

## Summary

### Artificial Neural Networks Application in Diagnosis of Electronic Circuits

As we are reading these words we are using a complex biological neural network. Every one of us has a highly interconnected set of some  $10^{11}$  neurons to facilitate our reading, breathing, motion, thinking and many more operations. Each of our biological neurons has the complexity, but not the speed, of a microprocessor. Some of our neural structure was with us at birth; other parts have been established by experience.

Scientists have only just begun to understand how biological neural networks operate. It is generally understood that all biological neural functions, including memory, are stored in the neurons and in the connections between them. Learning is viewed as the establishment of new connections between neurons or the modification of existing ones. This leads to the following question: Although we have only a rudimentary understanding of biological neural networks, is it possible to construct a small set of simple artificial “neurons” and perhaps train them to serve a useful function? The answer is, certainly, yes.

The neurons that we consider here are not biological. They are extremely simple abstractions of biological neurons, realized as elements in a program. Networks of these artificial neurons do not have a fraction of the power of the human brain, but they can be trained to perform useful functions.

Artificial neural networks (ANNs) have been used for many applications for years, such as: pattern recognition, speech recognition, process control, electronic design, and so on. ANN is a parallel, distributed information processing structure containing local memory and carrying processing operations. Its parameters are weights and thresholds. Neural function approximation is achieved by identifying the input-output relationship, described by a set of input-output pairs. The most important neural network property is its generalization property, meaning that it can give correct output even to an excitation not presented in the learning process.

In this dissertation, one of the possible ANN applications will be presented- an application in electronic circuits’ diagnosis.

Every complex system is liable to faults or failures. In most general terms a fault is any change in a system that prevents it from operating in the proper manner. We define diagnosis as the task of identifying the cause of a fault that is manifested by some observed behavior. Then some method of determining what fault has occurred is required. This is most often considered to be a two-stage process: firstly the fact that fault has occurred must be recognized – what is referred to as fault detection. Secondly, the nature should be determined such that appropriate remedial action may be initiated.

Attention of many researchers is directed to the tools that will help, and what is most desired, will perform diagnosis automatically. Such tools are a great challenge to design engineers that pertains to the fact that generally the diagnostic problem is indeterminate. In addition, it is a deductive process with one set of data creating, in general, unlimited number of hypotheses among which one should try to find the solution. This is why permanent attention of the research community is attracted by this problem. In order to solve the problem, in last decades new concepts are introduced, trying to create the system containing “intelligent characteristics”, such as artificial neural networks and fuzzy-neuro networks. In this dissertation approach based on artificial neural networks is chosen.

Diagnosis is a complex activity that involves collaboration of design, test, and field engineers and the mutual distribution of responsibilities throughout the life cycle of an electronic product. We assume that field engineers are expected to react after a functional failure of the system. In order to diagnose such a system they need to be supplied with: testing equipment, a list of specific measurements to be done (including a set of signals and test points), and diagnostic software to process the measurement data. A similar set of data and tools would be given to a test engineer in a production-plant environment in order to evaluate the production yield and create feedback to process engineers when prototyping the circuit. We believe, however, design engineers are the most familiar with the product and the most qualified and capable to synthesize test and diagnostic signals, and procedures. This means the simulation-before-test has to be applied to create fault dictionaries containing exhaustive lists of faults and corresponding responses. The fault dictionary is in fact a table representing the mapping from the fault list into a list of faulty (or possibly, fault-free) responses. In that way the diagnostic process becomes a search through the fault dictionary. We claim here that ANNs, being universal approximators, are the best way both to capture the mapping, and to search through the dictionary, thereby to perform diagnosis.

In the first chapter of this dissertation, description of the natural neuron is given, and also description of the artificial neuron, as the basic building unit of ANNs. The structure of feed-forward neural network is presented, as well as the problems considering network complexity.

In the second chapter basic diagnostic concepts are discussed. General diagnostic system is presented first, and approaches to electronic circuits' diagnosis are enumerated then.

Third chapter introduces the first example of artificial neural networks application to diagnosis of electronic circuits, defects diagnosis in a resistive circuit. This example, in fact, illustrates the approaches given in this work. In the example described, only catastrophic defects are diagnosed. The ANN generalization property is shown by supplying noisy data to ANN's inputs during diagnosis.

Forth chapter describes diagnosis in a nonlinear dynamic circuit. Analogue electronic circuits are known to be difficult to test and diagnose. Apart from the huge number of possible faults, this difficulty is a consequence of the inherent nonlinearity of these circuits. Even linear circuits (having linear input-output signal interdependence) exhibit nonlinear relations between circuit parameters and the output response. There are no linear active networks. Active networks are nonlinear with nonlinear reactive elements. They may be linearized and thought of as such in situations where signal and parameter changes are small in comparison to nominal values. In this chapter, an example of both parametric and catastrophic defects diagnosis in the circuit of an operational amplifier consisting of seven transistors is given. Network generalization property is also shown.

The explosion of integrated circuit technology has brought with it some difficult testing problems. The recent growth of mixed analogue and digital circuits complicates the testing problem even further. It becomes more complicated to determine a set of input test signals and output measurements that will provide a high degree of fault coverage. There is also a timing problem of testing the circuits even on the fastest automated equipment. The fifth chapter presents diagnosis in a mixed-signal circuit. The attention is paid to the choice of test signals, number of test points and exhaustive fault dictionaries. Both parametric and catastrophic defects will be diagnosed by the same neural network.

The last diagnosis example is given in the sixth chapter. Modeling, simulation and diagnosis of the micro-electro-mechanical system are described. Neural networks are applied to modeling fault-free and faulty micro-electro-mechanical components, speeding up the simulation time and enabling fast fault dictionary creation.

# Uvod

Dok čitamo ove redove, koristimo složenu prirodnu neuronsku mrežu. Svako od nas ima oko  $10^{11}$  neurona međusobno povezanih snažnim vezama, koje omogućavaju čitanje, disanje, kretanje, razmišljanje, i još mnoge funkcije [1]. Svaki od naših bioloških neurona ima složenost, ali ne i brzinu, mikroprocesora. Deo te nervne strukture je sa nama od rođenja, deo se stiče iskustvom.

Naučnici su tek počeli da otkrivaju kako rade prirodne, biološke neuronske mreže. Poznato je da su sve biološke funkcije, uključujući memoriju, smeštene u neuronima i njihovim međusobnim vezama. Učenje se posmatra kao uspostavljanje novih veza između neurona ili modifikacija postojećih. Ove činjenice dovode do sledećeg pitanja: Ako imamo osnovno znanje o biološkim neuronskim mrežama, da li je moguće napraviti mali skup jednostavnih veštačkih neurona, povezati ih, i možda ih obučiti tako da obavljaju korisne funkcije? Odgovor je, naravno, da.

Neuroni koje koristimo u ovom radu nisu prirodni. Oni su vrlo jednostavna apstrakcija prirodnih neurona, opisana računarskim programom. Mreže koje sačinjavaju ovi neuroni nemaju ni deo snage ljudskog mozga, ali mogu biti obučene tako da obavljaju korisne funkcije.

Veštačke neuronske mreže se već godinama koriste za najrazličitije primene, a neke od njih su: klasifikacija uzoraka, prepoznavanje govora, upravljanje procesima, projektovanja u elektronici, itd. Veštačka neuronska mreža je paralelna nelinearna distribuirana struktura koja sadrži lokalnu memoriju, obrađuje ulazne podatke, a njeni parametri su težine veza i pragovi. U procesu obučavanja mreže podešavaju se ovi parametri, sa ciljem da neuronska mreža nauči zadato preslikavanje. Mreži se na početku predstavljaju skupovi podataka, parovi ulaz-izlaz, na osnovu kojih ona treba da ekstrahuje određeno preslikavanje. Najvažnije svojstvo neuronske mreže je njena sposobnost generalizacije, tj. sposobnost da da korektan odziv i za pobudu koja joj nije predstavljena u procesu učenja.

U okviru ove disertacije, biće pokazana jedna od mogućih primena veštačkih neuronskih mreža- primena u dijagnostici elektronskih kola.

Svaki složeni sistem podložan je defektima ili kvarovima. U najopštijem slučaju, defekt je svaka promena u električnom kolu ili sistemu koja ga sprečava da radi ispravno. Dijagnostika treba da omogućiti da se ustanovi priroda i mesto defekta u kolu. Na osnovu ispravne dijagnostike može se intervenirati u korekciji proizvodnog procesa, odnosno može se zameniti neispravna komponenta prilikom održavanja sistema koji je u pogonu.

Pažnja mnogih istraživača usmerena je ka otkrivanju novih alata koji bi pomogli u procesu dijagnostike, ili, koji bi, u najboljem slučaju, izvršavali taj proces automatski. Takvi alati su veliki izazov za inženjere imajući u vidu da je dijagnostika proces gde postoji skup podataka koji, u opštem slučaju, generiše brojne hipoteze među kojima treba naći rešenje. Da bi se došlo do rešenja, poslednjih decenija korišćeni su novi koncepti koji pokušavaju da kreiraju sistem koji sadrži "inteligentne karakteristike", kao što su veštačke neuronske mreže i fazi-neuronske mreže. U ovoj disertaciji izabran je pristup zasnovan na veštačkim neuronskim mrežama.

Dijagnostika je kompleksna inženjerska aktivnost koja se oslanja na discipline kao što su projektovanje i testiranje, ali i mnoge druge. Smatra se da inženjer održavanja treba da reaguje čim se sistem pokvari. Da bi se sistem dijagnosticirao, potrebna je testna oprema, lista određenih merenja koja treba obaviti (uključujući skup signala i testne tačke), kao i softver za dijagnostiku koji obrađuje podatke merenja. Sličan skup podataka i alate treba dati testnom inženjeru u proizvodnji da bi se formirala slika o prinosu proizvodnje, kao i povratna sprega. Smatra se da projektanti najbolje poznaju proizvod i da su najpozvaniji da generišu testne signale za potrebe dijagnostike. Oni su u stanju da primene koncept tzv. simulacije pre testa koji omogućava formiranje

rečnika defekata sa iscrpnom listom defekata i odgovarajućim odzivima. Rečnik defekata je zapravo tabela koja predstavlja preslikavanje iz liste defekata u listu pogrešnih (ili možda, ispravnih) odziva. Na taj način dijagnostika postaje pretraživanje rečnika defekata. U ovom radu se tvrdi da su veštačke neuronske mreže, kao univerzalni aproksimatori, najbolji način za pretragu, i samim tim, za dijagnostiku kola.

Prvo poglavlje disertacije daje kratki opis prirodnog neurona, a zatim i veštačkog, kao osnovne gradivne jedinice svih tipova veštačkih neuronskih mreža. Opisana je osnovna struktura veštačke neuronske mreže korišćena u daljem radu, nerekurventna neuronska mreža. Razmotreni su i problemi koji se tiču složenosti mreže neophodne za aproksimaciju određene funkcije.

U drugom poglavlju opisani su osnovni koncepti dijagnostike. Najpre je predstavljen uopšteni dijagnostički sistem, a zatim su nabrojani pristupi dijagnostici elektronskih kola.

U trećem poglavlju dat je prvi primer primene veštačkih neuronskih mreža na dijagnostiku elektronskih kola, primer dijagnostike defekata u otpornom kolu. Ovaj primer zapravo ilustruje sam koncept dijagnostike primenjen u ovom radu. U tom primeru dijagnosticirani su samo katastrofalni defekti, slučajevi otvorene i prekinute grane u kolu. Sposobnost generalizacije mreže pokazana je velikim brojem primera, jer neuronska mreža uspešno detektuje defekte čak i kada se na njen ulaz vodi signal sa šumom.

Četvrto poglavlje opisuje primer dijagnostike nelinearnog dinamičkog kola. Naime, poznato je da je analogna elektronska kola, koja klasifikujemo kao nelinearna reaktivna kola sa nelinearnim reaktivnim elementima, teško dijagnosticirati. Osim velikog broja mogućih defekata, ovo je i posledica nelinearnosti ovih kola. Čak i linearna kola (koja imaju linearnu zavisnost ulaz-izlaz) imaju nelinearnu vezu parametara kola i izlaznog odziva. Aktivne mreže mogu da se linearizuju i razmatraju kao takve u situacijama kad su promene signala i parametara male u odnosu na nominalne vrednosti. Kada su u pitanju defekti, u kolu su prisutne velike promene parametara, ili čak katastrofalni defekti. U disertaciji je dat primer dijagnostike i parametarskih i katastrofalnih defekata u kolu operacionog pojačavača koji se sastoji od sedam tranzistora. Dokazana je i sposobnost generalizacije neuronske mreže.

Sveprisutnost tehnologije integrisanih kola donela je sa sobom i probleme koji se tiču testiranja i dijagnostike. Sve veći broj hibridnih i digitalnih kola još više komplikuje problem. Postaje sve složenije odrediti skup ulaznih testnih signala i izlazna merenja koja treba da obezbede veliku pokrivenost defekata. Postoji takođe i problem sa vremenom dijagnostike, čak i sa najsavremenijom opremom. U petom poglavlju disertacije biće pokazani primeri dijagnostike hibridnog elektronskog kola, tako što će posebna pažnja biti usmerena na testne signale, broj mernih tačaka, kao i što iscrpnije rečnike defekata. Razmatraće se i parametarski i katastrofalni defekti, koje će moći da istovremeno dijagnosticira ista neuronska mreža.

Poslednji primer dijagnostike pokazan je u šestom poglavlju, gde će biti razmatrani i modelovanje, simulacija i dijagnostika defekata u okviru mikro-elektro-mehaničkog sistema. Pri tome će neuronske mreže biti upotrebljene i za modelovanje ispravnih i defektnih mikro-elektro-mehaničkih komponenata, čime se znatno ubrzava vreme simulacije ovakvih sistema i omogućava efikasno kreiranje rečnika defekata.

Na kraju disertacije je zaključak. Sledi spisak korišćene literature.

# 1 Veštačke neuronske mreže

Veštačke neuronske mreže (VNM) su nastale u pokušaju čoveka da imitira biološku osnovu ljudske inteligencije [2], [3]. Naime, osnovna procesna jedinica veštačke neuronske mreže treba da imitira ponašanje prirodnog neurona kako po svojoj strukturi, tako i po funkciji. Međusobne veze između tih procesnih jedinica su tako organizovane da imitiraju delove ljudskog nervnog sistema. Neke strukture su tako napravljene da obavljaju preslikavanja nekih pobuda u odzive, dok druge pokušavaju da oponašaju ponašanje memorije mozga koji je zapravo memorija sa sadržajem koji se adresira.

Znanje se “pamti” u odgovarajućoj strukturi VNM sa specifičnim koeficijentima. Koeficijenti i struktura mreže se podešavaju u zavisnosti od problema koji se modeluje. Taj proces podešavanja naziva se učenje. Učenje se obično obavlja *off-line*. Ovo znači da su nakon podešavanja koeficijenti fiksirani i VNM se smatra završenom. U drugom slučaju, koeficijenti se podešavaju za vreme eksploatacije mreže, *on-line*, što znači da se VNM prilagođava novim situacijama koje se pojavljuju.

U daljem tekstu opisaćemo ukratko prirodni, a zatim i veštački neuron kao osnovnu gradivnu jedinicu svih tipova VNM [4]. Zatim će biti opisana osnovna struktura VNM korišćena u daljem radu.


## 1.1 Prirodni neuron

Izgled tipičnog prirodnog neurona u uprošćenom obliku prikazan je na Slici 1.1. 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) većeg broja drugih neurona. Spojevi između neurona zovu se sinapse i igraju ključnu ulogu u funkcionisanju celog sistema.

