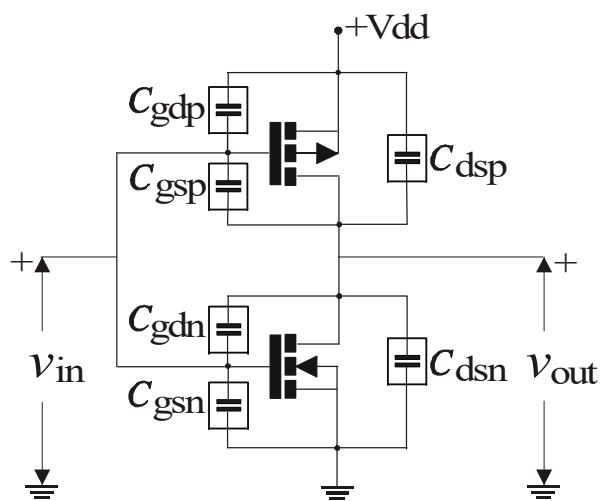


Sl. 4.50 [ema modela A/D čvora

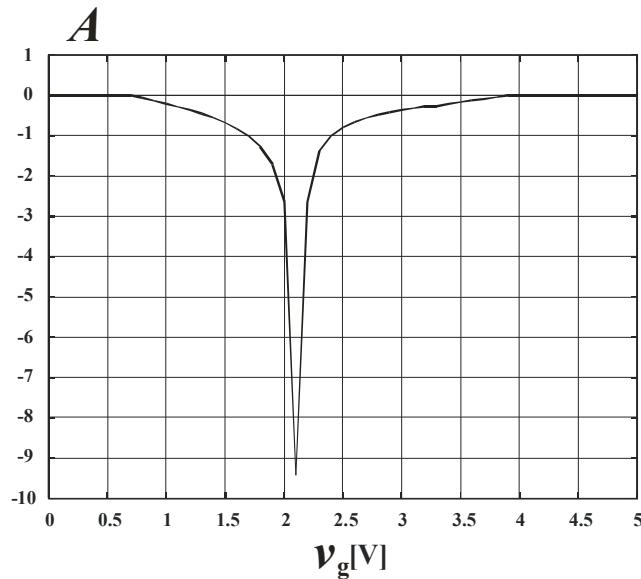
U narednom primeru [Li02a] ćemo pokazati da je ulazna kapacitivnost MOS kola izrazito nelinearna, pa zahteva precizniju metodu modelovanja.

Kako bismo dobili potpunu sliku problema koji se razmatra prvo opisujemo elemente kola koji se pojavljuju u jednostavnom kolu kao što je invertor (Sl. 4.51). Kao što se vidi, oko nelinearnih otpornih tranzistora imamo šest nelinearnih kondenzatora (tri po tranzistoru) [Mu87]. Dva kondenzatora su vezana tako da prosleđuju signal i od ulaza ka izlazu i suprotno pa se ponašaju kao Millerove kapacitivnosti, dok je pojačanje nelinearna funkcija ulaznog signala. Izvod prenosne karakteristike [$v_{out}(v_{in})$] je u stvari prikazan kao pojačanje invertora i prikazan na Sl. 4.52. Imajući ovo u vidu, ulazna impedansa invertora je nelinearni kondenzator koji zavisi od ulaznog signala. Međutim, funkcija koja opisuje tu zavisnost nije poznata. Ovo je razlog zbog koga je neuronska mreža pogodno rešenje za modelovanje ulaznog kola MOS celije.

Invertor je kolo sa jednim ulazom, pa se modeluje samo jedna ulazna impedansa. Kod višeulaznih kola, svaki ulaz ima svoju ulaznu impedansu, pa se zato modeluje onoliko ulaznih kola koliko ima ulaza.

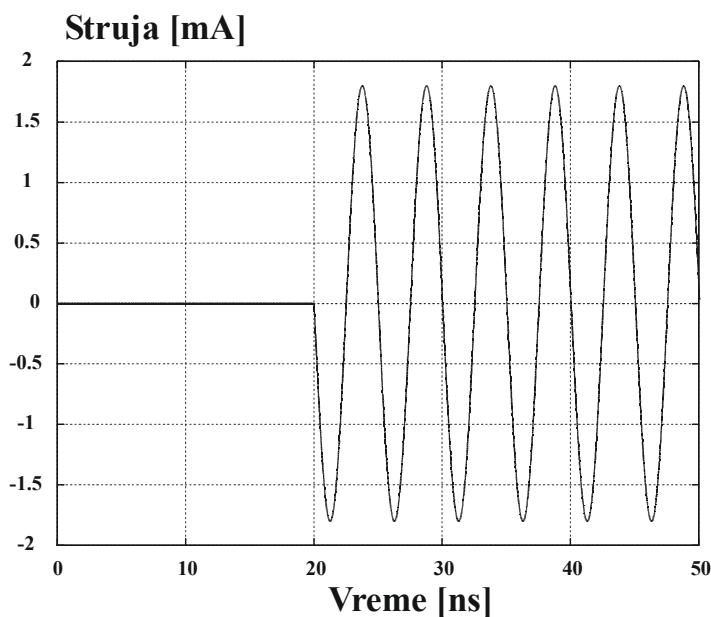


Sl. 4.51 CMOS invertor kod koga su prikazane nelinearne kapacitivnosti

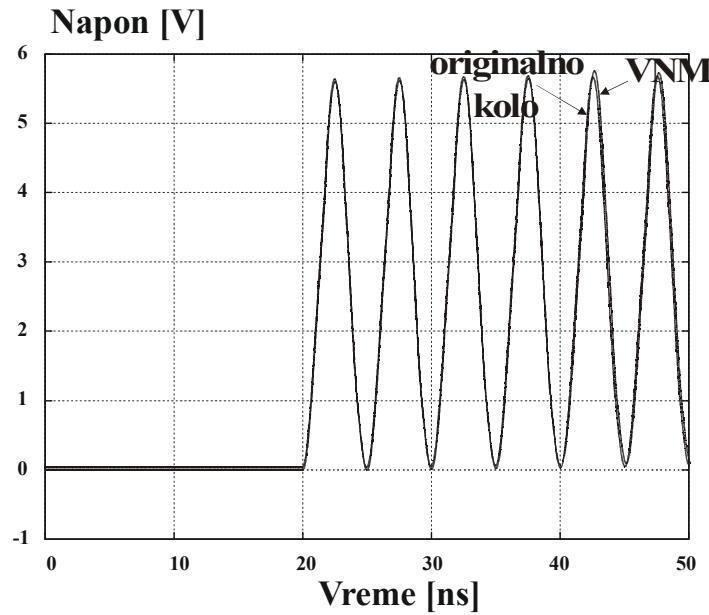


Sl. 4.52 Naponsko pojačanje invertora (A) na niskim frekvencijama kao funkcija ulaznog napona (v_g)

Sada treba razmotriti problem. Kao i u prethodnim primerima, treba pronaći topologiju, složenost i parametre mreže koja bi se ponašala kao ulazno kolo digitalnog dela A/D sprege, kao i signal za pobudu. Da bismo ovo rešili, prvo obavljamo električnu simulaciju digitalnog dela kola. Signal za pobudu treba da omogući simulaciju u vremenskom domenu, pa je kao i u prethodnim slučajevima frekvencijski modulisana sinusoida dobar izbor. Imajući u vidu kapacitivnu prirodu ulaznog kola, mala promena frekvencije bi odgovarala. Zapravo, signal koji je u ovom slučaju bio pobudni, nije frekvencijski modulisani. Pobudni signal prikazan je na Sl. 4.53.