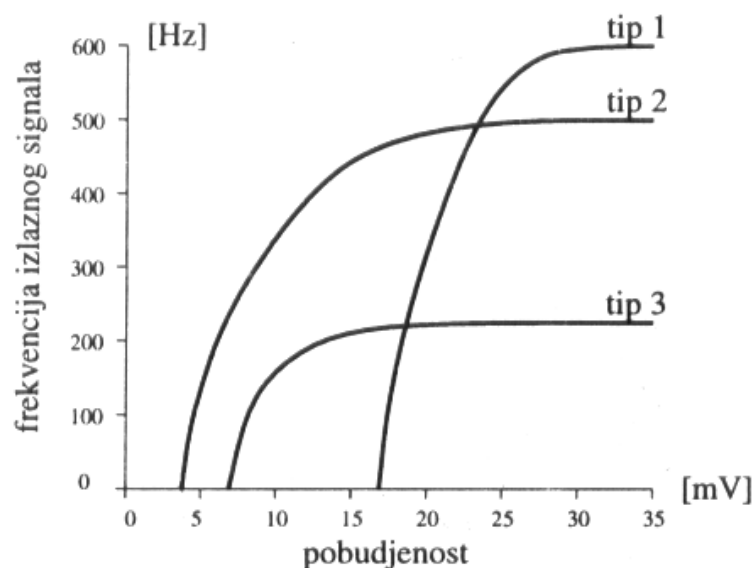
U normalnom, nepobuđenom stanju, potencijal some iznosi tipično oko  $-70\text{mV}$ . U tom slučaju ne postoji nikakva izlazna aktivnost.

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 amplitude  $100\text{mV}$ , a brzina prenosa duž aksona je  $120\text{m/s}$  bez slabljenja.



**Slika 1.1** *Struktura tipičnog prirodnog neurona*


Na Slici 1.2 može se videti jačina pobude u funkciji od frekvencije izlaznog signala za različite prirodne neurone. Na slici se mogu razlikovati tri oblasti: oblast ispod praga (bez generisanja aktivacionih impulsa), linearna oblast i oblast zasićenja. Naime, za jake pobude izlazna frekvencija odlazi u zasićenje i tako ograničava odziv neurona na maksimalnu vrednost.



**Slika 1.2 Prenosna (aktivaciona) karakteristika 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 koji 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.

Ljudski nervni sistem sastoji se od oko  $10^{11}$  prirodnih neurona koji su grupisani u oko sto podistema, i 60 triliona sinapsi. Svaki podsystem ima svoje dužnosti u obavljanju različitih zadataka. Neuroni u okviru svakog podistema su jako povezani. Podsystemi su, takođe, međusobno povezani veoma jakim vezama. Nervni sistem čoveka može se predstaviti kao trostepeni sistem [2], kao što je prikazano na Slici 1.3.




**Slika 1.3 Nervni sistem predstavljen kao trostepeni sistem**

U centru sistema je mozak, na Slici 1.3 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 strukturna 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.

## 1.2 Veštački neuron

Sa stanovišta modelovanja, prirodni neuron je složena struktura. Kao prvo, ima desetine hiljada ulaznih sinapsi. Broj izlaznih sinapsi je manji, ali nije mali - sa stanovišta teorije električnih kola. Zatim, neuron ima dinamička svojstva – integrali i sadrži neku vrstu VCO. Pri modelovanju se, međutim, najčešće koriste statički signali sa izlaznom frekvencijom koja se modeluje kao izlazni “napon”.



Slika 1.4 Nelinearni model neurona

Uopštena blok šema statičkog modela neurona prikazana je na Slici 1.4. Može se uočiti analogija sa modelom prirodnog neurona (Slika 1.1). Sinapse iz prirodnog modela ovde su predstavljene sinaptičkim težinama. Zapravo, signal  $x_j$  na ulazu sinapse  $j$  koji je povezan sa neuronom  $k$  množi se težinom  $w_{kj}$ . Težina  $w_{kj}$  je pozitivna ako je sinapsa ekscitatorna, a negativna ukoliko je sinapsa inhibitorna. Sabirač na Slici modeluje osobinu some da sabira signale sa više ulaza, a funkcija  $\varphi(\cdot)$  je nelinearna, aktivaciona funkcija neurona. Napon praga,  $\theta_k$ , predstavlja napon koji utiče na mrežu spolja, i tako menja izlazni napon za određeni nivo.

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 (1.1) i (1.2):

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (1.1)$$

$$y_k = \varphi(u_k - \theta_k) \quad (1.2)$$

U literaturi je u upotrebi više tipova aktivacionih funkcija.

Najjednostavnija je linearna aktivaciona funkcija:

$$\varphi(u) = u - \theta \quad (1.3)$$



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:


$$\varphi(u) = \begin{cases} 1 & \text{ako je } u \geq \theta \\ -1 & \text{ako je } u < \theta \end{cases} \quad (1.4)$$

Klasu sigmoidnih aktivacionih funkcija, koje se najviše koriste, čine logistička funkcija (1.5) i funkcija tangens hiperbolički (1.6):

$$\varphi(u) = \frac{1}{1 + e^{-(u-\theta)}} \quad (1.5)$$

$$\varphi(u) = \frac{e^{(u-\theta)} - e^{-(u-\theta)}}{e^{(u-\theta)} + e^{-(u-\theta)}} \quad (1.6)$$

U svim aktivacionim funkcijama  $\theta$  je ona vrednost za  $u$  čije prekoračenje dovodi do promene stanja neurona. Drugim rečima,  $\theta$  predstavlja prag i ima sličnu ulogu kao i aktivacioni prag prirodnog neurona. Na Slici 1.5 grafički su prikazane linearna i logistička funkcija.




Slika 1.5 Prenosne funkcije. a) linearna, b) logistička

### 1.3 Nerekurentna (*feed-forward*) neuronska mreža

Arhitektura neuronske mreže koja se koristi u daljem radu prikazana je na Slici 1.6 [5].

To je potpuno povezana nerekurentna neuronska mreža, sadrži jedan skriveni sloj, a signali se prostiru samo u jednom smeru.



**Slika 1.6 Nerekurentna neuronska mreža sa jednim skrivenim slojem**

$n$ ,  $n_0$  i  $n'$  predstavljaju broj neurona u ulaznom, skrivenom i izlaznom sloju, respektivno.  $\theta_{ji}$  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:

$$z_i = \frac{1}{1 + e^{-\lambda_1 \cdot s_i}} \quad (1.7)$$

Za neurone u izlaznom sloju koristi se linearna funkcija:

$$y_i = \lambda_2 \cdot q_i \quad (1.8)$$

Parametri  $\lambda_1$  i  $\lambda_2$  u izrazima (1.7) i (1.8) 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 (1.9) i (1.10):

$$s_i = \sum_{j=1}^n w(1, j)(2, i) \cdot x_j + \theta_{2i} \quad (1.9)$$

$$q_i = \sum_{j=1}^{n_0} w(2, j)(3, i) \cdot z_j + \theta_{3i} \quad (1.10)$$

Iz jednačina (1.9) i (1.10) 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.

## 1.4 Složenost mreže

Topologiju neuronske mreže sa Slike 1.6 treba prilagoditi konkretnom problemu, tj. treba odrediti broj skrivenih neurona, i eventualno, broj skrivenih slojeva (mreža na Slici 1.6 ima samo jedan skriveni sloj, što ne znači da ne može imati više ukoliko je to potrebno). 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 [6]. 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 zavisi 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.

Potreban 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 [6].

Broj neurona u skrivenom sloju je od izrazitog značaja [7]. Mali broj neurona u skrivenom sloju dovodi do mreže koja nije dobro obučena odnosno ne može da aproksimira željenu funkciju. Preveliki broj neurona uslovljava predugo vreme obučavanja, a može da dovede i do prezasićenja mreže [6]. 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:

$$n_0 = \sqrt{n \cdot n'} \quad (1.11)$$

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, korišćemo 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  $N$  [8].

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 značajnijem napretku, a zadovoljni smo odzivom mreže.

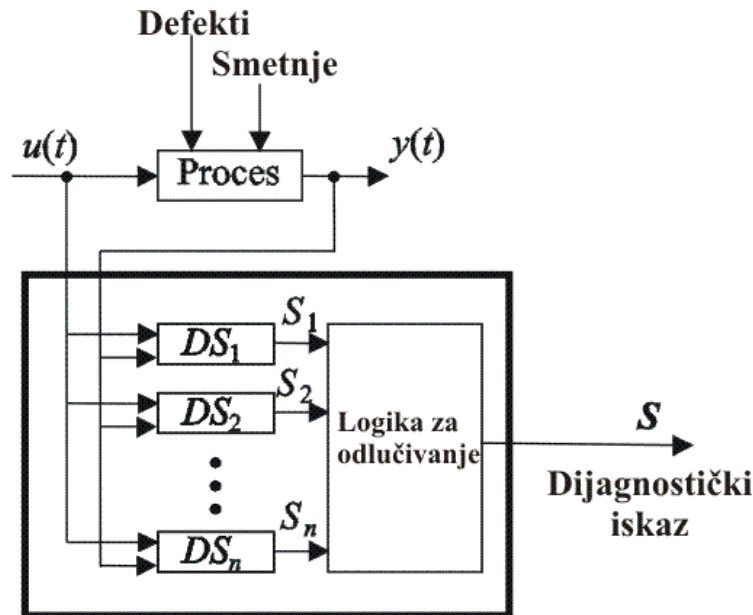
## 2 Osnovni koncepti dijagnostike

Svaki put kada pomislimo na nešto što ne funkcioniše kako bi trebalo, započinjemo proces dijagnostike. Samim tim je dijagnostika uobičajena aktivnost u svakodnevnom životu [9].

Svaki složeni sistem podložan je defektima ili kvarovima. U najopštijem slučaju, defekt je svaka promena u električnom kolu ili sistemu koja ga sprečava da radi ispravno. Dijagnostika treba da omogući da se ustanovi priroda i mesto defekta u kolu. Na osnovu ispravne dijagnostike može se intervenisati u korekciji proizvodnog procesa, odnosno može se zameniti neispravna komponenta prilikom održavanja sistema koji je u pogonu.

Opšta struktura dijagnostičkog sistema prikazana je na Slici 2.1. Signali  $u(t)$  i  $y(t)$  su ulaz u sistem i izlaz iz sistema, respektivno. Defekti i smetnje (u ovom slučaju su posledica greške merenja) takođe utiču na sistem koji se ispituje, ovde označen kao "Proces", ali ne postoji informacija o vrednostima ovih grešaka. Zadatak dijagnostičkog sistema je da generiše dijagnostički iskaz  $S$ , koji sadrži informaciju o prirodi greške koja može da objasni ponašanje Procesu, pri čemu smatramo da je dijagnostički sistem pasivan, tj. ne može da utiče na sam Proces.

Čitav dijagnostički sistem može da se podeli na manje delove koje ovde posmatramo kao testove. Ovi testovi su zapravo dijagnostički sistemi,  $DS_i$ . Takođe se smatra da svaki od njih generiše dijagnostički iskaz  $S_i$ . Funkcija logike za odlučivanje je da na osnovu ovih iskaza formira dijagnostički iskaz  $S$ .



Slika 2.1. Uopšteni dijagnostički sistem

Broj mogućih defekta u elektronskom sistemu može biti veoma veliki i defekti se mogu nalaziti svuda u sistemu. Da bi se obavila dijagnostika pod ovakvim uslovima, često se koristi hijerarhijski pristup, kada se sukcesivno generišu dijagnostički iskazi na svakom nivou, tako da je nivo opisa sistema sve niži sa približavanjem samom defektu [10], [11]. Ovo omogućava da se istovremeno razmatraju manji skupovi defekata za određeni hijerarhijski nivo. Moderni automatski generatori testnih uzoraka mogu da podržavaju ovakve koncepte [12].

## 2.1 Uvod u dijagnostiku

Pažnja mnogih istraživača [13] usmerena je ka otkrivanju novih alata koji bi pomogli u procesu dijagnostike, ili, koji bi, u najboljem slučaju, izvršavali taj proces automatski. Takvi alati su veliki izazov za inženjere imajući u vidu da je dijagnostika proces gde postoji skup podataka koji, u opštem slučaju, generiše brojne hipoteze među kojima treba naći rešenje.

Da bi se došlo do rešenja, poslednjih decenija korišćeni su novi koncepti koji pokušavaju da kreiraju sistem koji sadrži "inteligentne karakteristike", kao što su: koncepti zasnovani na modelu (*model-based concepts*) [9], veštačka inteligencija zasnovana na pravilu (*production rule based artificial intelligence*) [14], veštačke neuronske mreže [15], genetski algoritmi [16], fazi zaključivanje (*fuzzy-reasoning*) [17].

Da bismo shvatili kako se veštačke neuronske mreže primenjuju na dijagnostiku analognih i hibridnih elektronskih kola, najpre će biti objašnjen sam koncept dijagnostike.

Dijagnostika je kompleksna inženjerska aktivnost koja se oslanja na discipline kao što su projektovanje i testiranje ali i mnoge druge. Smatra se da inženjer održavanja treba da reaguje čim se sistem pokvari. Da bi se sistem dijagnosticirao, potrebna je testna oprema, lista određenih merenja koja treba obaviti (uključujući skup signala i testne tačke), kao i softver za dijagnostiku koji obrađuje podatke merenja. Sličan skup podataka i alate treba dati testnom inženjeru u proizvodnji da bi se formirala slika o prinosu proizvodnje, kao i povratna sprega. Smatra se da projektanti najbolje poznaju proizvod i da su najpozvaniji da generišu testne signale za potrebe dijagnostike. Oni su u stanju da primene koncept tzv. simulacije pre testa (*simulation-before-test, SBT*) koji

omogućava formiranje rečnika defekata sa iscrpnom listom defekata i odgovarajućim odzivima. Rečnik defekata je zapravo tabela koja predstavlja preslikavanje iz liste defekata u listu pogrešnih (ili možda, ispravnih) odziva. Na taj način dijagnostika postaje pretraživanje rečnika defekata.

S druge strane, moderne tehnike dijagnostike koje koriste tradicionalnu veštačku inteligenciju i metode zaključivanja (*reasoning*) spadaju u kategoriju simulacije posle testa (*simulation after test, SAT*). Dijagnostika sistema bi tada produžila vreme proizvodnje [18]. *SBT* sistemi obično zahtevaju veće početne troškove, ali obezbeđuju bržu proizvodnju.

U ovom radu se tvrdi da su veštačke neuronske mreže, kao univerzalni aproksimatori [19], najbolji način za pretragu, i samim tim, za dijagnostiku kola.

## 2.2 Dijagnostički sistemi

Kao što smo pokazali u uvodu, dijagnostički sistem je sistem koji može da prepozna prirodu problema ispitivanjem posmatranih simptoma. Izlaz iz sistema je dijagnostički iskaz, a obično se na ulaz vodi skup simptoma (posmatranja ili merenja predstavljena u nekom formatu koji računar može da pročita). Zadatak sistema je da prepozna moguće uzroke koji bi mogli da objasne uočene simptome. Da bi se obavila ova funkcija, dijagnostički sistem mora da poseduje neko "znanje". Potrebno znanje ili inženjer unosi u sistem, ili sistem mora da bude sposoban da sam stekne određeno znanje, na osnovu iskustva.

Prvi pristup, koji se naziva *knowledge engineering*, koristi se u izradi dijagnostičkih pravila za ekspertne sisteme ili za sisteme koji se zasnivaju na znanju (*knowledge-based systems*).

Drugi pristup oslanja se na korišćenje tehnike mašinskog učenja (*machine learning technique*) za automatsko prikupljanje podataka. Veštačka inteligencija nudi širok spektar pristupa inteligentnoj dijagnostici, tako da svaki pristup ima svoje prednosti i mane, u zavisnosti od problema koji se razmatra.

Naš cilj je da napravimo sistem koji efikasno obavlja tačnu dijagnostiku. Pristupi dijagnostici razlikuju se na osnovu toga kako će sistem doći do veze između posmatranih simptoma i odgovarajuće dijagnostike, kako će sistem predstaviti ovu vezu, i kako će to predstavljanje iskoristiti za dijagnostiku defekata.

Razmotrimo pristup koji se koristi kada je na raspolaganju model sistema koji detaljno prikazuje sistem, tj. njegove komponente i njihovu organizaciju. Problem dijagnostike se javlja kada se posmatrano ponašanje sistema ne slaže sa njegovim očekivanim ponašanjem, i zadatak je pronaći neispravnu komponentu sistema. Međutim, u mnogim praktičnim problemima, nisu nam dostupni precizni modeli sistema. Na primer, nemamo precizan model odziva ljudskog organizma na različita sredstva koja uzrokuju bolesti. Zato se medicinska dijagnostika ne zasniva na modelu, ili bar ne u potpunosti. Uobičajeno je u ovakvim slučajevima osloniti se na heurističko znanje o problemu. Eksperti bi trebalo da sumiraju svoje znanje (dobijeno iskustvom) u formu kvalitativnih principa. Ovi principi se onda preslikavaju, ili kodiraju, u sistem koji se zasniva na znanju. Tako u stvari taj sistem modeluje dijagnostička razmatranja eksperata. Efikasnost ovog pristupa naravno zavisi od verodostojnosti kodiranja kao i od kvaliteta iskustva eksperata. Ovi principi zasnivaju se zapravo na zapažanjima eksperta, dok se stvarno ponašanje sistema eksplicitno ne modeluje. Zato je ovaj pristup veoma praktičan u situacijama kada precizan model nije na raspolaganju.

### 2.2.1 Ekspertni sistemi

Ekspertni sistemi [20] su primer sistema koji se zasnivaju na znanju. To su zapravo programi koji modeluju znanje i mogućnosti zaključivanja kvalifikovanih specijalista u veoma specijalizovanim oblastima. Ovakvi sistemi se sastoje od tri osnovna modula: *baza znanja* koja sakuplja ekspertize specijalista, *mehanizam zaključaka* koji oponaša proces razmišljanja, i *radna memorija* koja se koristi kao područje za privremene podatke. U postupku rešavanja problema radna memorija čuva podatke koje je uneo

korisnik (npr. simptome) i pomoćne zaključke iz mehanizma zaključaka. Projektovanje ekspertnog sistema može biti veliki izazov. Najpre, eksperti koji pribavljaju podatke moraju biti u stanju da ga uobliče u ekspertizu. Zatim, inženjeri koji rade sa ekspertima treba da razumeju znanje eksperata u toj meri da izaberu dobar vid predstavljanja u bazi znanja, kao i da odrede odgovarajući mehanizam zaključaka. I na kraju, projektovanje baze znanja i mehanizma zaključaka, strategije za rešavanje konflikata, redosled po kome podaci ulaze u radnu memoriju, mogu značajno uticati, čineći zadatak testiranja i debugiranja ekspertnog sistema veoma komplikovanim u praksi.

### 2.2.2 Sistemi zasnovani na modelu

Nasuprot ekspertnim sistemima, sistemi zasnovani na modelu (*model-based systems*) imaju za cilj da modeluju osnovne principe rada sistema. Iako je čitav model sistema ili nedostupan ili nepodešen za rukovanje u mnogim praktičnim situacijama, ovaj pristup je ipak koristan u slučajevima kada su fizički principi funkcionisanja poznati (npr. veštački sistemi). Na primer, automobili se projektuju i proizvode na osnovu principa koji se temelje u fizici, i koji se mogu iskoristiti za pravljenje detaljnog modela automobila. Sistem zasnovan na modelu za dijagnostiku otkaza delova kod automobila može se napraviti formulisanjem pravila koja obuhvataju uzročno i funkcionalno znanje u ovom domenu, tj. pravila koja povezuju komponente automobila i ponašanje koje se manifestuje na određen način.

### 2.2.3 RMS sistemi

RMS sistemi (*reason maintenance systems*) se mogu iskoristiti za implementiranje dijagnostičkih sistema zasnovanih na modelu. RMS sistemi obično sadrže bazu podataka sa pravilima koja predstavljaju poznate činjenice i radne principe sistema. Za neke činjenice se zna da su tačne, dok se za druge samo pretpostavlja. Pravila se onda mogu, na osnovu ovih činjenica i pretpostavki, iskoristiti za izvlačenje zaključaka. Međutim, ako se za neke ranije pretpostavke ustanovi da su pogrešne, baza podataka mora da se ažurira. Ne treba promeniti samo istinitost pretpostavki, već i zaključci koji su izvučeni na osnovu tih pretpostavki moraju biti revidirani. Iako sistemi zasnovani na modelu imaju sposobnost da proizvedu tačnu dijagnostiku, imaju nekoliko nedostataka koji ih čine neprimenljivim u mnogim realnim kontekstima. Potrebu za preciznim modelom sistema nije moguće zadovoljiti u mnogim slučajevima. Zatim, izračunavanje svih dijagnostika za posmatrani defekt može biti računarski neizvodljivo za mnoge realne dijagnostičke primene. Jedna alternativa je izračunavanje samo nekoliko verovatnih dijagnostika. Takođe, moguće je koristiti i neke hibridne pristupe sa metodama koje će biti kasnije opisane.

### 2.2.4 CBR sistemi

U CBR sistemima (*case-based reasoning systems*) znanje se čuva u formi *slučajeva*. Pod slučajem se podrazumeva situacija koja se desila u prošlosti i rezultirala je nekom relevantnom akcijom. Slučajevi se čuvaju u biblioteci, pogodno indeksirani kako bi se olakšalo njihovo ponovno pronalaženje. Kada se atributima na ulazu dodeli određena situacija ili iskustvo, vrši se pretraživanje biblioteke kako bi se našao slučaj koji najviše odgovara (ili skup slučajeva) u odnosu na neki kriterijum poklapanja. Ako nova situacija ne odgovara staroj u potpunosti, rešenje koje je ponudio izabrani slučaj može biti modifikovano kako bi odgovaralo novoj situaciji, u procesu poznatom kao adaptacija. CBR sistemi se znatno razlikuju od ekspertnih sistema i RMS sistema. Dijagnostičko znanje se ne čuva ni kao eksplicitni model sistema, ni u formi kvalitativnih, heurističkih pravila, već je predstavljeno implicitno skladištem slučajeva. Znanje koje je specifično za problem koristi se za kreiranje heuristike za postupak poklapanja. CBR sistemi imaju sposobnost (mada ograničenu) da se prilagode promenama u okviru sistema jer te promene jednostavno rezultiraju promenama čuvanih slučajeva. Možemo primetiti da kod hijerarhijski organizovanih biblioteka slučajeva, promene slučajeva mogu zahtevati reorganizaciju čitave biblioteke. Nedostatak CBR sistema je velika cena izračunavanja vezana za postupak poklapanja,

kao i velika cena smeštanja podataka vezana za organizaciju biblioteke slučajeva. Primenljivost ovog pristupa veoma zavisi od prirode zadatka i načina predstavljanja slučajeva.

### 2.2.5 Induktivni dijagnostički sistemi

Sistemi o kojima je do sada bilo reči zahtevaju da projektant unese određeno “znanje” neophodno za dijagnostiku ili u bazu znanja ili u proces zaključivanja. Sistemi induktivnog učenja nude rešenje koje izbegava dugotrajan, skup i naporan posao izdvajanja svog tog znanja. Ovakvi sistemi mogu da nauče aproksimativni model tog sistema na osnovu dovoljnog broja primera ili uzoraka. Za razliku od CBR sistema koji jednostavno čuvaju primere u memoriji, induktivni sistemi koriste primere da bi uspostavili veze između simptoma i dijagnostike. Tehnički, sistem indukuje odgovarajući skup klasifikacionih pravila na osnovu skupa za obučavanje, odnosno skupa primera koje obezbeđuje korisnik. Uspeh induktivnog učenja zavisi od toga da li su ti primeri reprezentativni, jer bi u suprotnom klasifikaciona pravila mogla pogrešno da okarakterišu sistem. Kada je induktivni sistem jednom obučen, može se koristiti i za primere koji nisu korišćeni u procesu učenja, što znači da sistem ima svojstvo generalizacije. Induktivni sistemi koji se koriste za dijagnostiku su: stabla odluke, veštačke neuronske mreže i neki statistički pristupi.

Stablo odluke sastoji se od list-čvorova koji predstavljaju imena klasa i unutrašnjih čvorova koji su zapravo testovi za simptome, tako da postoji grana za svaki mogući test. Kada se stablo odluke jednom napravi, može da se koristi za klasifikaciju ulaznih primera. Polazi se od korena stabla, utvrđuje se određeni test, i bira se odgovarajuća grana. Tako se nastavlja dok se ne dođe do list-čvora, i u toj tački se primer pridružuje klasi koju predstavlja taj list-čvor. Sve dok skup za obučavanje nema kontradiktorne primere, uvek je moguće konstruisati stablo odluke koje ispravno klasifikuje sve naučene primere. Obično postoji mnogo stabala odluke koja su konzistentna sa datim skupom primera, tako da je cilj indukcije da nekako odredi stablo odluke koje ne samo da ispravno klasifikuje primere za obučavanje, već ima i veliku sposobnost generalizacije.

Veštačke neuronske mreže su paralelne, nelinearne distribuirane strukture koje sadrže lokalnu memoriju, obrađuju ulazne podatke na određeni način, i sastoje se od elemenata koji se nazivaju neuroni. Njihove prednosti su paralelna obrada ulaznih podataka, sposobnost adaptacije putem modifikacije njihove računarske strukture, i dobre performanse u prisustvu šuma ili defekta komponenata. Kako je njima posvećeno čitavo poglavlje u ovoj disertaciji, ovde neće biti detaljnije razmatrane.

Statistička teorija podataka se primenjuje u slučajevima kada znanje nije potpuno određeno i definisano. Tada se postavlja pitanje kako verovatnoća može biti ugrađena u logičku bazu podataka i da li je neophodno koristiti metode koje računaju verovatnoće na osnovu posmatranih podataka ili na osnovu podataka dobijenih od nekoliko stručnjaka koji se međusobno razlikuju. *Bayes*-ova statistika se primenjuje za rešavanje ovakvih problema, i osnova notacije je oznaka uslovne verovatnoće:  $P(H|E)$ . Ovaj izraz označava verovatnoću hipoteze  $H$  da imamo posmatrani dokaz  $E$ . Da bismo ovo izračunali moramo da uzmemo u obzir prethodnu verovatnoću  $H$  (verovatnoću koju bismo dodelili  $H$  da nemamo nikakav dokaz) i opseg do kog  $E$  obezbeđuje dokaz za  $H$ . *Bayes*-ova teorema tvrdi da:

$$P(H_i|E) = \frac{P(E|H_i)P(H_i)}{\sum_{n=1}^k P(E|H_n)P(H_n)} \quad (2.1)$$



gde je:

$P(H_i|E)$  = verovatnoća da je hipoteza  $H_i$  istinita za dati dokaz  $E$ .

$P(E|H_i)$  = verovatnoća da ćemo videti dati dokaz  $E$  da je hipoteza  $H_i$  istinita.

$P(H_i)$  = a priori verovatnoća da je hipoteza  $H_i$  istinita u odsustvu bilo kog dokaza.

$k$  = broj mogućih hipoteza.

Kao rezultat dobija se skup uslovnih verovatnoća koje zadovoljavaju svaku hipotezu.

### 2.3 Dijagnostika zasnovana na veštačkoj inteligenciji

U veštačkoj inteligenciji postoji nekoliko pristupa dijagnostici, [21], [22], [23], tako da je važno na osnovu svih tih pristupa generalizovati neke opšte principe na osnovu komparativnih studija. Ovde će proces dijagnostike biti opisan u okviru takozvane teorije kompetencije dijagnostike (CTD) [9].

CTD doprinosi na dva načina. Kao prvo, definiše razlaganje dijagnostike i dijagnostičke ciljeve na njene sastavne delove. Zatim, opisuje kako je moguće postići ove ciljeve pod određenim uslovima. Na osnovu tih postupaka i razmatranja, može se napraviti mnoštvo dijagnostičkih strategija. Štaviše, možemo bolje razumeti postojeće strategije.

CTD razlaže dijagnostiku u skup podzadataka, ili metoda za rešavanje problema. Metodi za rešavanje problema se sami mogu sastojati od različitih podzadataka, tako da se i oni razlažu sve dok se ne dođe do osnovnih zaključaka. Na taj način zadaci i metode mogu biti organizovani u zadatak-metod dekompozicionu strukturu. Imajući ovo u vidu, dijagnostički ciljevi se razlažu na podciljeve sve dok se do ciljeva ne može doći direktno zaključivanjem.

Dijagnostika se sastoji od tri podzadatka:

*Detekcija simptoma*: pronalaženje da li je "reklamacija" u stvari simptom (posmatranje koje odstupa od očekivanja).

*Generisanje hipoteza*: generisanje mogućih uzroka zasnovano na simptomima ili prvobitnim posmatranjima.

*Odvajanje hipoteza*: korišćenje dodatnih posmatranja da bi se izvršilo odvajanje među generisanim hipotezama.


Okvirni postupak modelovanja odslikava konvergenciju pristupa koji su orijentisani ka zadatku (*task-oriented*). Glavni elementi su:

- (1) zadaci,
- (2) metode rešavanja problema,
- (3) osnovni zaključci, i
- (4) ciljevi.

Zadatak ima cilj, i karakterišu ga tip ulaza i izlaza koje prima i proizvodi. Cilj zadatka je specifikacija onoga što se mora postići, i definiše vezu između ulaza i izlaza. U stvari, cilj dijagnostike je pronaći rešenje koji razjašnjava i početna i kasnija posmatranja.

Metod rešavanja problema definiše kako se može postići cilj zadatka. Metod razlaže zadatak u podzadatke ili primitivne zaključke i specificira tok podataka između njih. Kontrolno znanje određuje kako ovi podzadaci mogu postići cilj metoda.

Osnovni zaključak je zaključak do kog se može doći korišćenjem znanja o sistemu da bi se postigao cilj. On ima telo zaključka koje specificira kako se postiže cilj.



**Slika 2.2: Dijagram toka podataka primarne dijagnostičke metode**

Cilj se može razdvojiti u podciljeve tamo gde ostvarenje podcilja podrazumeva realizaciju matičnog cilja. Zadaci i ciljevi definišu šta treba postići, dok metodi specificiraju kako se oni postižu, tako da se razdvajanje ciljeva može izraziti u smislu zadataka i zaključnih ciljeva.

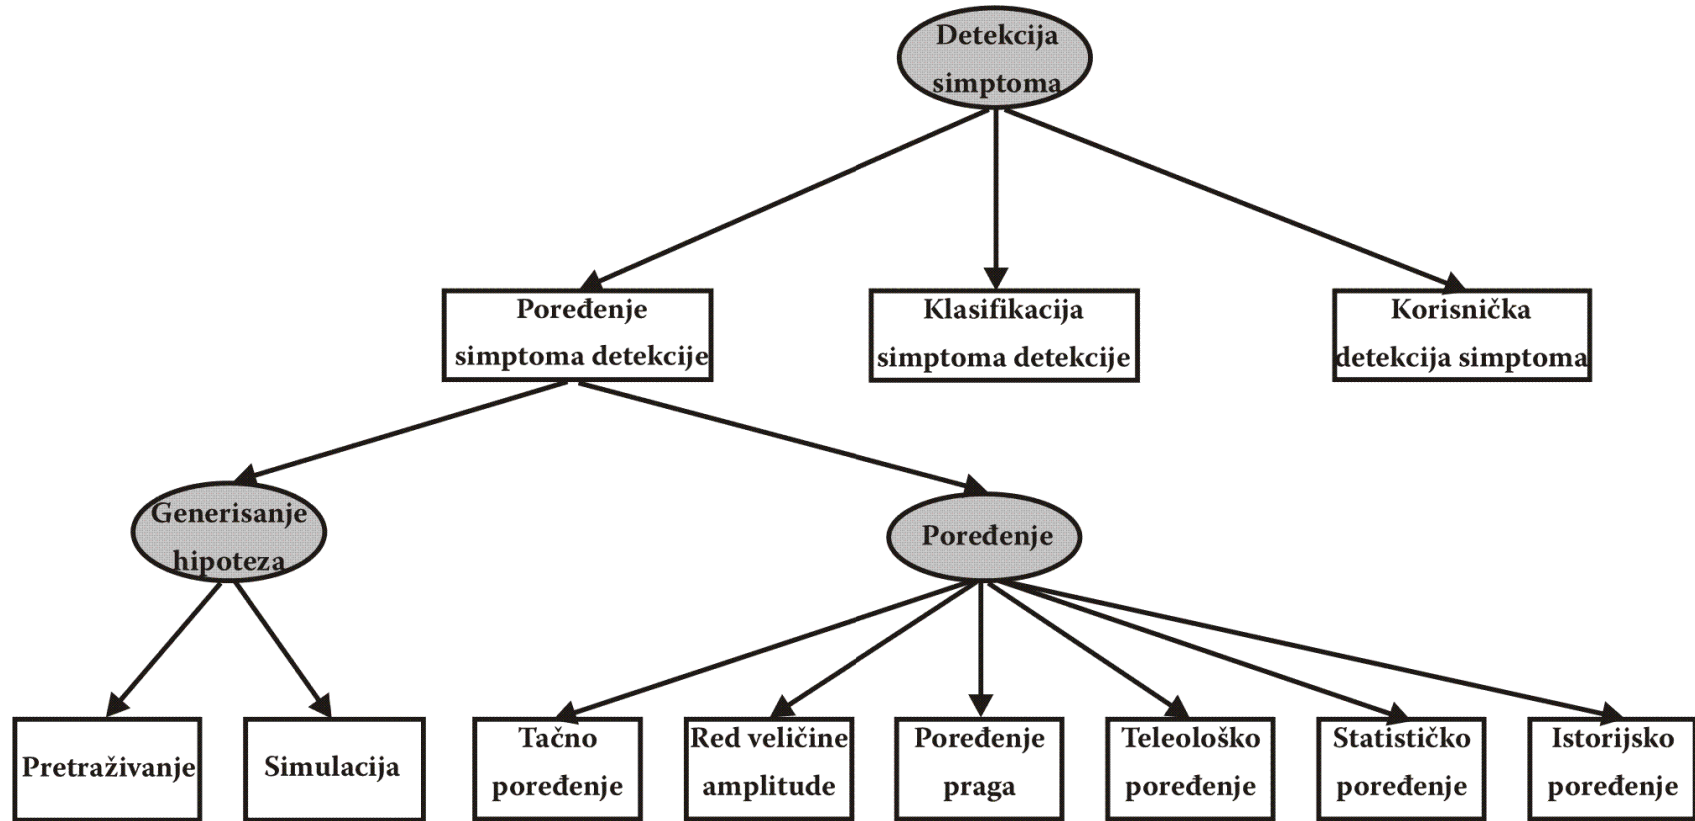
Tri podzadatka dijagnostike, detekcija simptoma, generisanje hipoteza i odvajanje hipoteza čine primarnu teoriju dijagnostike (*PDM- prime diagnostic method*). Drugim rečima, primena primarne teorije dijagnostike na dijagnostiku rezultira sa tri podzadatka, što predstavlja familiju metoda.