Sl. 4.53 Strujna pobuda korišćena za generisanje modela ($f=200$ MHz)



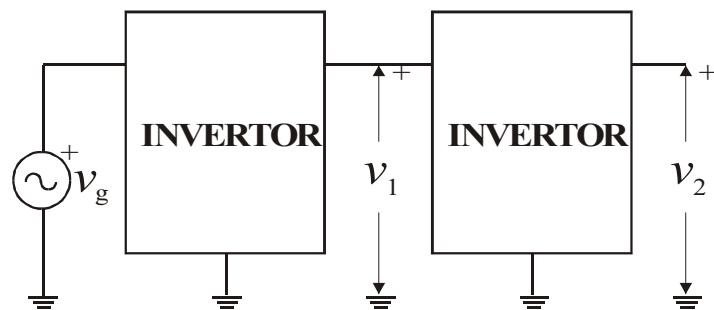
Sl. 4.54 Odzivi invertora sa Sl. 4.51 i modela na ulazu invertora dobijeni za pobudu sa Sl. 4.53

Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)	Izlazni neuron (prvi broj označava skriveni neuron)
1	$w^1(1,1) = -1.15618$ $w^1(2,1) = 0.303841$ $w^1(3,1) = 0.801999$ $w^1(4,1) = -0.655468$ $w^1(5,1) = -0.112933$ $\square^1_1 = 1.69522$	$w^2(1,1) = -1.24339$ $w^2(2,1) = 1.41557$ $w^2(3,1) = -1.98177$ $w^2(4,1) = -2.18655$ $\square^2_1 = 2.91066$
2	$w^1(1,2) = 0.138613$ $w^1(2,2) = -1.16098$ $w^1(3,2) = 1.01521$ $w^1(4,2) = -0.128065$ $w^1(5,2) = 0.915597$ $\square^1_2 = -0.890606$	
3	$w^1(1,3) = -0.537022$ $w^1(2,3) = 1.64986$ $w^1(3,3) = -1.1164$ $w^1(4,3) = -2.64625$ $w^1(5,3) = 1.49825$ $\square^1_3 = -1.15733$	
4	$w^1(1,4) = -1.13048$ $w^1(2,4) = 1.87005$ $w^1(3,4) = -0.716303$ $w^1(4,4) = -3.13684$ $w^1(5,4) = 2.4126$ $\square^1_4 = 1.53233$	

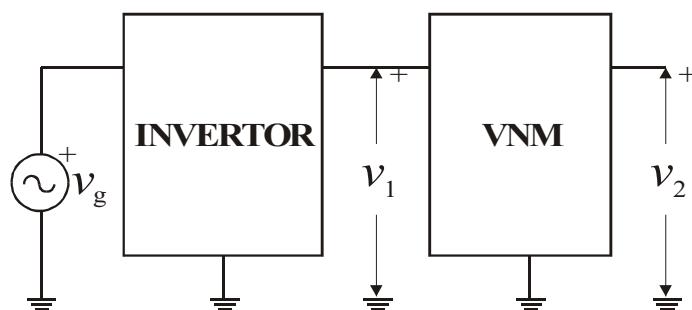
Tabela 4.7

Rezultati simulacije, ulazni napon u funkciji vremena, za invertor sa Sl. 4.52 prikazan je na Sl. 4.54. Talasni oblik izlaznog signala modela prikazan je zajedno sa originalnim talasnim oblikom odziva korišćenim za obučavanje. Dobijeno je odlično slaganje odziva iako je korišćena tako jednostavna pobuda. Da bi se dobio prikazani napon, korišćena je strujna sinusoidalna pobuda amplitude 1,8mA i frekvencije 200MHz. Parovi struja-napon iz simulacije korišćeni su da bi se obučila rekurentna mreža sa vremenskim kašnjenjem sa jednim skrivenim slojem i pet ulaznih, četiri skrivena i jednim izlaznim nevronom. Tabela 4.7 sadrži težine i pragove svih nevrona.

Dobrotu postupka aproksimacije i mogućnosti generalizacije mreže pokazaćemo na primeru kola koje služi samo za tu namenu. Ono se sastoji od dva invertora. Prvo (pobudno) smatramo analognim baš kao na Sl. 4.51. Drugo (opterećenje) smatramo digitalnim. Ova dva kola zajedno prikazana su na Sl. 4.55. Interesuje nas napon A/D sprege. Kasnije, u toku simulacije, on će biti upoređen sa pravovima da bismo uspostavili logički nivo ulaznog signala za logički deo. Da bismo dobili SPICE-like simulaciju, potrebno je digitalni deo zameniti odgovarajućim električnim kolom, pa je u fazi verifikacije digitalni deo zamjenjen električnom šemom.



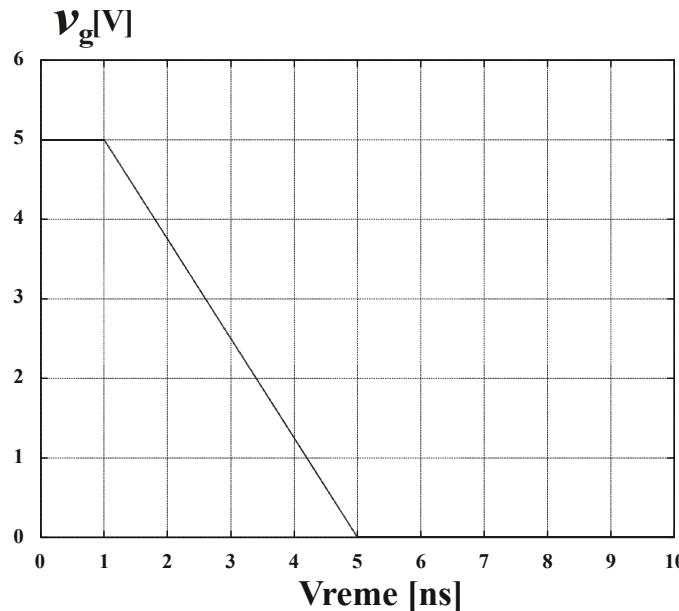
Sl. 4.55 Originalno kolo koje se koristi za verifikaciju (levi invertor je deo analognog kola, dok se desni smatra digitalnim)



Sl. 4.56 Invertor (analogni) opterećen neuronskom mrežom radi verifikacije modela

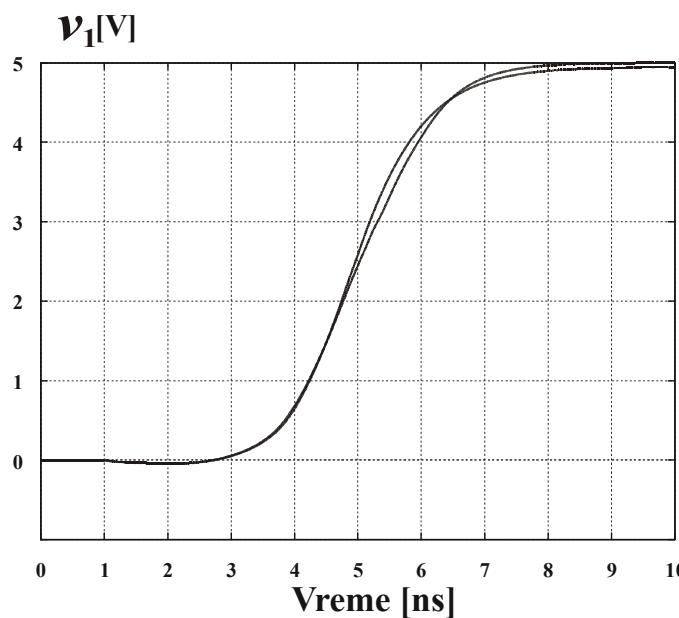
Primena modela u ovom slučaju znači postavljanje VNM na mesto digitalnog dela u kolu, kao što je prikazano na Sl. 4.56. Ovo kolo je potpuno analogno, ali VNM nije element kola. Ponovo zaključujemo da nam je potreban funkcionalni simulator da bismo to opisali.

Sposobnost generalizacije je verifikovana korišćenjem signala koji je bio nepoznat u procesu obučavanja. Imajući u vidu pobudu sa Sl. 4.53, i realne signale koji se pojavljuju u digitalnim kolima, izabrali smo linearno rastuću funkciju sa Sl. 4.57.



Sl. 4.57 Novi signal za pobudu

Poređenje rezultata simulacije kola sa Sl. 4.55 i Sl. 4.56 prikazano na Sl. 4.58. pokazuje uspešno modelovanje i potvrđuje izvodljivost ideje.