Kao što je prikazano na Slici 2.2, početna posmatranja su ulaz za zadatak detekcije simptoma, gde se ispravnosti ili neispravnosti pridružuju posmatranjima. Ovo je zatim ulaz za zadatak generisanja hipoteza, koji proizvodi skup hipoteza kao ulaznu informaciju za zadatak odvajanja hipoteza. Ovde se uzimaju u obzir i dodatna posmatranja. Izlaz iz zadatka odvajanja, koji je takođe i izlaz PDM-a, je skup dijagnostika, od kojih svaka objašnjava i početna i dodatna razmatranja.

Sada će biti detaljnije razmotrena tri podzadatka dijagnostike.

### 2.3.1 Zadatak detekcije simptoma

Postoji nekoliko metoda za detekciju ispravnosti i neispravnosti posmatranja. Slika 2.3 pokazuje različite metode, a i kako komparativni metod može da razloži na delove podzadatke i osnovne zaključke. Metodi su predstavljeni pravougaonicima, a zadaci elipsama.



Slika 2.3 Parcijalno razlaganje zadatak-metod za zadatak detekcije simptoma

*Metod poređenja* generiše očekivanu vrednost za ulazna posmatranja i onda poredi posmatranja i očekivanja. Tako se dobija podatak koji sadrži jedan od dva rezultata: jednaki ili nejednaki. Ako je procenjeno da su očekivanja i posmatranja jednaki, posmatranje se smatra ispravnim. U suprotnom je neispravno.

*Klasifikacioni metod* pretpostavlja dostupnost klasifikacionog znanja o sistemu; tim putem se početna posmatranja klasifikuju kao ispravna ili neispravna.

*Korisnički metod* se oslanja na korisnika koji ima znanje na osnovu kojeg odlučuje o posmatranjima.

U okviru zadatka generisanja očekivanja, koriste se dva metoda za generisanje očekivanja za posmatranje.

*Metod pretraživanja* konsultuje bazu podataka gde su smeštene sve relevantne očekivane vrednosti.

*Simulacioni metod* računa vrednosti na osnovu simulacije modela uređaja.

U okviru zadatka poređenja odlučuje se da li su posmatranje i očekivanje jednaki ili ne. Slika 2.3 pokazuje nekoliko različitih metoda poređenja zadataka, koji prikazuju različitu preciznost poređenja, ili činjenicu da podaci moraju biti posmatrani u širem kontekstu.

*Metod tačnog poređenja* direktno poredi posmatranje i očekivanje, i pogodan je u sistemima gde vrednosti nisu tačne. Kada postoje tolerancije u ponašanju sistema, potrebni su drugi metodi.

U *komparativnom metodi reda veličine amplitude* posmatranje i očekivanje koji se razlikuju ali su istog reda veličine amplitude, smatraju se istim.

*Komparativni metod praga* proverava da li razlika posmatranja i očekivanja prelazi određeni prag.

*Teleološki komparativni metod* obavlja teleološku apstrakciju (prema njegovoj funkciji i svrsi) očekivanja pre nego što ga uporedi sa očekivanjem kako bi se sprečio lažni alarm. Posmatranje neispravnosti (simptom) je na taj način neslaganje na teleološkom nivou.

U *statističkom komparativnom metodi* očekivanje se izražava kao statistička informacija, i onda se poredi sa posmatranjem.

*Istorijski komparativni metod* koristi istorijske podatke da odluči da li je razlika između posmatranja i očekivanja zaista neslaganje.

### 2.3.2 Zadatak generisanja hipoteza

Zadatak generiše hipoteze koje objašnjavaju skup početnih (ispravnih ili neispravnih) posmatranja. Ispravna posmatranja mogu da doprinesu u postupku odvajanja u procesu generisanja hipoteza. Slika 2.4 daje pregled metoda i zadataka relevantnih za generisanje hipoteza.

*Kompajlirani metod* za generisanje hipoteza koristi veze između simptoma i uzroka. Ovaj metod se često koristi tamo gde je razumevanje postojećih mehanizama samo delimično. Apstraktna posmatranja (kao što su kvalitativne i definicione apstrakcije i generalizovane apstrakcije) se ponekad koriste umesto niza posmatranja radi generisanja hipoteza.

*Metod zasnovan na modelu* za generisanje hipoteza označava familiju metoda koja se sastoji od tri podzadatka:

1. Naći skup objekata (kao što su komponente ili funkcije) koji doprinosi posmatranju neispravnosti. Pridruženi skup ima bar jedan neispravni element.
2. Transformisati pridružene skupove u skup hipoteza, u kome svaki element ima moguće objašnjenje posmatranja.
3. Koristiti predikcione filtre da bi se dalje odbacile nekonzistentne hipoteze iz skupa hipoteza, koristeći samo početna posmatranja. Filtriranje se smatra delom

generisanja hipoteza. Članovi familije metoda mogu biti degenerisani pa su svi podzadaci izvršeni.

*Zadatak pridruživanja.*

*Metod praćenja traga* pridružuje neispravnim posmatranjima tako što prati ponašanje modela koje predstavlja ispravno ponašanje.

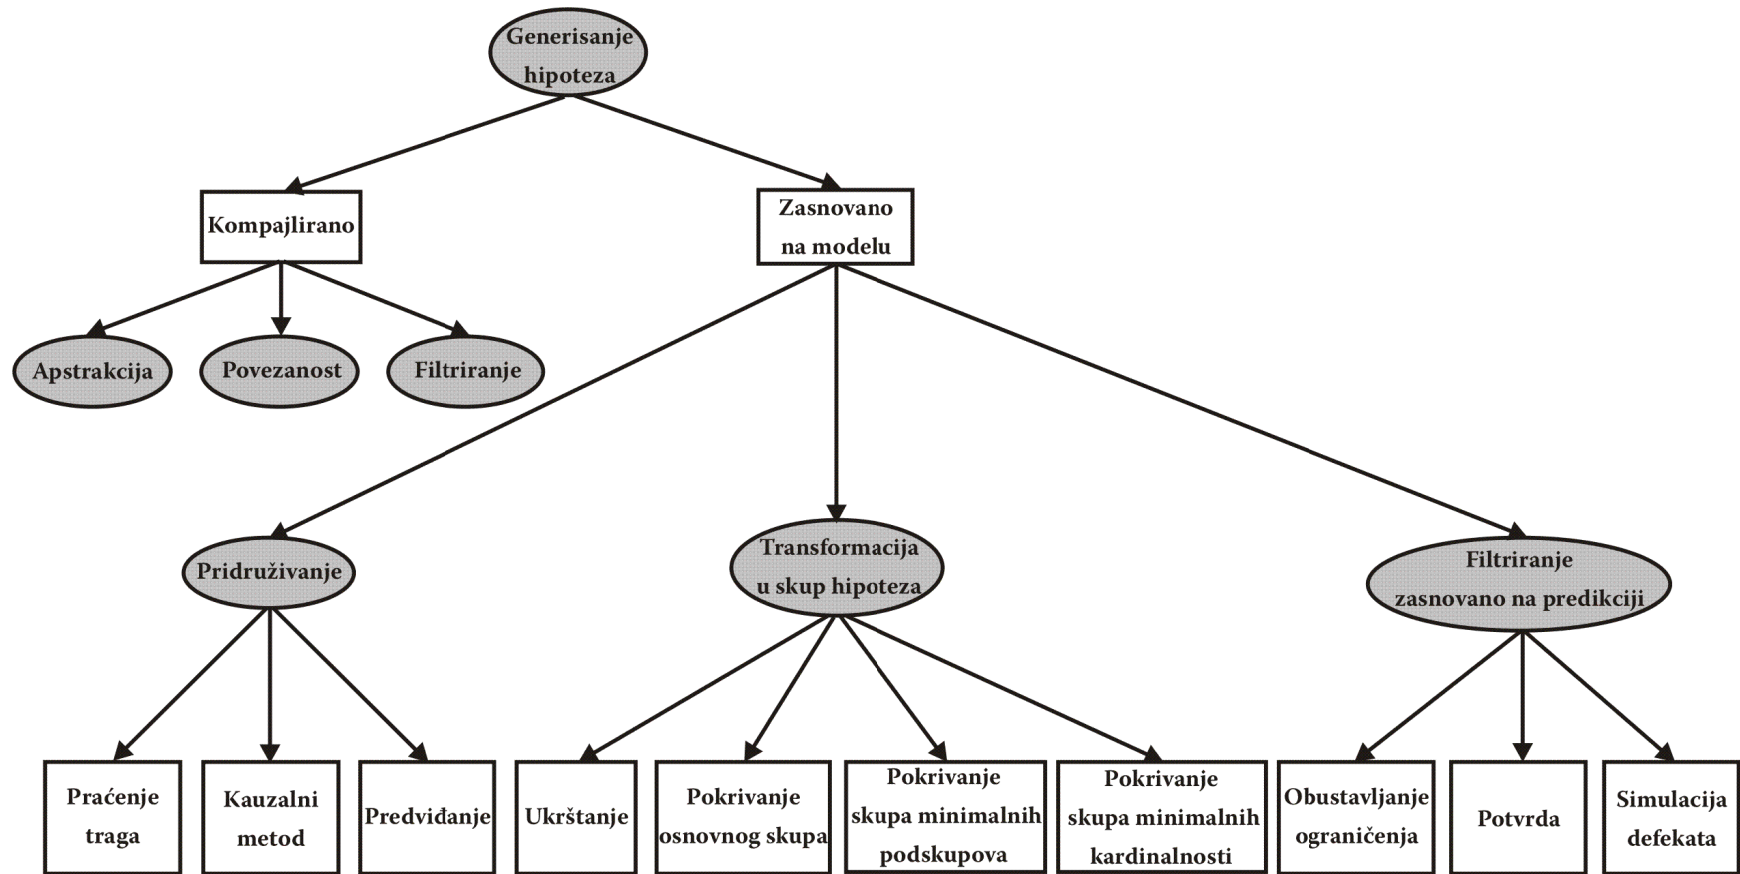
*Kauzalni metod* radi sa kauzalnim modelom koji određuje da li su pridruživanja nastajala inkrementalno ili odjednom.

U *metodu koji se zasniva na predikciji* pridruženi skup je proizvod procesa simulacije. Za vreme simulacije snimaju se poravnanja za izračunate vrednosti. Ako se pronade nekonzistentnost između rezultata simulacije i stvarnih posmatranja, pridruženja za ove nekonzistentnosti se mogu naći u zapamćenim poravnanjima.

*Zadatak transformacije skupa hipoteza.*

Jedan način za transformaciju pridruženog skupa u skup hipoteza je primena *metoda ukrštanja*. U ovom metodu, svi pridruženi metodi su ukršteni, tako da presek proizvodi hipotezu. Ako presek sadrži više od jednog elementa, svaki element se posmatra kao pojedinačna hipoteza. Kada postoji samo jedan pridruženi skup, metod ukrštanja razmatra svako pridruživanje kao hipotezu sa jednostrukim defektom.

*Metod preklapanja skupova* generiše sve skupove hipoteza koji imaju neprazan presek sa bilo kojim od pridruženih skupova. Tako, svaka hipoteza pokriva sve pridružene skupove. Ovaj metod pretpostavlja potpunu nezavisnost uzroka, što znači da pojedinačni uzrok objašnjava skup posmatranja bez obzira na to kako se smatraju ostali uzroci. Metod preklapanja skupova ne primenjuje samo kriterijum štedljivosti da bi se smanjio skup hipoteza, već i prikuplja sve moguće hipoteze koje su do tada konzistentne sa posmatranjima. Kriterijum štedljivosti može se primeniti u preklapanju skupova: minimalnost podskupova i minimalnost kardinalnosti. Metodi koji su povezani sa štedljivosti su često diskutovani u kontekstu *abductive* dijagnostike, gde su pojedinačne hipoteze kombinovane u složene hipoteze koje najbolje objašnjavaju posmatranja. Postupak slaganja hipoteza može takođe da koristi logičko znanje i veze ili informacije o verovatnoći.



Slika 2.4 Parcijalno razlaganje zadatak-metod za zadatak generisanja hipoteza

### *Zadatak filtriranja zasnovan na predikciji.*

Ovaj zadatak koristi postupak predikcije da bi dalje isključio nekonzistentne hipoteze koristeći samo početna posmatranja. Jedan metod koji omogućava da se ovo uradi je metod *obustavljanja ograničenja*. Za svaku hipotezu u skupu hipoteza, ponašanje odgovarajućeg modela objekta (ili objekata) se obustavlja poništavanjem odgovarajuće simulacije i pravila zaključivanja. Model koji je ostao se onda simulira uzimajući u obzir početna posmatranja. U suprotnom, hipoteza ne može konzistentno da objasni početna posmatranja, i odbacuje se. Obustavljanje ograničenja komponente znači da više nemamo model ponašanja komponente, i kao posledica, svako ponašanje komponente je konzistentno sa posmatranjima. Prema tome, hipoteze dobijene ovim metodom ne mogu da obezbede pokrivanje ili pomoćno objašnjenje posmatranja.

Kada se posmatrana vrednost poklopi sa očekivanjima, pojavljuje se potvrđivanje. *Metod potvrđivanja* koristi ideju da svaka hipoteza (model objekta) koja se potvrđuje mora biti neškodljiva i tako odbačena iz skupa hipoteza.

*Metod simulacije defekta* instancira model defekta koji odgovara jednoj od hipoteza. Ako je ponašanje predviđeno na osnovu modela nekonzistentno sa posmatranjima, hipoteza može biti odbačena. Da bi se hipoteze zadržale u skupu hipoteza, može se zahtevati pokrivanje početnih posmatranja, ili se zadovoljiti samo konzistentnošću.

### 2.3.3 *Zadatak odvajanja hipoteza*

U ovom zadatku, posmatranja se prikupljaju i razjašnjavaju da bi se hipoteze i dalje odvajale. Izlaz zadatka odvajanja hipoteza je skup dijagnostika, gde svaka objašnjava početna i dodatna posmatranja. Slika 2.5 daje delimičnu dekompoziciju ovog zadatka.

Metod odvajanja ažurira skup hipoteza, i sastoji se od tri podzadatka: odabrati hipoteze, prikupiti podatke i shvatiti (objasniti) podatke.

#### *Zadatak biranja hipoteza.*

U okviru ovog zadatka, bira se hipoteza koja zahteva dodatne podatke. Ovo može da se uradi na nekoliko načina.

*Metod slučajnog odabira* je jednostavan pristup, i koristan je kada nisu modelovane veze između hipoteza. Finiji metod je kada se hipoteze biraju na osnovu nekog kriterijuma.

Kod metoda *pametnog odabira*, svaka hipoteza u skupu je povezana sa procenom cene testiranja čitavog skupa hipoteza, počevši od određene hipoteze. Procena se može bazirati na različitim tipovima znanja. Na primer, može se zasnivati na očekivanom broju testova koje treba izvršiti. Hipoteze su poređane u odnosu na procenu cene, i prva se izabira radi prikupljanja dodatnih podataka.

#### *Zadatak prikupljanja podataka.*

Ovaj zadatak zahteva dodatna posmatranja i procene u zavisnosti od toga da li se očekivanja upoređuju ili ne.

Jedan metod za realizaciju ovog zadatka je *kompajlirani test metod*. Za svaku hipotezu dostupno je znanje o postupcima testiranja i tome šta će značiti rezultat (da li je hipoteza potvrđena ili ne).

*Metod proveriti* spada u familiju metoda za prikupljanje podataka i sastoji se od tri podzadatka: merenje, generisanje očekivanja i poređenje. Zadatak merenja omogućava dobijanje dodatnih posmatranja i dalje se deli na dva metoda. U metodu direktnog merenja, posmatranja se dobijaju sa objekata koji odgovaraju hipotezi. Ovi objekti moraju biti dostupni za posmatranja. Kada ovaj zahtev nije održan, koristi se metod koji se zasniva na indikatoru. Indikator je alternativno posmatranje, koje, iako delimično, neprecizno i indirektno, daje indicaciju statusa hipoteze. Na primer, ako je teško dopreti do neke komponente, pristup zasnovan na modelu može da sugerise alternativnu komponentu koja indicira status originalne komponente.

Drugi metod za prikupljanje dodatnih podataka je *metod upravljanja*, koji dovodi ulaz na uređaj i posmatra rezultat. U zavisnosti od hipoteze koju želimo da verifikujemo, moramo zaključiti koji je ulazni vektor potreban. U osnovi, moramo odrediti koja vrsta internih ulaza je potrebna da bi se testirale hipoteze, pa da se vratimo unazad i zaključimo koji spoljni ulazi su potrebni da bi pobudili interne. Zatim, startuje se simulacija da bi se generisala očekivanja na izlazima komponente. Očekivanje se poredi sa dobijenim posmatranjima, što je rezultat priključivanja ulaznog vektora. Rezultat je podatak (jednaki ili ne). Metod upravljanja nailazi na poteškoće kada su sumnjive komponente sukobljene prilikom odlučivanja o testnom ulaznom vektoru ili za vreme generisanja očekivanja na izlazu komponente. U takvim slučajevima ne možemo biti sigurni da primenjeni ulazni vektor dovodi do očekivanog rezultata.

Takođe je moguće prikupiti podatke zamenom komponente i posmatranjem da li se kvar još uvek javlja. U ovom metodu zamene, dijagnostika i popravka mogu da se poklope.

#### *Zadatak objašnjavanja podataka.*

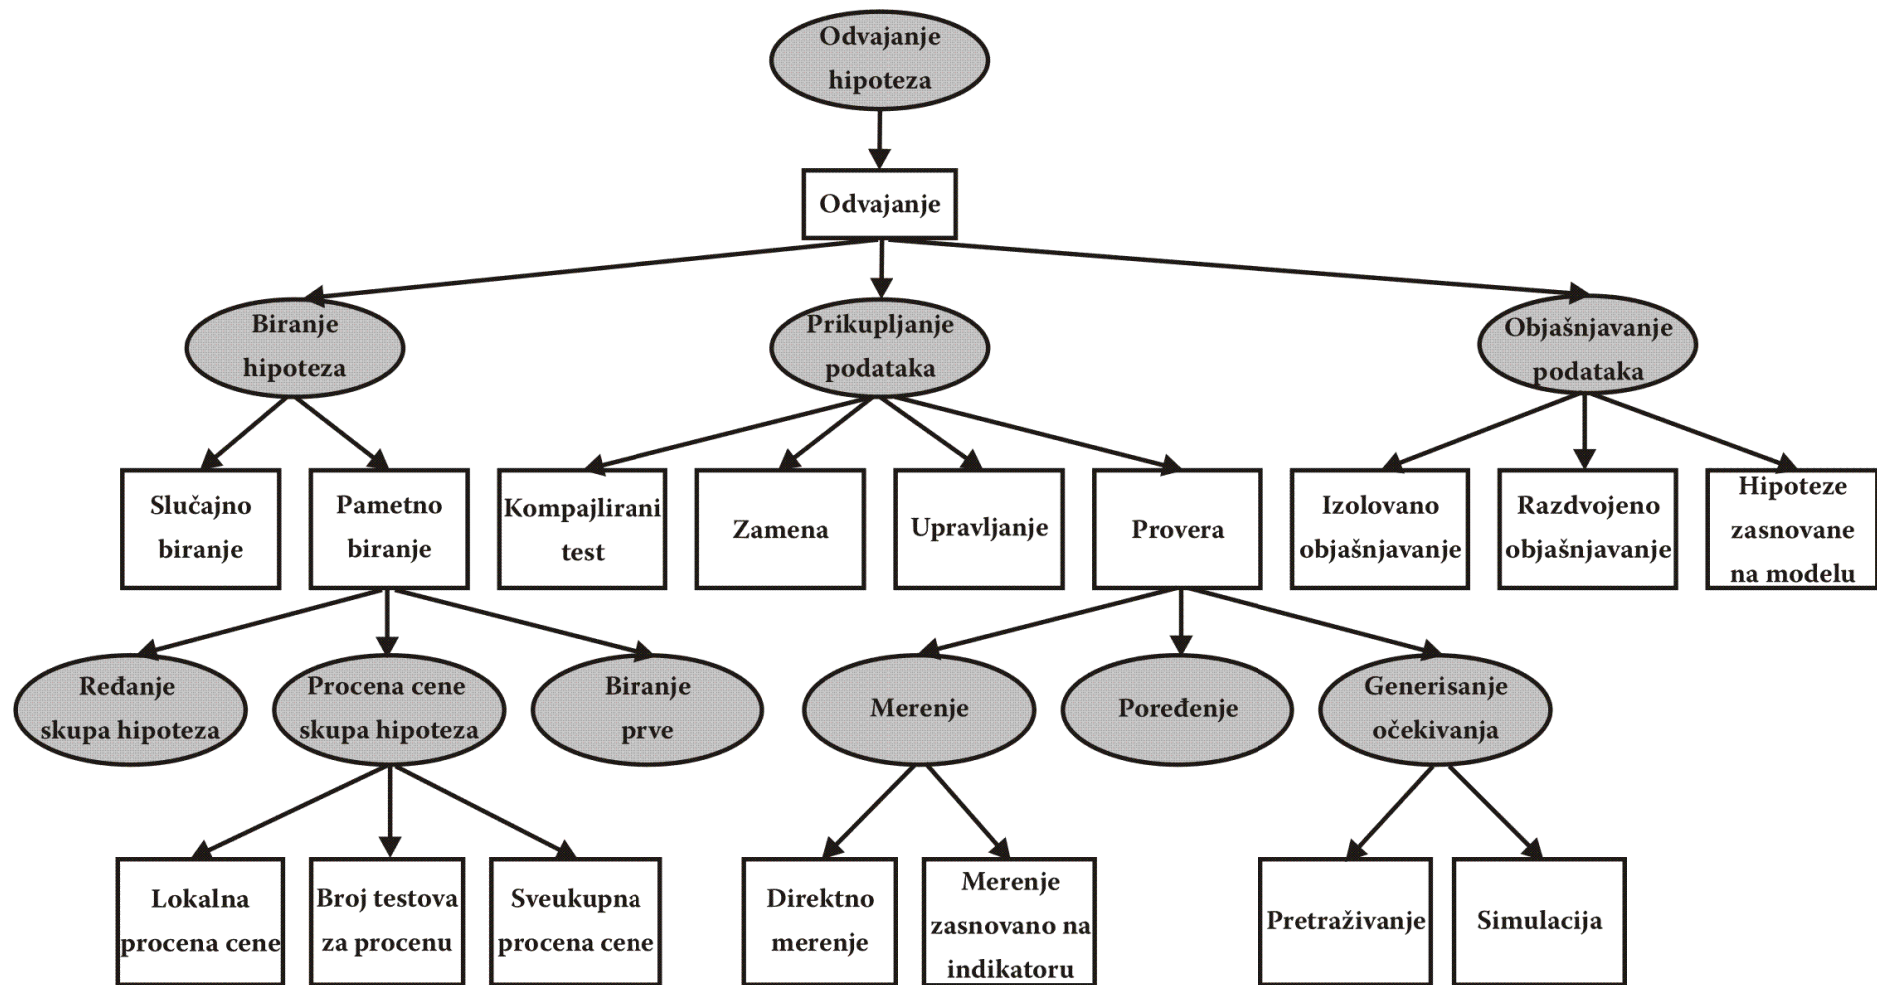
Ovaj zadatak počinje kada su prikupljeni dodatni podaci. Kao što se koriste hipoteze u zadatku generisanja hipoteza, ovaj zadatak koristi posmatranja da bi se ažurirao skup hipoteza i tako se uključilo i razmatranje. Ovde se, međutim, radije koriste dodatna nego početna posmatranja.

Jednostavan metod za objašnjavanje podatka je obraditi njegov uticaj lokalno ili objasniti ga izolovanog. Tako se hipoteza ili odbacuje ili zadržava u zavisnosti od zahtevanog podatka. Ovaj metod je koristan kad su hipoteze nepovezane.

Ako su, međutim, hipoteze u skupu na neki način međusobno povezane, može se primeniti metod razdvojenog objašnjavanja. Tu je skup hipoteza podeljen na dva dela, i jedan se odbacuje u zavisnosti od podatka. Falsifikovanje testiranih hipoteza falsifikuje sve hipoteze koje doprinose mestu gde je podatak dobijen. S druge strane, verifikacija omogućava odbacivanje svih hipoteza koje nisu doprinele.

Drugi način da se objasne dodatni podaci je ponovno korišćenje procesa generisanja hipoteza zasnovanih na modelu, ovog puta sa dodatkom novih posmatranja. U mnogim dijagnostičkim sistemima objašnjenje dodatnih podataka se radi iteriranjem osnovnih koraka generisanja i odvajanja.





Slika 2.5 Zadatak odvajanja hipoteza

## 2.4 Fazi-neuro koncept

U prethodno prikazanim konceptima, podaci se udružuju u skupove kojima u potpunosti pripadaju. U kontekstu dijagnostike, kada se govori o pojmu napona, možemo imati visok ili nizak napon. Šta se, međutim, dešava kada je napon umereno visok ili veoma visok? U skladu sa tim, šta je sa veoma niskim i srednjim vrednostima? Ova pitanja podstakla su razvijanje nove teorije, poznate kao teorija fazi skupova [24].

Nasuprot konvencionalnoj teoriji skupova u kojoj funkcija “pripada” pridružuje objekte skupovima, u fazi teoriji skupova specificira se “stepen pripadanja” kada se vrši pridruživanje. Na primer, kada se definišu dva skupa “visoki naponi” i “niski naponi”, dati napon od 1000V bi se u potpunosti pridružio (u potpunosti znači sa faktorom 1) klasi visokih napona. Međutim, kada imamo napon od 850V, notacija “dosta visok” opisuje pripadnost klasi visokih napona sa faktorom 0.85. Slično, faktor 0.2 može da se primeni za pripadnost napona od 800V klasi niskih napona.

Kada se pridruživanje obavi na opisani način, moguće je definisati sistem zaključivanja zasnovan na tehnikama za kombinovanje raspodela. Ovakvi sistemi se zovu neuro-fazi sistemi [25]. Oni kombinuju semantičku transparentnost fazi sistema zasnovanim na pravilima sa sposobnostima učenja neuronskih mreža.

### 2.4.1 Fazi modeli

Matematički model, koji na neki način koristi fazi skupove, zove se fazi model. Obično je implementiran u formi zasnovanoj na pravilu. Ovo znači da su veze među promenljivama predstavljene pomoću ako-onda (*if-then*) pravila sa nepreciznim (višeznačnim) predikatima, kao što je:

**Ako je struja velika onda temperatura raste brzo.**

Ovo pravilo na opisni način definiše vezu između grejanja i temperature u sobi, na primer. Da bi ovakav model postao operativan, značenje izraza “veliki” i “brz” mora da bude preciznije definisano. Ovo se radi pomoću fazi skupova, tj. skupova u kojima se članstvo menja postepeno, a ne naglo. Fazi skupovi se definišu svojom funkcijom članova koja preslikava elemente iz određenog prostora u jedinični interval  $[0,1]$ . Ekstremne vrednosti 0 i 1 označavaju potpuno članstvo i ne-članstvo, respektivno, dok opseg između 0 i 1 označava delimično članstvo u fazi skupu. U zavisnosti od strukture ako-onda pravila, razlikuju se dva osnovna tipa fazi modela: Mamdani (ili lingvistički) model i Takagi-Sugeno model [26].

### 2.4.2 Primena neuro-fazi koncepta na dijagnostiku

U literaturi postoji nekoliko primena neuro-fazi dijagnostike [27]. Razmatraju se različite teme kao što je gas turbina [28], trofazni električni indukcionni motor [29], elektro-pneumatski ventil [30], itd. Treba primetiti da su implementirani pristupi uglavnom usmereni na sisteme upravljanja sa naglaskom na procenu parametara.

Uprkos činjenici da svi oni mogu biti okarakterisani kratkom listom merenih veličina i skoro jednako kratkom listom defekata koji se dijagnosticiraju, smatramo da je ovaj pristup obećavajući u smislu detekcije i izolovanja defekata.

U literaturi nisu diskutovana kola sa mešovitim signalima. Ovo, pretpostavljamo, može postati problem ukoliko se posmatraju binarni ulazi istovremeno sa analognim.

### 3 Dijagnostika defekata u otpornom kolu

Dijagnostika elektronskih kola pomoću neuronskih mreža je pristup koji je izabran u ovom radu, pa će u narednim poglavljima biti pokazano nekoliko primera koji ilustruju ovaj pristup. Kako su otporna kola najjednostavnija za analizu, pa samim tim i za analizu defekata, u prvom primeru biće pokazana dijagnostika defekata u otpornom kolu.

Da bi se formiralo znanje o ponašanju sistema u prisustvu defekata, primenjen je koncept rečnika defekata [13]. Rečnik defekata je tabela pretraživanja (*look-up table*), gde se u prvoj koloni navodi kod defekta. U sledećim kolonama dati su rezultati merenja (ili simulacije) dobijeni analizom kola u prisustvu defekta, i oni se nazivaju signature. Ova lista rezultata može biti duga u zavisnosti od toga koliko je ambiciozan dijagnostički zadatak.

U klasičnim dijagnostičkim primenama sistem koji se testira se za vreme testiranja pobuđuje istom pobudom koja se koristi pri formiranju rečnika. Zatim se primenjuje tehnika pretraživanja da bi se našao kod defekta, pa se porede novi rezultati merenja sistema sa defektom sa signaturama koje su zapamćene u rečniku. Ako je poređenje neuspešno, pretraga se nastavlja za signature koje su slične dobijenim rezultatima merenja.

Glavni problem kod ovog pristupa vezan je za situaciju kada je nekoliko signatura u tabeli pretraživanja slično merenim rezultatima. U ovim slučajevima formira se skup sličnih defekata i treba primeniti neku "inteligentnu" tehniku koja bi među podacima koji su bliski merenim pronašla defekt.


Prvi korak u formiranju rečnika je definicija defekta, gde se predviđaju najverovatniji defekti. Ovo je veoma kritičan aspekt čitavog pristupa, jer je samo te defekte moguće kasnije identifikovati. Zbog toga treba uzeti u obzir veliki broj potencijalnih defekata. Ovo, naravno, ima uticaj na veličinu rečnika i uvodi ograničenje u ovaj pristup.