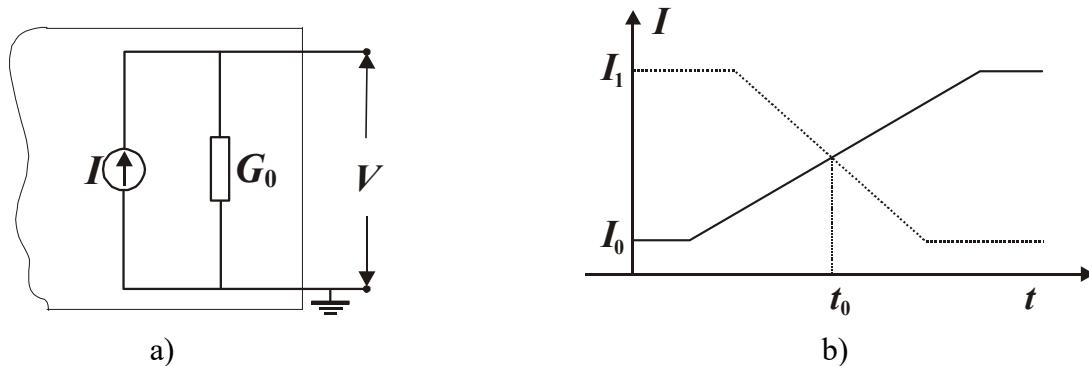


Sl. 4.58 Odzivi dva invertora. Jedan je dobijen simulacijom kola kada je digitalni deo zamenjen celokupnim kolom invertora (Sl. 4.55), a drugi kada je digitalni deo zamenjen modelom (Sl. 4.56)

4.3.2.2 Modelovanje D/A sprege

Kada se signal prostire od logičkog ka analognom elementu, potrebna je konverzija digitalnog signala u analogni. S obzirom na analogno opterećenje, treba razrešiti problem generisanja talasnog oblika na izlazu digitalnog kola. Modelovanje D/A čvora predstavlja mnogo složeniji problem od prethodnog, jer iz skupa logičkih stanja treba generisati talasni oblik napona kojim se pobuđuje analogni deo kola. Algoritmi konverzije su uglavnom zasnovani na sintezi električnog kola koje zamenjuje logički element, i koje se priključuje kao pobuda datom čvoru. Treba uzeti u obzir i kašnjenja logičkih elemenata.

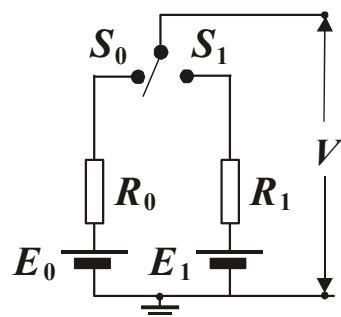
Najjednostavnija verzija D/A konverzije signala ilustrovana je na Sl. 4.59a [Zw89]. Prikazana je grana koja se sastoji od konstantne odvodnosti G_0 i strujnog generatora I , a priključuje se na D/A čvor.



Sl. 4.59 a) Kolo za jednostavnu D/A konverziju, b) Talasni oblik struje generatora

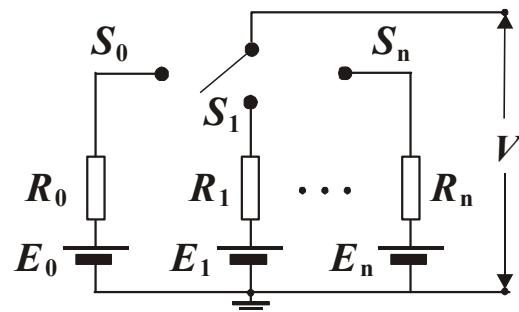
Količnici I_1/G_0 i I_0/G_0 odgovaraju naponskim nivoima logičke jedinice i logičke nule, respektivno, pri čemu je dozvoljeno različito vreme prelaska od logičke jedinice na nulu, i obrnuto. Talasni oblik struje pri prelasku od logičke jedinice na nulu, i obrnuto, dat je na Sl. 4.59b.

Malo složenije izlazno kolo prikazano je na Sl. 4.60 [Ar78]. Koriste se dva realna naponska generatora (E_0, R_0) i (E_1, R_1) koji se priključuju za analogni čvor u zavisnosti od stanja na izlazu logičkog elementa. Ova funkcija se ostvaruje preko prekidača kontrolisanog Boole-ovom funkcijom. R_0 i R_1 su izlazne otpornosti logičkog elementa kada su na izlazu logička nula ili jedinica, respektivno, što znači da su to dve različite otpornosti, za razliku od prethodnog slučaja, kada se koristi odvodnost G_0 u oba slučaja. Kašnjenje logičkog elementa je sadržano u trenutku prebacivanja prekidača.



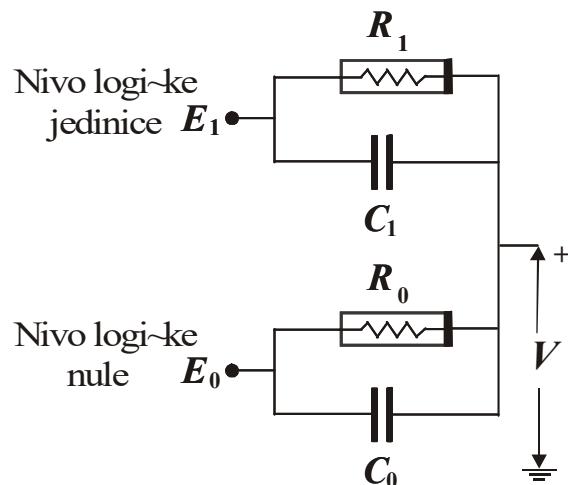
Sl. 4.60 D/A konverzija sa naponskim nivoima

Kola sa Sl. 4.59 i Sl. 4.60 ne obezbeđuju dovoljnu tačnost konverzije, pa je na Sl. 4.61 prikazano kolo koje daje bolju aproksimaciju [Ac90]. Koristi se niz parova vrednosti (E_i, R_i) i prekidač kontrolisan naponom.



Sl. 4.61 Konverzija upotrebom više stanja električnog signala na izlazu logičkog elementa

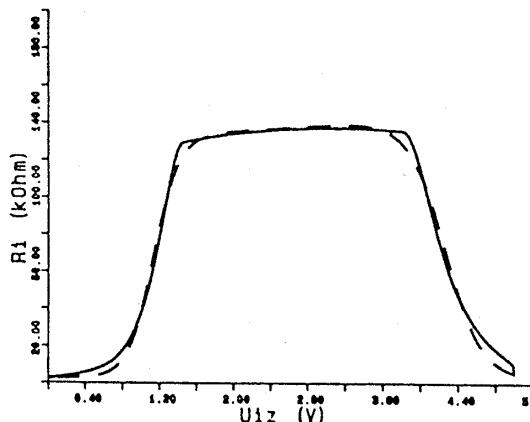
U kolu sa Sl. 4.62 [Co88] se izlazni priključak logičkog elementa vidi kao izlaz razdelnika napona. Kapacitivnosti su konstantne i zadaju se po potrebi, a otpornici su nelinearni i zadaje ih korisnik u obliku tabele. Kod kola sa Sl. 4.61 i Sl. 4.62 logički signal se najpre konvertuje u električni koji ima oblik rampe, pa se vrednosti ovog signala diskretizuju poređenjem sa zadatim nizom pragova i na osnovu toga se upravlja prekidačima (Sl. 4.61) ili vrednostima otpornika (Sl. 4.62).



Sl. 4.62 D/A konverzija upotrebom para naponom kontrolisanih otpornika

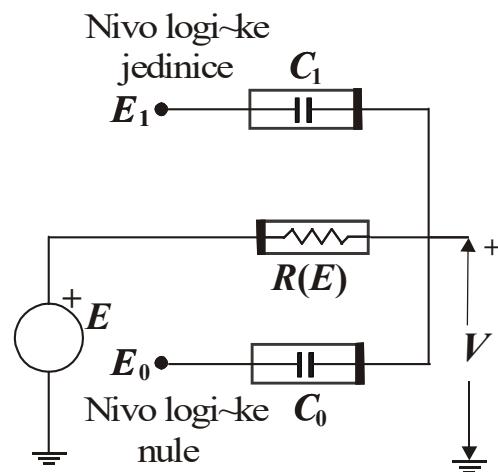
Kola u prethodno navedenim primerima aproksimiraju analogni signal prekidnim funkcijama, što je veoma nepovoljno za analizu nelinearnih kola.

Izlazno kolo je aproksimirano neprekidnom funkcijom u [Pe89], [Pe91]. Pri tome, u obzir je uzeta samo nelinearna otpornost, za koju su aproksimacijom dobijeni analitički izrazi na osnovu zavisnosti izlazne otpornosti i izlaznog napona, kao na Sl. 4.63.



Sl. 4.63 Aproksimacija izlazne otpornosti

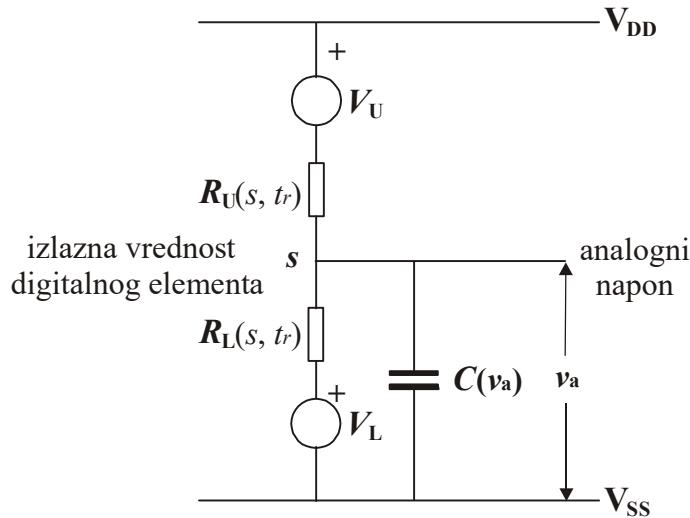
Kolo sa Sl. 4.64 [Pe92] uzima u obzir i izlaznu kapacitivnost. Ono se sastoje od nelinearnog kontrolisanog idealnog naponskog generatora E , nelinearnog otpornika R i dva izlazna nelinearna kondenzatora C_0 i C_1 . Prenosna karakteristika, kašnjenje, izlazna otpornost i kapacitivnost digitalnih modula su precizno modelovani. U prethodno opisanim modelima uzimano je u obzir samo kašnjenje. Električni signal koji ima oblik rampe, i koji je dobijen konverzijom logičkog signala, najpre se zakasni i kao takav predstavlja kontrolišuću veličinu nelinearnog generatora E , čija zavisnost od kontrolišućeg napona je zapravo prenosna karakteristika ekvivalentnog invertora. C_0 i C_1 su kapacitivnosti prostornog nanelektrisanja komplementarnih tranzistora u ekvivalentnom invertoru.



Sl. 4.64 D/A konverzija upotrebom nelinearnog reaktivnog dela

Otpornici čija je vrednost funkcija vremena korišćeni su u [Ni92]. Model izlazne impedanse logičkog kola prikazan je na Sl. 4.65. Vrednosti otpornosti R_U i R_L zavise od vrednosti s , kao i od vremena prelaza t_r , ali ne i od napona na analognom čvoru v_a . Kapacitivnost C zavisi od ovog napona. Naponi V_{DD} i V_{SS} su pozitivni i negativni napon napajanja logičkog elementa, a V_U i V_L su fiksne vrednosti ofseta koje odgovaraju određenom tipu elementa. Otpornosti R_U i R_L linearno menjaju svoju vrednost između minimalne i maksimalne, i obrnuto, u funkciji vremena t_r . Linearna promena ne uzrokuje

probleme u analognoj simulaciji, jer je vrednost analognog napona neprekidna. Parametar t_r je izabran tako da je dovoljno veliki da bi se izbegla suviše brza promena analognog napona, čak iako je vrednost kapacitivnosti nula. Promena kapacitivnosti data je u [Ni92].

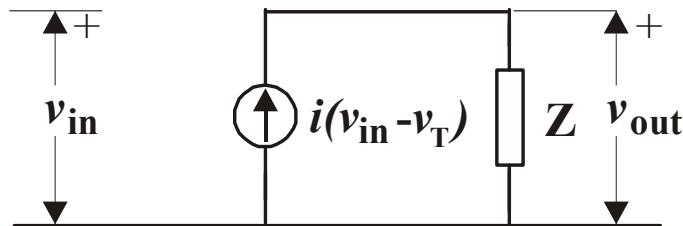


Sl. 4.65 Model izlazne impedanse

Slično rešenje gde otpornici menjaju svoju vrednost prikazano je u [Br91].

Sledi predloženo rešenje zasnovano na veštačkim neuronskim mrežama. Smatra se da je ovo rešenje pogodno zato što se funkcija aproksimira vrlo jednostavno na osnovu merenih vrednosti, bez generisanja električnih kola.

Pri modelovanju ove sprege, predložena je nova topologija kola, prikazana na Sl. 4.66.



Sl. 4.66 Topologija kola za modelovanje D/A sprege

U narednom primeru se razmatra invertor. v_{in} je linearno rastući kontrolišući napon,

$$i(v_{in} - v_T) = I_{\max} [1 - \text{th}(v_{in} - v_T)], \quad (4.5)$$

a Z je neuronska mreža sa vremenskim kašnjenjem koja aproksimira funkciju:

$$v_{out} = Z(i) \quad (4.6)$$

I_{\max} je maksimalna struja napajanja za vreme promene stanja invertora, i v_T je (obično) jednako $V_{DD}/2$, pri čemu je V_{DD} napon napajanja. Očigledno, VNM model ima jedan ulazni kraj (struja) i jedan izlazni (napon). Obučavanje mreže je onda zasnovano na parovima za obučavanje ($i(t)$, $v_{out}(t)$), gde se $i(t)$ računa iz (4.5), dok se $v_{out}(t)$ dobija iz simulacije kola koje se modeluje (invertora u ovom slučaju). Neuronska mreža (Z) ima jedan skriveni sloj, pet ulaza, tri skrivena neurona i jedan izlazni neuron. Tabela 4.8 sadrži težine i pragove svih neurona.

Br.	Neuroni u skrivenom sloju (prvi broj označava ulazni neuron)	Izlazni neuron (prvi broj označava skriveni neuron)
1	$w^1(1,1) = 2.28185$ $w^1(2,1) = -3.51137$ $w^1(3,1) = 1.36815$ $w^1(4,1) = 3.54312$ $w^1(5,1) = -1.37367$ $\square \square^1_1 = -1.3177$	$w^2(1,1) = 0.644039$ $w^2(2,1) = 0.644042$ $w^2(3,1) = 0.644043$ $\square \square^2_1 = -0.408248$
2	$w^1(1,2) = 2.28187$ $w^1(2,2) = -3.51135$ $w^1(3,2) = 1.36816$ $w^1(4,2) = 3.54312$ $w^1(5,2) = -1.37366$ $\square \square^1_2 = -1.31769$	
3	$w^1(1,3) = 2.28187$ $w^1(2,3) = -3.51135$ $w^1(3,3) = 1.36816$ $w^1(4,3) = 3.54313$ $w^1(5,3) = -1.37366$ $\square \square^1_3 = -1.31769$	

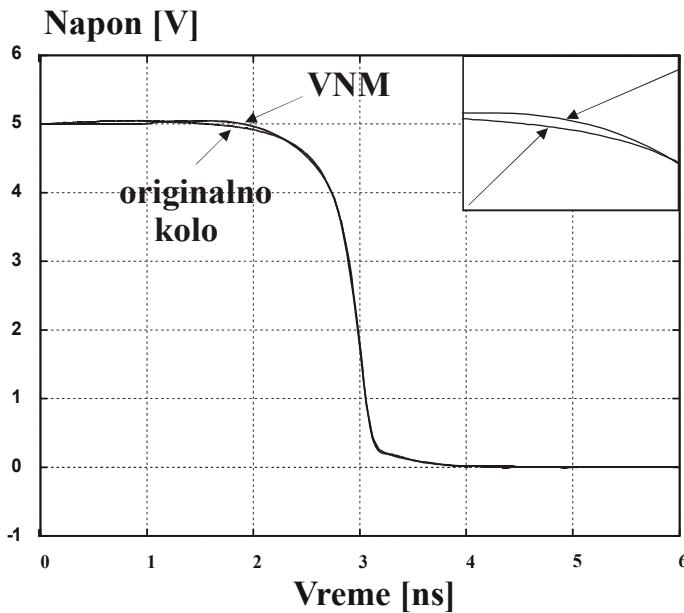
Tabela 4.8

Invertor je jednoulazno kolo, pa je vrednost napona v_{in} iz izraza (4.5) samo jedna.