Sledeći korak u formiranju rečnika je simulacija (ili merenje) parametara sistema koji se testira za hipotetičke slučajeve kola sa defektom, kako bi se dobio skup pobuda i odziva, na osnovu kojih se defekti kasnije detektuju i izoluju. Signature odziva čuvaju se u rečnicima zbog korišćenja u *on-line* procesu identifikacije defekata. Optimalni izbor pobude, odziva i signatura se zahteva da bi se čuvala minimalna količina podataka, a sve to u cilju postizanja željenog stepena detekcije i izolacije.

U sledećem primeru pokazaćemo da VNM može da se iskoristi za modelovanje tabele pretraživanja. Najpre se VNM obučava da modeluje tabelu pretraživanja. Zatim, VNM koja daje odziv na određeni ulazni vektor pobuda može da se posmatra kao pretraživanje tabele defekata. Odziv dobro obučene mreže će odmah naći defekt. Šta više, neodređeni (do neke mere) ulazni podaci mogu da dovedu do izolovanja defekta zahvaljujući sposobnosti generalizacije VNM.

### 3.1 Primer kola sa zvezdastom strukturom

Dijagnostički zadatak u ovom primeru odnosi se na dijagnostiku defekata u jednostavnom otpornom električnom kolu koje se sastoji od 10 otpornika povezanih kao na Slici 3.1 [13].



**Slika 3.1** Otporno kolo koje se koristi kao primer

Vrednosti elemenata kola su:  $V_{DD}=5V$ ,  $R_1=1k\Omega$ ,  $R_2=2k\Omega$ ,  $R_3=3k\Omega$ ,  $R_4=4k\Omega$ ,  $R_5=5k\Omega$ ,  $R_6=6k\Omega$ ,  $R_7=7k\Omega$ ,  $R_8=8k\Omega$ ,  $R_9=9k\Omega$ ,  $R_{10}=10k\Omega$ .

Pošto se kolo sastoji samo od otpornika, ne postoji ni veliki broj defekata koji se mogu dogoditi u kolu. Mogući su meki defekti, tj. promena vrednosti parametara kola, ili, eventualno, promena vrednosti napona napajanja, ali su jednako verovatni i katastrofalni defekti: kratki spojevi i prekidi.

U ovom primeru su modelovani samo katastrofalni defekti, i to: kratkospojene i otvorene otporne grane. Da bi se formirao što iscrpniji rečnik defekata, ispitani su efekti svih mogućih defekata kratkospojenih i otvorenih grana. Broj ovako generisanih defekata je dvostruko veći od broja otpornika u kolu, a svaki defekt je označen brojem na Slici. Osim prekida otpornih grana, mogući su i prekidi prema napajanju i masi (označeni su brojevima 21 i 22 na Slici 3.1), tako da su dodata još ta dva defekta koji se odnose na izvor napajanja  $V_{DD}$  i na masu.

Rečnik defekata kreira se analizom kola, i to tako što se simulira kolo sa svakim pojedinačnim defektom i pamte se vrednosti napona u čvorovima 1, 2, 3, 4. Napon u čvoru 5 smatra se konstantnim jer je vezan za izvor referentnog napona  $V_{DD}$ , a u primeru se ne razmatraju promene vrednosti napona napajanja. Dobijeni rezultati simulacije su prikazani u Tabeli 3.1.

Tabela 3.1 Rečnik defekata za kolo sa Slike 3.1

(FF=kolo bez defekata- **F**ault **F**ree **C**ircuit; **SC**=kratkospojena grana- **S**hort **C**ircuited branch, **OC**=otvorena grana-**O**pen **C**ircuited branch)

| Kod defekta | Tip defekta | $V_1$ (V) | $V_2$ (V) | $V_3$ (V) | $V_4$ (V) | $\Delta$ |
|-------------|-------------|-----------|-----------|-----------|-----------|----------|
| 00000       | FF          | 1.683967  | 0.9370691 | 1.127734  | 2.610747  | 0        |
| 00001       | SC $R_1$    | 1.418368  | 0         | 1.068404  | 2.539773  | 0.195673 |
| 00010       | SC $R_2$    | 1.35293   | 0.8966994 | 0         | 2.01647   | 0.263527 |
| 00011       | SC $R_3$    | 1.619701  | 0.9292318 | 1.655421  | 1.655421  | 0.218659 |
| 00100       | SC $R_4$    | 2.290453  | 1.011031  | 2.037885  | 5         | 0.525745 |
| 00101       | SC $R_5$    | 2.835549  | 5         | 1.384977  | 2.918477  | 0.848397 |
| 00110       | SC $R_6$    | 1.131171  | 1.131171  | 1.004249  | 2.463027  | 0.123342 |
| 00111       | SC $R_7$    | 0         | 0.7317074 | 0.751566  | 2.160752  | 0.358994 |
| 01000       | SC $R_8$    | 1.355274  | 0.8969846 | 1.355274  | 2.667375  | 0.081148 |
| 01001       | SC $R_9$    | 2.131264  | 0.9916176 | 1.0193    | 2.131264  | 0.133373 |
| 01010       | SC $R_{10}$ | 5         | 1.341463  | 1.868476  | 3.496868  | 0.706923 |
| 01011       | OC $R_1$    | 2.515455  | 3.870661  | 1.313473  | 2.83294   | 0.612575 |
| 01100       | OC $R_2$    | 2.356835  | 1.019126  | 3.420008  | 3.818697  | 0.535655 |
| 01101       | OC $R_3$    | 1.778004  | 0.948537  | 0.355600  | 4.008617  | 0.31995  |
| 01110       | OC $R_4$    | 1.1598    | 0.873146  | 0.341117  | 0.545788  | 0.454386 |
| 01111       | OC $R_5$    | 1.478222  | 0.211174  | 1.081774  | 2.555767  | 0.151577 |
| 10000       | OC $R_6$    | 1.979403  | 0.833333  | 1.193729  | 2.689694  | 0.065918 |
| 10001       | OC $R_7$    | 2.250222  | 1.006125  | 1.254225  | 2.762063  | 0.120716 |
| 10010       | OC $R_8$    | 1.817818  | 0.953392  | 1.035075  | 2.587687  | 0.033045 |
| 10011       | OC $R_9$    | 1.494848  | 0.914005  | 1.17358   | 2.813474  | 0.056390 |
| 10100       | OC $R_{10}$ | 0.974951  | 0.850603  | 0.969352  | 2.421281  | 0.15115  |
| 10101       | OC $V_{DD}$ | 0         | 0         | 0         | 0         | 0.687    |
| 10110       | OCgnd       | 5         | 5         | 5         | 5         | 1.38862  |

Svakom defektu je pridružen kod defekta, prikazan u prvoj koloni Tabele 3.1. Podrazumeva se da je to kod koji generiše dijagnostički sistem kada se određeni defekt javi u kolu. Defekti su kodirani binarnim kodom, tako da je potrebno 5 bitova za kodiranje 22 različita defekta. Druga kolona Tabele opisuje tip defekta. FF označava kolo bez defekta (*Fault Free Circuit*). SC  $R_j$  opisuje slučaj kada je grana u kojoj se nalazi otpornik  $R_j$  ( $j=1, 2, \dots, 10$ ) kratkospojena (*Short Circuited branch*). OC  $R_j$  opisuje slučaj kada je grana u kojoj se nalazi otpornik  $R_j$  ( $j=1, 2, \dots, 10$ ) otvorena (*Open Circuited branch*). OC  $V_{DD}$  prikazuje slučaj kada je prekinuta veza ka napajanju, a OCgnd kada je prekinuta veza ka masi. Vrednosti napona u čvorovima 1-4 date su u kolonama 3-6 Tabele 3.1.


U poslednjoj koloni Tabele 3.1 data je vrednost:

$$\Delta_i = \|\mathbf{V}_i - \mathbf{V}_0\| / V_{DD} = \frac{1}{V_{DD}} \sqrt{\sum_{j=1}^4 (V_{i,j} - V_{0,j})^2} \quad \text{za } i = 0, 1, \dots, 22 \quad (3.1)$$

$$\Delta_{1i} = V_{DD} \cdot \Delta_i = 5 \cdot \Delta_i \quad (3.2)$$

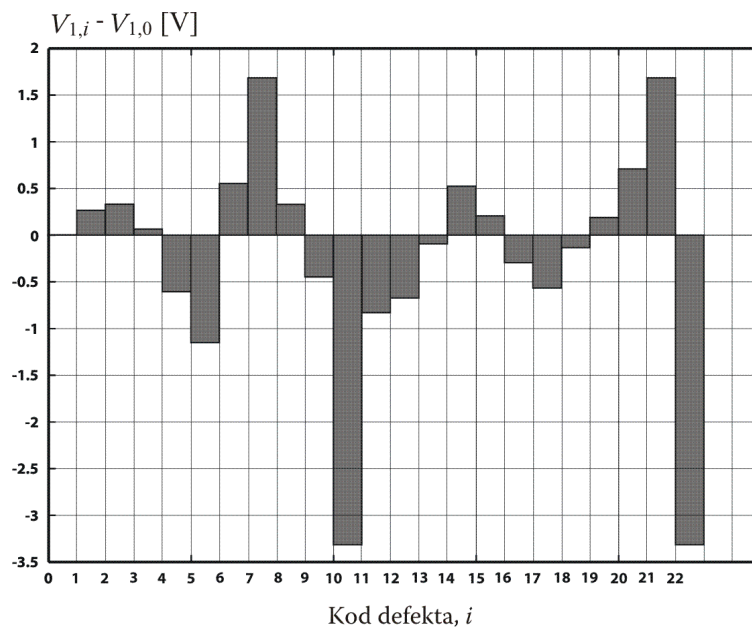
Vrednost  $\Delta_{1i}$  je zapravo moduo vektora koji je razlika vektora koji predstavljaju napone čvorova u kolu bez defekta i napone čvorova u skupu kola sa defektom za svaki defekt, kao što je prikazano na Slici 3.2. Primetimo da je najveća vrednost modula  $\Delta_{1i}$  koja se pojavljuje aproksimativno:

$$\Delta_{1i} = V_{DD} \cdot \Delta_i = 5 \cdot \Delta_i = 5 \cdot 0.85 = 4.25 \quad (3.3)$$

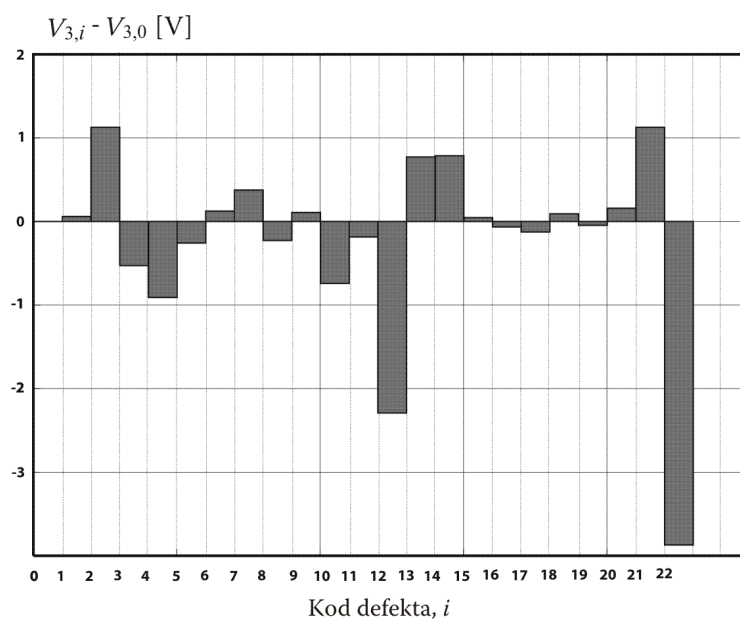


**Slika 3.2. Objašnjenje vrednosti  $\Delta_{1i}$**


Na Slikama 3.3., 3.4., i 3.5. prikazane su razlike napona u kolu sa određenim defektom i u kolu bez defekta, za sve moguće defekte, i to za čvorove 1, 3 i 4, respektivno. Sa slika se vidi da postoji vrlo velika sličnost odziva za neke defekte. Ovi slučajevi su pokazani da bi se uočile sve teškoće koje se javljaju pri dijagnostici ovih sličnih defekata.



**Slika 3.3** Razlike koje se pojavljuju kada je prisutan defekt (u čvoru 1)




**Slika 3.4** Razlike koje se pojavljuju kada je prisutan defekt (u čvoru 3)



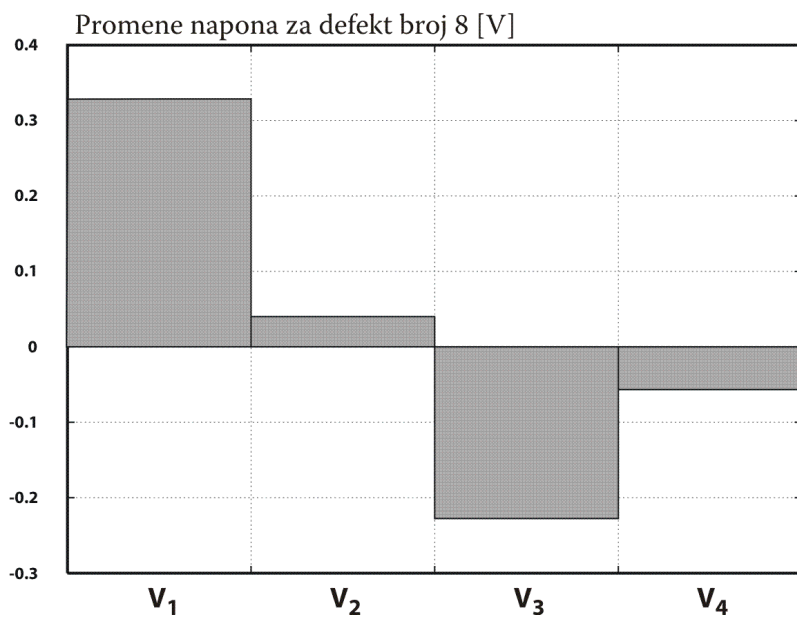
**Slika 3.5** Razlike koje se pojavljuju kada je prisutan defekt (u čvoru 4)

Na Slikama 3.6 do 3.10 pokazane su situacije kada se odzivi kola sa defektom razlikuju za 0,1-0,3V u odnosu na kolo bez defekta, što je veoma mala razlika, pa su samim tim i ti slučajevi vrlo teški za dijagnostiku.