Kod višeulaznih kola postoji i više ulaznih napona, pa treba u svakom trenutku znati koji od njih postaje v_{in} , jer za svaku kombinaciju ulaznih veličina postoji odgovarajuća izlazna impedansa. Postoji i problem sekvenčnih kola kod kojih stanje na izlazu zavisi kako od stanja na ulazima, tako i od prethodnog stanja na izlazu. Izbor kontrolišuće veličine za slučaj analognih makromodela prikazan je u [Pe90], gde se ona kod kombinacionih višeulaznih kola određuje analizom tablice istinitosti, dok se kod sekvenčnih kola vrši detaljnija analiza rada celije na osnovu koje se utvrđuje redosled delovanja ulaznih veličina na promenu izlaznog stanja.

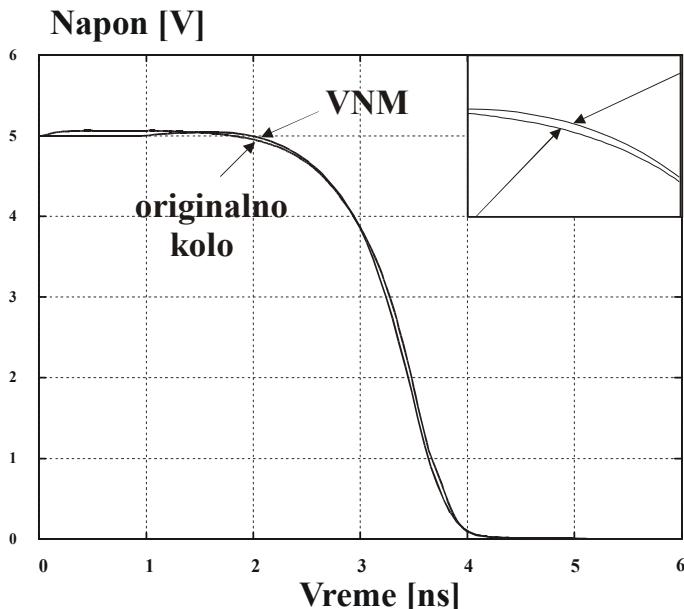
U ovom slučaju kolo je hibridno, što znači da se neuronska mreža na ulazu spreže sa logičkim kolom, pa je napon v_{in} napon digitalnog čvora. U toku logičke simulacije evidencija o događajima i vremenu njihovog nastajanja se vodi u Tabelama Budućih Događaja. Tako je na osnovu te tabele poznato koji su ulazi inicirali određeno stanje na ulazu, pa se shodno tome za D/A čvor priključuje i odgovarajuća impedansa u koju je ugrađeno potrebno kašnjenje.

Prvi rezultati prikazani su na Sl. 4.67. Dati su izlazni talasni oblik originalnog invertora i modela da bi se pokazao kvalitet postupka aproksimacije. Simulirana su neopterećena kola, pri čemu je korišćen funkcionalni simulator.



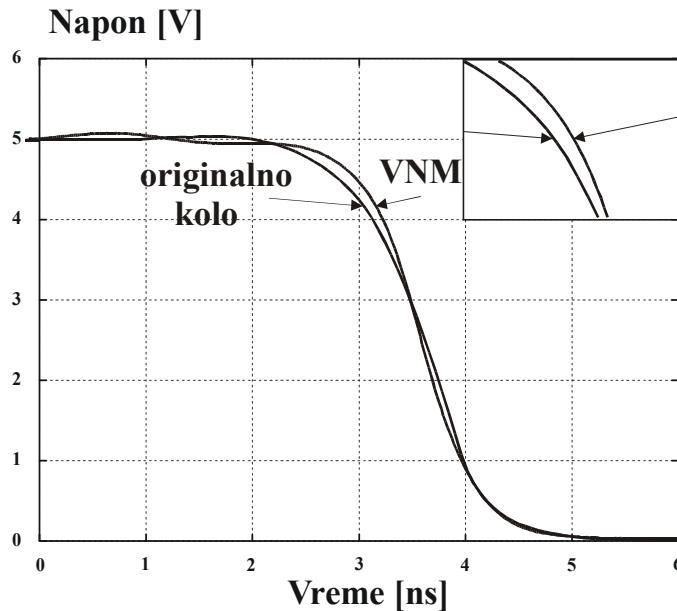
Sl. 4.67 Modelovanje D/A sprege: odzivi neopterećenog CMOS invertora (koji se smatra za digitalni izlaz) i modela

Naredna tri primera treba da provere postupak modelovanja, odnosno kako se kolo ponaša u situacijama koje mu nisu bile poznate u postupku obučavanja. Sl. 4.68 pokazuje dva odziva. Prvi je izlazni napon invertora (koji je modelovan potpunim modelima tranzistora) koji je opterećen invertorom. Drugi predstavlja odziv istog kola pri čemu se VNM model koristi za pobudu kola, a električni model invertora kao opterećenje. Ova situacija je bila nepoznata u postupku modelovanja.



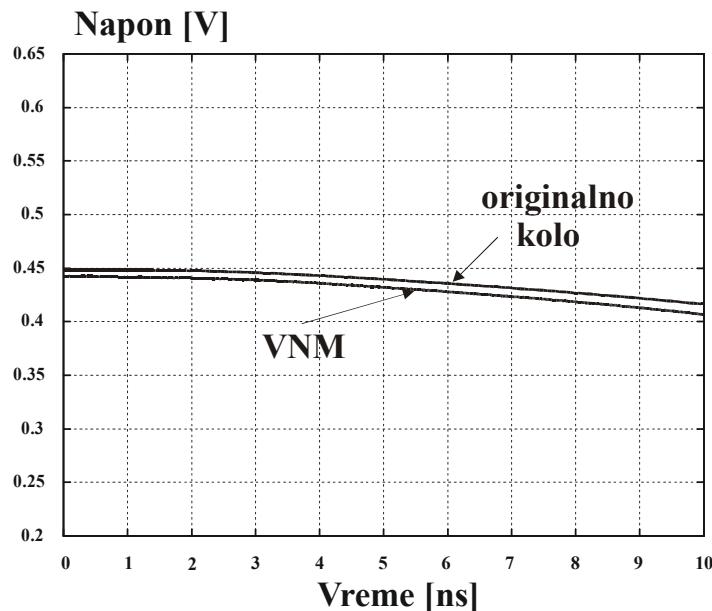
Sl. 4.68 Modelovanje D/A sprege: odzivi CMOS invertora opterećenog invertorom i modela opterećenog invertorom

Dalje, Sl. 4.69 predstavlja slično poređenje, pri čemu je opterećenje transmisioni vod modelovan π -RC mrežom [Ch01].



Sl. 4.69 Modelovanje D/A sprege: odzivi CMOS invertora opterećenog RC π -mrežom i modela opterećenog RC π -mrežom

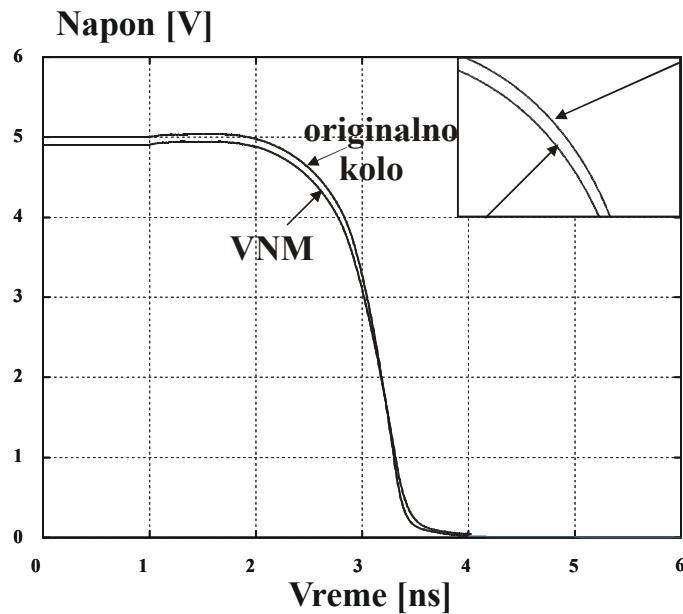
Najzad, dioda je iskorišćena da bi se pokazala primenljivost modela u slučaju “velikih” nelinearnih dinamičkih opterećenja. Poređenje simulacije kola i funkcionalne simulacije je na Sl. 4.70.



Sl. 4.70 Modelovanje D/A sprege: odzivi CMOS invertora opterećenog diodom i modela opterećenog diodom

U nekim situacijama potrebno je modelovati izlazno kolo pobudnog dela kola, dok je u suprotnom slučaju potrebno modelovati ulazno kolo opterećenja, a ponekad su potrebna oba. Ovakav primer je za D/A spregu dat na Sl. 4.71. Prikazan je odziv invertora

opterećenog invertorom i odziv dobijen funkcionalnom simulacijom korišćenjem neuronske mreže i za pobudu i za opterećenje.



Sl. 4.71 Simulacija kola: odziv invertora opterećenog invertorom i analogno-analogno modelovanje sprege: VNM model opterećen VNM modelom

5 Zaključak

Problem modelovanja elektronskih komponenata i kola neprestano je aktuelan od razvoja prve komponente. U poslednje vreme, sa razvojem funkcionalnih simulatora koji istovremeno manipulišu sa mešovitim (kontinualnim i diskretnim) signalima problem modelovanja elektronskih kola, a naročito nelinearnih reaktivnih, postao je naročito aktuelan. Ovakvi modeli omogućavaju hijerahiski predstavljanje složenih elektronskih sistema i verifikaciju svake faze sinteze od funkcionalne do fizičke predstave. Nedostatak alternativnih sredstava verifikacije rezultata sinteze čini rešenja problema modelovanja izuzetno značajnim. Suština problema modelovanja nelinearnih reaktivnih kola jeste u nereverzibilnosti karakteristika ovakvih komponenata što se ponekad manifestuje i haotičnim ponašanjem.

Veštačke neuronske mreže se već godinama koriste za najrazličitije primene, kao što su: klasifikacija uzoraka, prepoznavanje govora, upravljanje procesima, itd. ^injenica da su one univerzalni aproksimatori funkcija dovela je do ideje da se one mogu iskoristiti za modelovanje elektronskih komponenata. Naime, vrlo često fizika komponente nije u potpunosti poznata, jer se dešavaju vrlo složeni procesi koji mogu biti i električne, i magnetne, i mehaničke prirode. Zato je vrlo teško napraviti fizički model komponente, pa se u takvim slučajevima uvodi pristup crne kutije. Zapravo, da bi se dobio analitički izraz pogodan za formulaciju jednačina, na osnovu merenih karakteristika ulaz-izlaz, funkcija komponente se aproksimira. Jedan od odličnih aproksimatora je i veštačka neuronska mreža, pa je cilj istraživanja u okviru ovog rada modelovanje nelinearnih reaktivnih kola primenom neuronskih mreža.

U ovom radu predstavljeno je modelovanje nelinearnih reaktivnih elektronskih kola koje se ostvaruje u prirodnom, vremenskom domenu. Najpre su rešeni osnovni problemi vezani za proces generisanja modela: sinteza talasnog oblika pobudnog signala, sinteza topologije neuronske mreže i određivanje složenosti mreže. Time su postavljeni temelji za rešavanje najšireg spektra problema koji nastaju pri modelovanju modernih elektronskih komponenata, kola i sistema.

U radu je prikazan niz novih modela za elektronske komponente. Najpre su modelovane nelinearne otporne komponente kao što je MOS tranzistor bez kapacitivnih komponenata. Zatim su modelovani nelinearni otporni dvopoli koji ispoljavaju nagib sa promenljivim znakom. Primer ovakvog dvopola je negativni otpornik koji menja znak nagiba, a koji je u stvari element haotičnog atraktora, Chua-ovog kola, pa je na taj način demonstrirana njihova upotrebljivost za simulaciju celularnih neuronskih mreža.

Prva reaktivna kola koja su modelovana su linearne. Modelovanjem ovakvih kola verifikovan je sam postupak modelovanja. Ispitane su mogućnosti mreža čije su topologija i složenost prethodno diskutovane, a verifikovana je i njihova sposobnost generalizacije.

Po prvi put su prikazani postupci modelovanja nelinearnih reaktivnih dvopola kao i njihove različite primene. Princip modelovanja je prikazan kroz primer kola sa poznatom

strukturuom, iako je u stvari motivacija za modelovanje nelinearnih reaktivnih dvopola vezana za razvijanje modela i optimizaciju električnog okruženja aktuatora. U tom slučaju se zahteva metod modelovanja koji će biti primjenjen odmah na bazi onih znanja koja su raspoloživa, pa je metod "crne kutije" zasnovan na neuronskim mrežama vrlo pogodan. S tim u vezi, ilustrovan je i postupak za modelovanje implantiranih slušnih pomagala.

Pri projektovanju savremenih elektronskih i telekomunikacionih integrisanih kola nastaju sve složeniji hibridni sistemi koji sadrže i analogne i digitalne delove. Projektovanje ovakvih sistema zahteva alat za simulaciju koji je istovremeno i brz i precizan. Jedna od prepreka pri ispunjavanju ovog zahteva vezana je za dovoljno precizno modelovanje digitalno-analogne (D/A) i analogno-digitalne (A/D) spregi koje se često sreću u ovakvim sistemima. Osnovni problem je modelovati ulaznu, odnosno izlaznu impedansu logičkog kola koja je izrazito nelinearna, jer treba modelovati svaku nelinearnost. U ovom radu je data aproksimacija impedanse zasnovana na neuronskim mrežama, i pokazano je da ona dovoljno dobro modeluje spregu, što je pokazano kroz niz primera kada je ona opterećena raznovrsnim komponentama.

Verifikacija svih modela obavljena je simulacijom upotrebom funkcionalnog simulatora koji neuronsku mrežu tretira kao ravnopravni element kola. Svaki od dobijenih modela je implementiran u realno okruženje, takođe kroz simulaciju, da bi se videla njegova interakcija sa okolinom, a samim tim i upotrebljivost i svrha.

Kroz date primere pokazano je da je koncept modelovanja zasnovan na veštačkim neuronskim mrežama primenljiv u različitim situacijama, a naročito je koristan kada je model komponente brzo potreban, a njena fizika nije u potpunosti spoznata.

Dalji rad u ovoj oblasti biće usmeren ka primeni prikazanog koncepta u modelovanju realnih kola koje je teško modelovati drugim konceptima, a isto tako, i ka njihovoj realizaciji. Poboljšanje samog postupka obučavanja mreže moglo bi se ostvariti modelovanjem vremena, gde bi vremenski korak bio novi ulaz u mrežu. Tako bi informacija o vremenu bila implementirana u samu neuronsku mrežu, pa bi u tom slučaju bilo moguće koristiti promenljiv vremenski korak. Još jedan zadatak koji nam predstoji je i simulacija celularnih mreža proizvoljne složenosti, koje mogu da procesiraju signale u realnom vremenu, tj. rade kao biološke neuronske mreže.