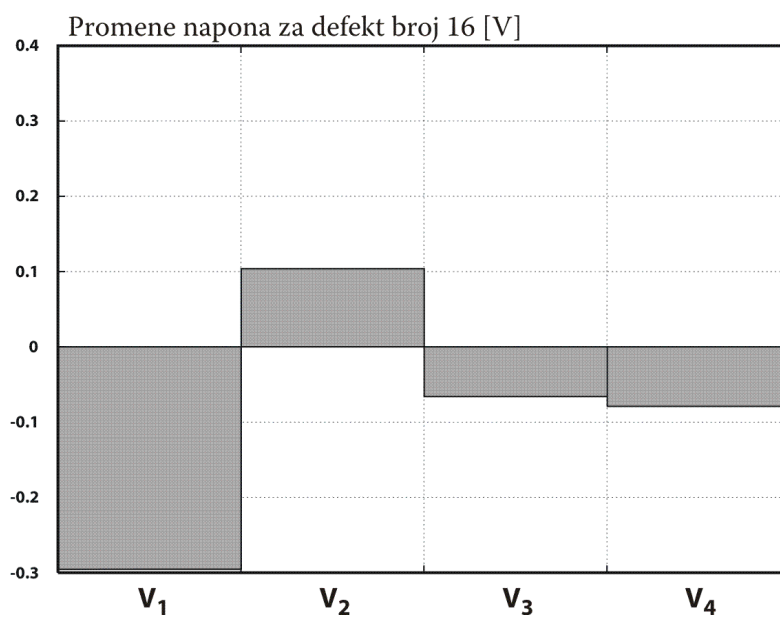


**Slika 3.6** Razlike napona u svim čvorovima kada je u kolu prisutan defekt broj 5 i kada u kolu nije prisutan defekt

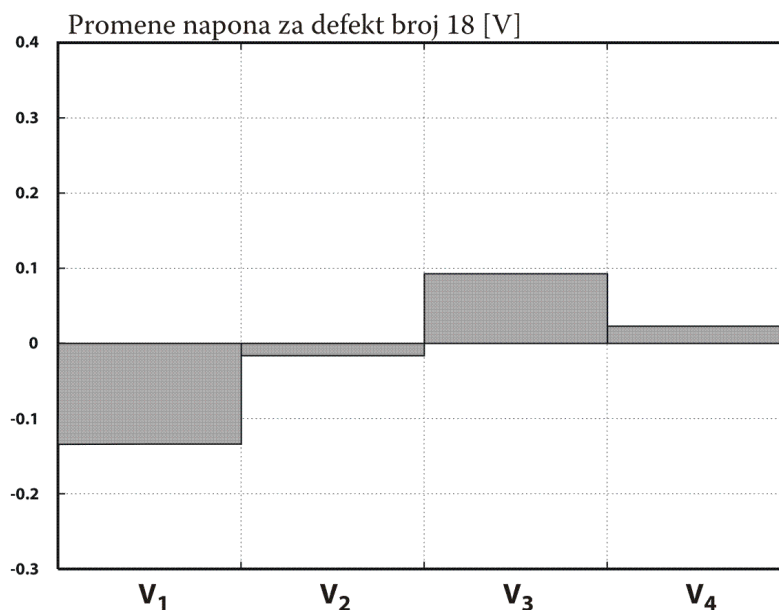




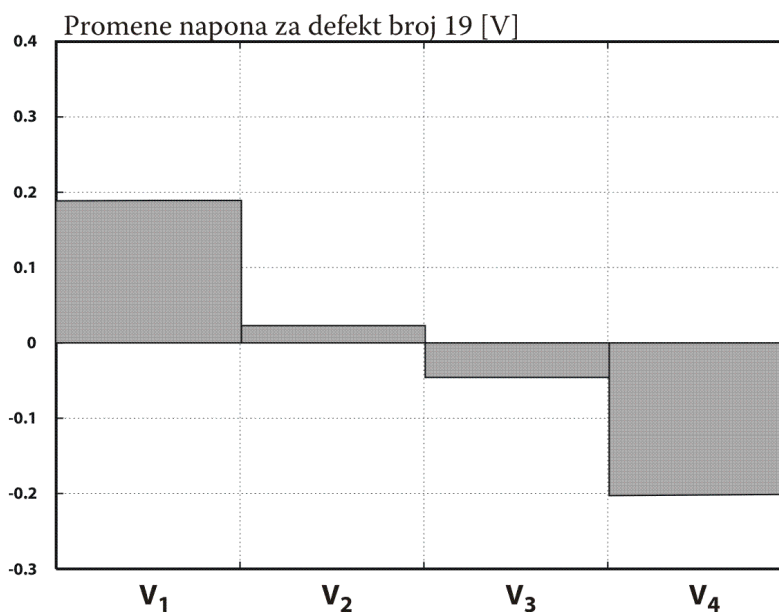
**Slika 3.7** Razlike napona u svim čvorovima kada je u kolu prisutan defekt broj 8 i kada u kolu nije prisutan defekt



**Slika 3.8** Razlike napona u svim čvorovima kada je u kolu prisutan defekt broj 16 i kada u kolu nije prisutan defekt



**Slika 3.9** Razlike napona u svim čvorovima kada je u kolu prisutan defekt broj 18 i kada u kolu nije prisutan defekt



**Slika 3.10** Razlike napona u svim čvorovima kada je u kolu prisutan defekt broj 19 i kada u kolu nije prisutan defekt

Za dijagnostiku svih defekata u ovom kolu koristi se veštačka neuronska mreža koja mora da ima četiri ulaza, jer se nezavisni naponi čvorova koriste kao ulazni signali. Na osnovu broja defekata izračunava se broj izlaza veštačke neuronske mreže. Izlazni signal predstavljen je binarno, tako da svaki izlaz neuronske mreže predstavlja bit izlazne reči. Shodno tome, potrebno nam je 5 bitova (izlaza) da bismo predstavili 22 moguća defekta. U skrivenom sloju je 30 neurona. Parametri date mreže dati su u Tabeli 3.2.

Tabela 3.2. (prvi deo) Težine i pragovi neuronske mreže za dijagnostiku defekata u otpornom kolu sa Slike 3.1, težine između ulaznog i skrivenog sloja i pragovi neurona u skrivenom sloju

| skriveni neuron, $i$ | $w(1, i)$ | $w(2, i)$ | $w(3, i)$ | $w(4, i)$ | $\theta_{\square}(i)$ |
|----------------------|-----------|-----------|-----------|-----------|-----------------------|
| 1                    | -15.8048  | 17.8643   | 6.13942   | -20.3786  | 10.5047               |
| 2                    | -2.23356  | 1.75094   | 1.41768   | -1.21641  | 0.962233              |
| 3                    | 5.58318   | 80.0969   | -39.7922  | -40.2832  | 17.6825               |
| 4                    | -29.7041  | 18.0353   | 8.63447   | -5.70917  | 11.7618               |
| 5                    | -22.6667  | 17.5203   | 2.72153   | -9.52235  | 9.73476               |
| 6                    | -20.1181  | 20.3739   | 11.4168   | -9.73945  | 11.058                |
| 7                    | -19.0754  | 25.7023   | 6.08132   | -12.3114  | 14.5654               |
| 8                    | -19.8973  | 16.2231   | 15.3301   | -22.2547  | 10.7767               |
| 9                    | -19.7984  | 15.0675   | -2.11163  | -15.0004  | 12.0374               |
| 10                   | -28.5369  | 18.5168   | 8.21925   | -7.32571  | 11.7826               |
| 11                   | -27.8946  | 16.6345   | 10.6283   | -8.41014  | 5.27124               |
| 12                   | -15.1747  | 8.65262   | 3.27628   | -16.9711  | 0.147375              |
| 13                   | -32.8307  | 22.3048   | 4.24555   | -3.13776  | 8.76184               |
| 14                   | -22.052   | 17.916    | 3.91471   | -15.6947  | 2.56499               |
| 15                   | -10.6257  | 16.6566   | -1.87192  | -19.8915  | -0.32797              |
| 16                   | -18.6728  | 17.1585   | 12.1377   | -9.26202  | 3.28049               |
| 17                   | -13.7222  | 21.9598   | 11.679    | -10.5029  | 1.63688               |
| 18                   | -15.2571  | 16.116    | 10.0852   | -15.8295  | 2.99424               |
| 19                   | -16.4597  | 22.6724   | 3.99661   | -9.16523  | 5.09733               |
| 20                   | -7.07347  | 24.901    | 5.83719   | -13.4813  | 5.07147               |
| 21                   | -13.0616  | 22.6256   | -0.86455  | -14.5897  | 9.35131               |
| 22                   | -12.4197  | 16.3371   | 4.10164   | -21.9193  | 8.35381               |
| 23                   | -12.9467  | 18.06     | 12.3765   | -17.2691  | 7.43625               |
| 24                   | -8.84834  | 23.9314   | 8.31734   | -8.28075  | 6.05142               |
| 25                   | -16.4512  | 24.2428   | 2.13336   | -7.01649  | 5.61139               |
| 26                   | -9.06702  | 18.8579   | 8.38263   | -18.7337  | 6.8011                |
| 27                   | -14.9101  | 19.4553   | 7.74503   | -9.96075  | 6.09712               |
| 28                   | -11.1224  | 22.4533   | 1.81449   | -12.2365  | 9.96386               |
| 29                   | -10.6688  | 9.43082   | -0.66163  | -14.7599  | 17.6624               |
| 30                   | -16.0243  | 17.0961   | 7.90762   | -13.2573  | 3.10409               |

Tabela 3.2. (drugi deo) Težine i pragovi neuronske mreže za dijagnostiku defekata u otpornom kolu sa Slike 3.1, težine između skrivenog i izlaznog sloja i pragovi neurona u izlaznom sloju

| skriveni neuron, $i$ | $w(i, 1)$               | $w(i, 2)$               | $w(i, 3)$               | $w(i, 4)$               | $w(i, 5)$               |
|----------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|
| 1                    | -7.62242                | 5.67655                 | 1.77153                 | -1.81542                | -4.39187                |
| 2                    | 15.0008                 | -23.6793                | -0.43088                | -24.3762                | 35.971                  |
| 3                    | -2.73144                | -3.85609                | -2.7306                 | -6.8355                 | -2.36133                |
| 4                    | 1.66851                 | -0.49052                | -0.18283                | 1.85204                 | -8.7688                 |
| 5                    | -1.45884                | 2.85789                 | -9.01655                | 2.38022                 | 8.56584                 |
| 6                    | -6.01959                | -3.22459                | -2.83897                | -1.13058                | -2.13961                |
| 7                    | -3.38246                | 1.89599                 | 0.78134                 | -4.51888                | -5.09918                |
| 8                    | 0.331394                | 1.86942                 | -2.8895                 | -8.31326                | -9.67643                |
| 9                    | 0.251026                | -5.4869                 | -3.10044                | -2.60557                | -3.81443                |
| 10                   | 1.44262                 | -0.12388                | 0.588112                | 0.0153467               | -7.22859                |
| 11                   | 6.54498                 | -1.63968                | 7.67288                 | 6.98842                 | 4.1923                  |
| 12                   | 3.58364                 | -1.26274                | -5.20685                | 3.48344                 | 5.18112                 |
| 13                   | -7.10849                | -1.26537                | 7.2326                  | -2.53811                | -5.69807                |
| 14                   | -6.43182                | 0.264993                | -1.61994                | 0.230809                | -5.58792                |
| 15                   | 5.05643                 | -0.19085                | 10.9167                 | -7.51547                | -0.08376                |
| 16                   | 0.961457                | 2.44663                 | -4.80005                | 2.8517                  | -1.16835                |
| 17                   | -5.08358                | -1.14228                | -0.3247                 | 5.06773                 | -3.82674                |
| 18                   | 5.6348                  | 0.408807                | -1.76836                | 5.48012                 | 2.68278                 |
| 19                   | 6.28683                 | -0.41184                | -1.40426                | 3.13814                 | 6.25795                 |
| 20                   | 0.912919                | 1.35198                 | -0.72507                | 4.43014                 | -6.23529                |
| 21                   | 3.54338                 | 0.973733                | 5.09899                 | 8.22882                 | -2.16387                |
| 22                   | 7.34334                 | -2.53278                | 2.53852                 | 5.09192                 | 6.41415                 |
| 23                   | -4.29175                | -0.5515                 | 2.05582                 | -3.69177                | 3.58456                 |
| 24                   | 2.10215                 | 2.97569                 | 2.18423                 | 2.39332                 | -1.34293                |
| 25                   | 9.44295                 | 0.807351                | -2.53713                | 3.94212                 | 4.77989                 |
| 26                   | -3.91431                | -1.63352                | 2.60118                 | -1.56182                | 4.30041                 |
| 27                   | 0.47192                 | 2.39633                 | 0.196849                | -2.76789                | 3.38198                 |
| 28                   | -4.9571                 | 3.29928                 | 5.33234                 | 0.73942                 | 1.98274                 |
| 29                   | 5.86849                 | 0.985276                | -4.69553                | 3.5916                  | 11.1117                 |
| 30                   | -10.8776                | 4.79256                 | -2.23827                | -10.7473                | -8.46557                |
|                      | $\theta_{\square}(3,1)$ | $\theta_{\square}(3,2)$ | $\theta_{\square}(3,3)$ | $\theta_{\square}(3,4)$ | $\theta_{\square}(3,5)$ |
|                      | -4.16215                | 7.40506                 | 1.85872                 | 9.85813                 | 8.30937                 |

Da bi se verifikovala ovako određena struktura neuronske mreže, njena sposobnost generalizacije proverena je na sledeći način.

Smatra se da najveća apsolutna vrednost devijacije (greške merenja) ne sme da premaši 5%. Imajući to u vidu, računa se koeficijent normalizacije  $\alpha_i$  za svaki defekt:

$$\alpha_i = \left( \frac{1}{4} \sqrt{V_1^2 + V_2^2 + V_3^2 + V_4^2} \right)_i \cdot 0.05 \quad (3.4)$$

Tabela 3.3 Slučajne vrednosti sa slučajnom raspodelom i vrednosti za  $A_i = 2 \cdot \alpha_i$ 

| Kod   | $x_1$  | $x_2$  | $x_3$  | $x_4$  | $A_i$  |
|-------|--------|--------|--------|--------|--------|
| 00000 | 0.2171 | 0.0039 | 0.7535 | 0.1537 | 0.0859 |
| 00001 | 0.423  | 0.76   | 0.2    | 0.673  | 0.077  |
| 00010 | 0.939  | 0.667  | 0.425  | 0.463  | 0.0647 |
| 00011 | 0.565  | 0.327  | 0.836  | 0.543  | 0.0748 |
| 00100 | 0.223  | 0.997  | 0.05   | 0.588  | 0.149  |
| 00101 | 0.953  | 0.622  | 0.277  | 0.659  | 0.1648 |
| 00110 | 0.918  | 0.105  | 0.27   | 0.766  | 0.0776 |
| 00111 | 0.495  | 0.344  | 0.069  | 0.092  | 0.06   |
| 01000 | 0.555  | 0.677  | 0.643  | 0.629  | 0.085  |
| 01001 | 0.99   | 0.35   | 0.808  | 0.085  | 0.083  |
| 01010 | 0.543  | 0.725  | 0.39   | 0.0361 | 0.163  |
| 01011 | 0.407  | 0.267  | 0.811  | 0.219  | 0.139  |
| 01100 | 0.488  | 0.527  | 0.996  | 0.453  | 0.143  |
| 01101 | 0.386  | 0.367  | 0.52   | 0.206  | 0.112  |
| 01110 | 0.438  | 0.505  | 0.283  | 0.731  | 0.0397 |
| 01111 | 0.448  | 0.155  | 0.475  | 0.646  | 0.0788 |
| 10000 | 0.089  | 0.901  | 0.931  | 0.768  | 0.091  |
| 10001 | 0.682  | 0.27   | 0.665  | 0.549  | 0.0977 |
| 10010 | 0.07   | 0.463  | 0.54   | 0.85   | 0.0865 |
| 10011 | 0.2    | 0.56   | 0.74   | 0.734  | 0.088  |
| 10100 | 0.761  | 0.055  | 0.456  | 0.003  | 0.0727 |
| 10101 | 0.042  | -0.047 | 0.036  | -0.015 | 0      |
| 10110 | 0.9    | 0.313  | 0.981  | 0.356  | 0.25   |

Zatim se za svaki defekt generiše četiri slučajna broja,  $x_j, j=1,2,3,4$ , sa uniformnom raspodelom u intervalu  $[0,1]$ :

Svaki od tih brojeva se preslikava u interval  $[-1,1]$  na sledeći način:

$$\delta'_j = 2 \cdot (x_j - 0.5) \quad (3.5)$$

Konačno:

$$\delta_j = \alpha_i \cdot \delta'_j = A_i \cdot (x_j - 0.5) \quad (3.6)$$

za  $i=1,2, \dots$ , defekata, gde se  $A_i = 2 \cdot \alpha_i$ , računa da bi se omogućilo računanje novih vrednosti napona:

$$V_{j,novo} = V_j + \delta_j \quad (3.7)$$

za svako merenje (za svako  $i$ ).

Tabela 3.4. Naponi čvorova sa dodatim šumom, koji se koriste za verifikaciju generalizacije, su novi ulazi u neuronsku mrežu.

Prikazana je i relativna promena.