Literatura

- [Ac90] Acuna, E. L. et all.: "Simulation techniques for mixed analog/digital circuits", *IEEE Journal of Solid-State Circuits*, Vol. 25, No. 2, pp. 353-363, April 1990.
- [Am94] Amirikan, B., Nishimura, H.: "What Size Network Is Good for Generalization of a Specific Task of Interest?", *Neural Networks*, Vol. 7, No. 2, pp. 321-329, 1994.
- [An89] J. A. Anderson, E. Rosenfeld: "Introduction, Neurocomputing: Foundations of research", J.A. Anderson and E. Rosenfeld, Eds., pp. 673-674. The MIT Press, 1989.
- [An02] M. Andrejević, V. Litovski: "Primena veštačkih neuronskih mreža za modelovanje reaktivnih nelinearnih dvopola", *TEHNIKA (Elektrotehnika)*, Br. 2, 2002, pp. 1-10.
- [Ar78] Arnout, G., De Man H. J.: "The use of threshold functions and Boolean-controlled network elements for macromodeling of LSI circuits", *IEEE Journal of Solid-State Circuits*, Vol. SC-13, No. 3, pp. 326-332, June 1978.
- [Ba88] Philippe Bartissol, Leon O. Chua: "The double hook", *IEEE Trans. Circuits Syst.*, Vol. 35, pp. 1512-1522, Dec. 1988.
- [Ba97] Ball, G., Maxfield, B.: "Floating Mass Transducer for Middle Ear Applications: An Analytical Model", privatna komunikacija, 1997.
- [Be94] Bernieri, A., D'Apuzzo, M., Sansone, L., Savastano, M.: "A Neural Network Approach for Identification and Fault Diagnosis on Dynamic Systems", *IEEE Trans. on Instrumentation and Measurement*, Vol. 43, No. 6, December 1994.
- [Br89] M. L. Brady, R. Raghavan, J. Slawny: "Backpropagation Fails to Separate Where Perceptrons Succeed", *IEEE Transactions on Circuits and Systems*, Vol. 36, No. 5, pp. 665-674, 1989.
- [Br91] A.D. Brown, K.G. Nichols, M. Zwolinski, T.J. Kazmierski: "CLASS Simulator Comparable Mixed-Mode Interfacing", *Research Journal, Dept. of ECS*, University of Southampton, England, pp. 99-101, 1994.
- [Ca98] Cannas, B., Cincotti, S., Fanni, A., Marchesi, M., Pilo, F., Usai, M.: "Performance analysis of locally recurrent neural network", *COMPEL- The Int. Journal for Computation and Mathematics in Electrical and Electronic Engineering*, Vol. 17, No. 5/6, pp. 708-716, 1998.
- [Ch01] Chatzigeorgiou, A., Nikolaidis, S., Tsukalas, I.: "Modeling CMOS Gates Driving RC Interconnect Loads", *IEEE Trans. on Circuits and Systems -II: Analogue and Digital Signal Processing*, Vol. 48, No. 4, pp. 413-418, April 2001.
- [Ch75] Chua, L.O., Lin, P.M.: "Computer-Aided Analysis of Electronic circuits: Algorithms and Computational Techniques", *Prentice-Hall*, New Jersey, 1975.
- [Ch88] Leon O. Chua, Lin Yang: "Cellular Neural Networks: Applications", *IEEE Trans. Circuits Syst.*, Vol. 35, No. 10, pp. 1273-1290, Oct. 1988.

- [Ch90] T. Chen, H. Chen, R. Liu: "A constructive proof of Cybenko's approximation theorem and its extensions", pp. 163-168 in *Proc. 22nd Symp. Interface*, East Lansing, Michigan, May 1990.
- [Ch92a] C.-H. Choi, J. Y. Choi: "Construction of neural networks to approximate arbitrary continuous functions of one variable", *Electronics Letters*, Vol. 28, No. 2, 16th January 1992.
- [Ch92b] C. Chui, X. Li: "Approximation by ridge functions and neural networks with one hidden layer", *Journal of Approximation Theory*, 70, pp.131-141, 1992.
- [Ch95a] T. Chen, H. Chen, R. Liu: "Approximation capability in C^n_R by multilayer feedforward networks and related problems", *IEEE Trans. Neural Networks*, Vol. 6, No. 1, Jan. 1995.
- [Ch95b] T. Chen, H. Chen: "Universal Approximation to Nonlinear Operators by Neural Networks with Arbitrary Activation Functions and Its Application to Dynamical Systems", *IEEE Trans. Neural Networks*, Vol. 6, No. 4, July 1995.
- [Ch96] Cheng, Y.: "BSIM3v3 Manual (Final Version)", University of California at Berkley, ERL, 1996.
- [Ci99] Citterio, C., Piuri, V., Rocca, L.: "Function Approximation- A Fast Convergence Neural Approach Based on Spectral Analysis", *IEEE Trans. on Neural Networks*, Vol. 10, No. 4, July 1999.
- [Cl97] Daniel S. Clouse, C. Lee Giles, Bill G. Horne, Garrison W. Cottrell: "Time-Delay Neural Networks: Representation and Induction of Finite-State Machines", *IEEE Trans. Neural Networks*, Vol. 8, No. 5, September 1997.
- [Co88] Corman, T., Wimborow, M. U.: "Coupling a digital logic simulator and an analog circuit simulator", *VLSI System Design*, pp. 40-47, February 1988.
- [Cr92] Jose M. Cruz, Leon O. Chua: "A CMOS IC Nonlinear Resistor for Chua's circuit", *IEEE Trans. Circuits Syst: - Fundamental Theory and Applications*, Vol. 39, No. 12, pp. 985-995, Dec. 1992.
- [De93] T. Denouex, Regis Lengelle: "Initializing Back Propagation Networks With Prototypes", *Neural Networks*, Vol. 6, pp. 351-363, 1993.
- [Fo98] Foyt, D.: "MOSFET Modeling Circuit Simulation", *IEEE Circuits and Devices*, Vol. 14, No. 4, pp. 26-31, July 1998.
- [Gl96] Glozić, D.: "Alecsis, the Simulator", Elektronski Fakultet, LEDA, Niš, Yugoslavia (interna publikacija), 1996.
- [Ha94] Haykin, S.: "Neural Networks: A Comprehensive Foundation", *Macmillan College Publishing Company, Inc.*, 1994.
- [He89] Hecht-Nielsen, R.: "Neurocomputing", *Addison-Wesley Publishing Company*, Reading, MA, 1989.
- [Ho89] K. Hornik, M. Stinchcombe, H. White: "Multi-layer feedforward networks are universal approximators," *Neural Networks*, Vol. 2, pp. 359-366, 1989.
- [Hu98] Guang-Bin Huang, Haroon A. Babri: "Upper Bounds on the Number of Hidden Neurons in Feedforward Networks with Arbitrary Bounded Nonlinear Activation Functions", *IEEE Trans. Neural Networks*, Vol. 9, No. 1, January 1998.
- [Il00] Ilić, T., Zarković, K., Litovski, V.B., Mrčarica, @.: "ANN Application in Modeling of Dynamic Linear Circuits", *Proc. of the Small Systems Simulation Symposium, SSSS' 2000*, Niš, Yugoslavia, pp. 43-47, September 2000.

- [Il02] A. Ilišković, F. Softić : "Modelovanje frekventne karakteristike uha konvertorima impedanse", *XLVI Konferencija ETRANA*, Banja Vrućica, Bosna i Hercegovina, 2002.
- [Jo99] Slobodan T. Jovičić: "Govorna komunikacija", *Nauka*, Beograd, 1999.
- [Ka65] Katzenelson, J.: "An Algorithm for Solving Nonlinear Resistive Networks", *Bell System Technical Journal*, Vol. 44, pp. 1605-1620, October 1965.
- [Ko89] Koch, C., Segev, I., editors: "Methods in Neuronal Modeling", *MIT Press*, 1989.
- [Ku99] K.S. Kundert: "Introduction to RF Simulation and Its Application", *IEEE Journal Solid-State Circuits*, Vol. 34, No. 9, pp. 1298-1318, Sept. 1999.
- [Li00] Litovski V.B.: "Projektovanje elektronskih kola: simulacija, optimizacija, testiranje, fizičko projektovanje", *Nova Jugoslavija*, Vranje, 2000.
- [Li02a] Litovski, V., Andrejević, M.: "ANN application in Modeling of A/D interfaces for mixed-mode behavioral simulation", *XLVI Konferencija ETRANA*, Banja Vrućica, Bosna i Hercegovina, 2002.
- [Li02b] Litovski, V., Andrejević, M.: "ANN Application in Modeling of Chua's circuit", prihvaćen za *NEUREL* 2002.
- [Li92] Litovski, V.B., Rađenović, J. I., Mrčarica, @. M., Milenković, S. Lj.: "MOS transistor modeling using neural networks", *Electronics Letters*, Vol. 28, No. 18, pp. 1766-1768, 1992.
- [Li97] Litovski, V.B., Mrčarica, @., Ilić, T.: "Simulation of non-linear magnetic circuits modeled using artificial neural network", *Simulation Practice and Theory*, Elsevier, No. 5, pp. 553-570, 1997.
- [Ma85] Takashi Matsumoto, Leon O. Chua, Motomasa Komuro: "The double scroll", *IEEE Trans. Circuits Syst.*, Vol. CAS-32, pp. 797-818, Aug. 1985.
- [Ma93] Masters, T., "Practical Neural Network Recipes in C++", Academic Press, San Diego, 1993.
- [Mh92] H. N. Mhaskar, C. A. Micchelli: "Approximation for nonlinear functionals", *IEEE Trans. Circuits Syst.*, Vol. 39, No. 1, pp. 65-67, Jan 1992.
- [Me91] Kishan G. Mehrotra, Chilikuru K. Mohan, Sanjau Ranka: "Bounds on the Number of Samples Needed for Neural Learning", *IEEE Trans. Neural Networks*, Vol. 2, No. 6, November 1991.
- [Mi91] Michael, C.: "Statistical modeling for computer-aided design of analogue MOS integrated circuits", Doktorska disertacija, The Ohio State University, Columbus, 1991.
- [Mi96] Srđan Milenković: "Dinamičko učenje neuronskih mreža drugog reda zasnovano na simuliranom očvršćavanju", Doktorska disertacija, 1996.
- [Mu87] Muller, R.S., Kamins, T.I.: "Device Electronics for Integrated Circuits", *John Wiley and Sons*, New York, 1987.
- [Ni92] K.G. Nichols, A.D. Brown, M. Zwolinski, T.J. Kazmierski: "A Logic-Analog Interface Model", *Research Journal, Dept. of ECS*, University of Southampton, England, pp. 106-109, 1992.
- [Pe89] P. Petković, V. Litovski: "Time domain black-box modeling of CMOS structures and analogue timing simulation", *Proc. of the Third Annual European Computer Conference, COMPEURO'89*, Hamburg, pp. 5.142-5.143, May 1989.
- [Pe90] Predrag Petković: "Makromodeliranje i makroanaliza CMOS LSI elektronskih kola", Doktorska disertacija, Niš, 1990.

- [Pe91] P. Petković, V. Litovski: "Output resistance of CMOS logic cells", *Proc. of the 3rd Mideuropean Conf. Custom/ASICS, CCC1991*, Sopron, Hungary, pp. 237-244, April 1991.
- [Pe92] P. Petković, Z. Stojanović: "Primena analognih makromodela logičkih celija u modeliranju D/A sprege kod hibridnog simulatora", *Zbornik radova sa XXXVI Jugoslovenske konferencije ETANa*, Kopaonik, II Sveska, pp. 51-57, Septembar 1992.
- [Pr88] W.H. Press et all.: "Numerical Recipes in C", *Cambridge University Press*, New York, 1988.
- [Ru86] D.E. Rumelhart, G.E. Hinton, R.J. Williams: "Learning Internal Representation by Error Propagation", *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, D.E. Rumelhart and J. L. McClelland, Eds., Vol I, pp. 318-362. MA: MIT Press, 1986.
- [Sc98] Franco Scarselli, Ah Chung Tsoi: "Universal Approximation Using Feedforward Neural Networks: A Survey of Some Existing methods, and Some New Results", *Neural Networks*, Vol. 11, No.1, pp.15-37, 1998.
- [Sh99] Shahram, M.: "Calibrating Simulations Tools for Nanometer Designs", *IEEE Spectrum*, Vol. 36, No. 6, pp. 77-82, June 1999.
- [Sm94] P.P. van der Smagt: "Minimization Methods for Training Feedforward Neural Networks", *Neural Networks*, Vol. 7, No. 1, pp. 1-11, 1994.
- [So91] E. D. Sontag, H. J. Sussmann: "Backpropagation Separates Where Perceptrons Do", *Neural Networks*, Vol. 4, pp. 243-249, 1991.
- [Sp67] Sparks, J.J.: "Device modeling", *IEEE Trans. on Electron Devices*, Vol. ED-1, No. 5, pp. 229-232, 1967.
- [St90] M. Stinchcombe, H. White: "Approximation and learning unknown mappings using multilayered feedforward networks with bounded weights", *Proc. IJCNN*, pp. III-7 - III-16, 1990.
- [St99] M. B. Stinchcombe: "Neural network approximation of continuous functionals and continuous functions on compactifications", *Neural Networks*, Vol. 12, pp. 467-477, 1999.
- [Su98] Shin Suzuki: "Constructive function-approximation by three-layer artificial neural networks", *Neural Networks*, Vol. 11, pp. 1049-1058, 1998.
- [Tr95] R. Trihy, K.Kundert: "Top Down Design with VHDL-A", *Proc. EUROSIM'95 - Session: Software Tools and Products*, Vienna, pp. 53-56, September 1995.
- [Ts94] Ah Chung Tsoi, Andrew Back: "Locally Recurrent Globally Feedforward Networks: A Critical Review of Architectures", *IEEE Trans. Neural Networks*, Vol. 5, No. 2, March 1994.
- [Wa89] Waibel, A., Hanazawa, T., Hinton, G., Shikano, K. : "Phoneme Recognition Using Time-Delay Neural Networks", *IEEE Trans. on Acoustics, Speech, and Signal Processing*, Vol. 32, No. 3, March 1989.
- [Wa97] Wang, F., Zhang, Q-j.: "Knowledge-based Neural Models for Microwave Design", *IEEE Trans. on MTT*, Vol. 45, No. 12, pp. 2333-2343, December 1997.
- [Ya93] L. Yang, W. Yu: "Backpropagation with Homotopy", *Neural Computation*, No. 5, pp. 363-366, 1993.
- [Za01] K. Zarković, T. Ilić, M. Savić, V. Litovski: "ANN application in modeling of dynamic two-terminal linear circuits", *ETAI*, Ohrid, Makedonija, 2001.

- [Za94] K. Zarković, V. Litovski, S. Stojiljković: "Ubrzanje učenja veštačkih neuronskih mreža stastičkim metodama", *Zbornik radova XXXVIII konferencije ETRANa*, Niš, 1994, pp. 205-206.
- [Zw89] Zwolinski, M. et all.: "The "HOMICIDES" mixed-mode circuit simulator", *Proc. of the Silicon Design Conf.*, Heathrow, November 1-2, 1989.
- [-02] School of Medicine, Washington University in St. Louis, 2002,
<http://research.medicine.wustl.edu/ocfr/research.nsf>

Sadržaj

Summary	1
Uvod.....	3
1 Modelovanje komponenata.....	5
1.1 Klasifikacija i hijerarhija modela.....	5
1.1.1 Klasifikacija modela prema veličini signala	5
1.1.2 Klasifikacija modela prema frekvenciji signala.....	6
1.1.3 Hijerarhija modela	6
1.2 Struktura modela.....	7
1.3 Generisanje modela.....	8
2 Neuronske mreže	10
2.1 Modeli neurona	11
2.1.1 Statički modeli	11
2.1.2 Dinamički modeli.....	14
2.2 Arhitekture neuronskih mreža.....	15
2.2.1 Nerekurentne neuronske mreže.....	16
2.2.2 Rekurentne neuronske mreže	17
2.3 Učenje veštačkih neuronskih mreža.....	18
2.3.1 Backpropagation algoritam za učenje neuronskih mreža	20
2.3.2 Poboljšanja backpropagation algoritma	23
2.4 Veštačke neuronske mreže kao univerzalni aproksimatori funkcija.....	26
3 Opis rešenja.....	32
3.1. Sinteza talasnog oblika	36
3.2. Sinteza topologije mreže.....	38
3.3. Složenost mreže	40
4 Primena neuronskih mreža u modelovanju.....	42
4.1 Modelovanje otpornih mreža	42
4.1.1 Modelovanje MOS tranzistora	42
4.1.2 Modelovanje nelinearnih otpornih dvoprilaznih elemenata sa karakteristikom koja menja znak nagiba.....	48
4.2 Modelovanje linearnih dinamičkih kola	58
4.3 Modelovanje nelinearnih dinamičkih kola.....	63
4.3.1 Modelovanje slušnog pomagala.....	72
4.3.2 Modelovanje A/D i D/A sprege za hibridnu funkcionalnu simulaciju	78
4.3.2.1 Modelovanje A/D sprege	79
4.3.2.2 Modelovanje D/A sprege	85
5 Zaključak.....	93
Literatura.....	95