(??) znači da vrednost ne može biti određena u odnosu na 0.

| Kod   | $V_1 + \delta_1$     | $V_2 + \delta_2$     | $V_3 + \delta_3$     | $V_4 + \delta_4$     |
|-------|----------------------|----------------------|----------------------|----------------------|
|       | $\delta_1 / V_1$ (%) | $\delta_2 / V_2$ (%) | $\delta_3 / V_3$ (%) | $\delta_4 / V_4$ (%) |
| 00000 | 1.66                 | 0.894                | 1.15                 | 2.581                |
|       | 1.44%                | 4.81%                | -1.94%               | 1.15%                |
| 00001 | 1.412                | 0.0201               | 1.045                | 2.553                |
|       | 0.45%                | ??                   | 2.24%                | -0.52%               |
| 00010 | 1.381                | 0.907                | -0.0048              | 2.014                |
|       | -2.03%               | -1.13%               | ??                   | 0.12%                |
| 00011 | 1.624                | 0.916                | 1.68                 | 1.658                |
|       | -0.265%              | 1.44%                | -1.46%               | -0.156%              |
| 00100 | 2.25                 | 1.085                | 1.97                 | 5.013                |
|       | 1.8%                 | -6.82%               | 3.45%                | -0.26%               |
| 00101 | 2.91                 | 5.02                 | 1.348                | 2.944                |
|       | -2.56%               | -0.4%                | 2.74%                | -0.87%               |
| 00110 | 1.163                | 1.1                  | 0.986                | 2.483                |
|       | -2.74%               | 2.83%                | 1.85%                | -0.8%                |
| 00111 | -0.0003              | 0.722                | 0.726                | 2.136                |
|       | ??                   | 1.34%                | 3.52%                | 1.16%                |
| 01000 | 1.36                 | 0.912                | 1.367                | 2.678                |
|       | -0.35%               | -1.65%               | -0.86%               | -0.4%                |
| 01001 | 2.172                | 0.979                | 1.045                | 2.097                |
|       | -1.88%               | 1.29%                | -2.46%               | 1.63%                |
| 01010 | 5.007                | 1.378                | 1.85                 | 3.421                |
|       | -0.14%               | -2.65%               | 1%                   | 2.22%                |
| 01011 | 2.503                | 3.84                 | 1.357                | 2.79                 |
|       | 0.497%               | 0.8%                 | -3.2%                | 1.54%                |
| 01100 | 2.355                | 1.023                | 3.49                 | 3.812                |
|       | 0.08%                | -0.38%               | -2%                  | 0.18%                |
| 01101 | 1.765                | 0.933                | 0.357                | 3.975                |
|       | 0.74%                | 1.67%                | -0.39%               | 0.85%                |
| 01110 | 1.157                | 0.873                | 0.332                | 0.555                |
|       | 0.24%                | 0.02%                | 2.75%                | -1.66%               |
| 01111 | 1.474                | 0.184                | 1.08                 | 2.567                |
|       | 0.29%                | 14.7%                | 0.16%                | -0.44%               |
| 10000 | 1.942                | 0.87                 | 1.233                | 2.714                |
|       | 1.93%                | -4.21%               | -3.185%              | -0.9%                |
| 10001 | 2.268                | 0.983                | 1.27                 | 2.766                |
|       | -0.78%               | 2.35%                | -1.24%               | -0.14%               |
| 10010 | 1.78                 | 0.95                 | 1.038                | 2.618                |
|       | 2.12%                | 0.357%               | -0.28%               | -1.16%               |
| 10011 | 1.468                | 0.919                | 1.195                | 2.834                |
|       | 1.83%                | -0.54%               | -1.8%                | -0.72%               |
| 10100 | 0.994                | 0.818                | 0.966                | 2.385                |
|       | -1.92%               | 3.99%                | 0.35%                | 1.52%                |
| 10101 | 0.042                | -0.047               | 0.036                | -0.015               |
|       | ??                   | ??                   | ??                   | ??                   |
| 10110 | 5.1                  | 4.953                | 5.12                 | 4.964                |
|       | -1.96%               | 0.95%                | -2.34%               | 0.73%                |

Tabela 3.3 prikazuje vrednosti vektora  $x$  za situaciju kada u kolu nema defekata i za svaki defekt. Vrednosti  $\delta$  posmatramo kao amplitude šuma koje se dodaju merenom signalu da bi se proverio odziv neuronske mreže. Tako formirane, nove vrednosti signala prikazane su u Tabeli 3.4., i one se vode na ulaze neuronske mreže da bi se proverili njihovi odzivi. (?%) znači da vrednost ne može biti određena u odnosu na 0.

Tabela 3.5 (prvi deo) Verifikacija generalizacije. Odzivi neuronske mreže na ulaze sa šumom

| Kod   | out1 (V) | out2 (V) | out3 (V) | out4 (V) | out5 (V) |
|-------|----------|----------|----------|----------|----------|
| 00000 | -0.384   | 0.0506   | -0.0564  | -0.597   | -0.258   |
|       | 0        | 0        | 0        | 0        | 0        |
| 00001 | -0.079   | 0.0736   | 0.1141   | 0.1084   | 0.927    |
|       | 0        | 0        | 0        | 0        | 1        |
| 00010 | -0.0303  | 0        | -0.0189  | 1.0912   | -0.1183  |
|       | 0        | 0        | 0        | 1        | 0        |
| 00011 | -0.0193  | 0.0105   | -0.016   | 0.9695   | 0.9943   |
|       | 0        | 0        | 0        | 1        | 1        |
| 00100 | -0.0338  | 0.0433   | 1.0483   | -0.0046  | -0.9445  |
|       | 0        | 0        | 1        | 0        | 0        |
| 00101 | 0.2783   | 0.1892   | 0.8489   | 0.2667   | 1.1874   |
|       | 0        | 0        | 1        | 0        | 1        |
| 00110 | -0.1267  | 0.056    | 0.6837   | 0.525    | -0.1864  |
|       | 0        | 0        | 1        | 1        | 0        |
| 00111 | 0.0286   | -0.001   | 1.0128   | 1.0358   | 1.0182   |
|       | 0        | 0        | 1        | 1        | 1        |
| 01000 | -0.0051  | 1.0154   | -0.0048  | 0.0217   | -0.0244  |
|       | 0        | 1        | 0        | 0        | 0        |
| 01001 | -0.2913  | 1.08     | 0.185    | -0.3348  | 1.0243   |
|       | 0        | 1        | 0        | 0        | 1        |
| 01010 | 0.1736   | 0.792    | -0.403   | 0.604    | 0.397    |
|       | 0        | 1        | 0        | 1        | 0        |
| 01011 | 0.18     | 0.93     | 0.026    | 1.06     | 1.15     |
|       | 0        | 1        | 0        | 1        | 1        |

Tabela 3.5 prikazuje nove odzive neuronske mreže. Može se primetiti da u ovom jednostavnom pokušaju verifikacije nema grešaka u pronalaženju defekata.

Umesto zaključka, navešćemo karakteristike opisanog koncepta za dijagnostiku defekata u prikazanom otpornom kolu:

- Istovremeno je razmatran veliki broj defekata, i iz Tabele 3.1 se vidi da su neki vektori vrlo slični, tj. da se njihove razlike mere milivoltima. U nekim slučajevima je amplituda šuma reda veličine amplitude signala, čak i veća. Uprkos tome, dijagnostika je uspešna.
- Kolo je razmatrano u jednosmernom režimu, što ne treba smatrati nedostatkom, jer je u dinamičkom sistemu moguće, dovoljno čestim semplovanjem generisati takve statične signale u okviru periode semplovanja.

Sve razmatrane veličine su naponi. Međutim, treba imati u vidu da se na ulaze neuronske mreže vode brojne vrednosti. Uz odgovarajuću normalizaciju, svaka veličina može da ima isti značaj pri dijagnostici defekata.

Tabela 3.5 (drugi deo) Verifikacija generalizacije. Odzivi neuronske mreže na ulaze sa šumom

|       |         |        |        |         |         |
|-------|---------|--------|--------|---------|---------|
| 01100 | -0.3163 | 1.0971 | 0.9    | -0.176  | -0.2525 |
|       | 0       | 1      | 1      | 0       | 0       |
| 01101 | -0.052  | 0.9521 | 1.052  | 0.0299  | 0.80881 |
|       | 0       | 1      | 1      | 0       | 1       |
| 01110 | 0.0182  | 0.9913 | 1.001  | 1.0062  | 0.0286  |
|       | 0       | 1      | 1      | 1       | 0       |
| 01111 | -0.0259 | 0.8646 | 0.8844 | 0.8295  | 0.9984  |
|       | 0       | 1      | 1      | 1       | 1       |
| 10000 | 1.1494  | 0.134  | 0.1254 | 0.2431  | 0.0122  |
|       | 1       | 0      | 0      | 0       | 0       |
| 10001 | 0.5876  | -0.061 | -0.019 | -0.4034 | 1.2136  |
|       | 1       | 0      | 0      | 0       | 1       |
| 10010 | 0.8643  | -0.071 | 0.0191 | 0.8818  | -0.0289 |
|       | 1       | 0      | 0      | 1       | 0       |
| 10011 | 1.13445 | 0.1555 | 0.0215 | 1.201   | 1.2077  |
|       | 1       | 0      | 0      | 1       | 1       |
| 10100 | 0.8504  | 0.0236 | 0.9367 | -0.3918 | -0.099  |
|       | 1       | 0      | 1      | 0       | 0       |
| 10101 | 0.854   | 0.0578 | 0.903  | 0.117   | 0.899   |
|       | 1       | 0      | 1      | 0       | 1       |
| 10110 | 1.3707  | 0.0046 | 0.7557 | 1.1721  | 0.3255  |
|       | 1       | 0      | 1      | 1       | 0       |



## **4 Dijagnostika nelinearnih dinamičkih analognih kola**

Poznato je da je analogna elektronska kola, koja klasifikujemo kao nelinearna dinamička kola sa nelinearnim dinamičkim elementima, teško dijagnosticirati. Osim velikog broja mogućih defekata, ovo je i posledica nelinearnosti ovih kola. Čak i linearna kola (koja imaju linearnu zavisnost ulaz-izlaz) imaju nelinearnu vezu parametara kola i izlaznog odziva. Aktivne mreže su nelinearne sa nelinearnim reaktivnim elementima, ali mogu da se linearizuju i razmatraju kao takve u situacijama kad su promene signala i parametara male u odnosu na nominalne vrednosti. Kada su u pitanju defekti, u kolu su prisutne velike promene parametara, ili čak katastrofalni defekti. Postojeći teorijski koncepti za dijagnostiku obuhvataju ograničene potklase kola (linearna pasivna ili linearna aktivna), ograničene tipove defekata (uglavnom parametarske), i signala.

### **4.1 Koncepti dijagnostike analognih kola**

Nekoliko različitih koncepata se primenjuje na dijagnostiku analognih mreža. Najpre ćemo pomenuti onaj koji se odnosi na razmatranje zasnovano na merenim podacima i nekim merenjima rastojanja između odziva ispravnog kola i kola sa defektom.

U prvim radovima na ovu temu prikazana su osnovna istraživanja, [13], [31]. U [13] dat je detaljan pregled i poređenje više tehnika za lokalizaciju defekata, među kojima je opisana i tehnika bazirana na formiranju rečnika defekata. Postupak formiranja rečnika, koji se koristi u ovoj disertaciji, je prikazan detaljno, s tim što se dijagnostika dobija poređenjem odziva čuvanih u rečniku i odziva dobijenih simulacijom neispravnog kola. U [31] primenjen je sličan pristup, ali se kolo samo testira, bez dijagnostike.

U [32] faza lokalizacije defekata razmatra se kao problem optimizacije gde se traži vrednost parametra da bi se minimizirala razlika između stvarnog i simuliranog odziva. Linearna kola u frekvencijskom domenu posmatraju se predstavljena svojim simboličkim funkcijama. Slično, u [33] se primenjuje potpuno automatizovani merni sistem za dijagnostiku defekata u analognom elektronskom kolu upotrebom tehnike zasnovane na modelu. Metod se zasniva na korišćenju simboličkih funkcija kola koje su zapravo jednačine za dijagnostiku defekata. Simbolička funkcija predstavlja početak algoritma za lokalizaciju neispravnog elementa, a moguće je dijagnosticirati jednostruke i dvostruke defekte.

SBT (*Simulation-before-test*) metod za dijagnostiku mekih defekata u linearnim kolima predložen je u [34]. Dijagnostika se dobija poređenjem signature dobijene merenjem na testnim čvorovima i one koja se čuva u rečniku defekata, tako da je moguće testiranje podsistema i otkrivanje defekata u kolu. Ono što je specifično za metod, je da se rečnik defekata formira korišćenjem harmonijske analize, koja se koristi i za izbor najpogodnije testne pobude i čvorova pomoću pristupa zasnovanog na osetljivostima.

U [35] je predstavljen algoritam za izbor testnih tačaka korišćenjem teorije grafova za dijagnostiku defekata u pasivnom kolu. Pasivna kola se dijagnosticiraju i u [36] korišćenjem teorije grafova. Zapravo, iz kola se ekstrahuju, a zatim i analiziraju polovi i nule, tj. određuju se regija prolaza i regija otkaza za nule i polove kola u realno-imaginarnoj ravni.

U [37] je predložena *Bool*-ova šema odlučivanja za dijagnostiku linearnih kola opisanih u frekvencijskom domenu. Da bi se dijagnosticirali višestruki meki defekti u istom tipu kola, primenjena je *Woodbury* formula na modifikovanu metodu čvorova da bi se dobila takozvana jednačina defekta [38]. Ta jednačina linearno povezuje merene odzive kola sa višestrukim defektima u kolu.

Metod dekompozicije koristi se u [39] da bi se rešio problem složenosti kola, ali u ovom pristupu kolo može da se razloži i na nepristupačnim čvorovima i da se računaju naponi tih čvorova u kolima sa defektom. Ovaj metod je pogodan jer kolo ne mora da ima veliki broj pristupnih čvorova, a i povećana je fleksibilnost dekompozicije, tako da je metod koristan za velike mreže.

U jednom od pristupa, [40], dozvoljene su male promene parametara pri DC i AC analizi linearnih, i samo u DC analizi nelinearnih kola. Dijagnostika se ne zasniva na optimizaciji kao u većini slučajeva, već se uvodi metod linearnog programiranja u dijagnostičkom odlučivanju. Razmatrani su samo meki defekti, dok je dijagnostika velikih parametarskih defekata je opisana u [41]. Rečnik defekata je podeljen na DC i AC deo; za jednosmernu analizu koriste se linearno-segmentni modeli, a odvojena razmatranja tiču se dijagnostike defekata u dinamičkom delu mreže (nelinearni elementi su aproksimirani linearno segmentnim modelima), i ta razmatranja su zasnovana na izračunavanjima velikih promena osetljivosti. Dalje, u [42] dijagnostički metod koji se primenjuje sastoji se u ubacivanju mogućih defekata u matematički model linearnog kola, da bi se kasnije poredio odziv tog kola sa odzivom pravog kola sa defektom. Formirane su prenosne funkcije transformisane u Z domen, pa je ubacivanje defekata obavljeno u Z domenu.

U [43] primenjuje se metodologija zasnovana na linearnoj regresiji modela korišćenjem ranijih simulacija kola, koje povezuju skup merenja sa internim parametrima kola. Najpre se bira skup merenja koja se obavljaju da bi se dobila potpuna dijagnostička informacija o komponenti koja se testira. Iz ovih odabranih merenja, dobijaju se rešenja za vrednosti parametara upotrebom iterativnih numeričkih tehnika.

Linearna kola u frekvencijskom domenu dijagnosticirana su u [44] gde se računa frekvencijski odziv na skupu sinusnih ulaznih frekvencija u izabranim testnim čvorovima. *Prony*-jev metod je zatim korišćen kao pretprocesor da bi se ekstrahovao optimalni skup karakteristika koje predstavljaju talasne oblike napona čvorova. Dobijene karakteristike se koriste za obučavanje neuronske mreže *back-propagation* algoritmom da bi se dijagnosticirali defekti u kolu. U [45] predlaže se rešenje istog problema zasnovano na merenju šuma. Razmatrana su izračunavanja šuma u kolu sa defektom, koja zbog defekta nekada mogu biti vrlo komplikovana, a šum neispravnog

kola se računa da bi se kasnije uporedio sa šumom ispravnog kola, i da bi se tako izolovao defekt u kolu.

Meki i tvrdi defekti (kratki spojevi i prekidi) u nelinearnom dinamičkom kolu dijagnosticirani su u [46]. Postupak uključuje statistički metod izračunavanja *Mahalanobis*-ovog rastojanja da bi se našli defekti na štampanim pločama i komponentama. Prikazana je kratka lista defekata. Dijagnostika u malošumnom pojačavaču prikazana je u [47] korišćenjem digitalnih signatura pogodnih za koncepte projektovanja sa samotestiranjem (*built-in self test design*).

## 4.2 Izbor testnih tačaka i izlaznih veličina koje se mere

Specifičan aspekt dijagnostike je broj i položaj testnih tačaka. Jednostavno, možemo reći da treba izbegavati testne tačke koje se nalaze unutar kola, tj. preporučuje se da se merenja obavljaju na ulazima i izlazima kola ili sistema koji se dijagnosticira. Razlog nije samo to što im je lako pristupiti, već je vezan i za samu prirodu dijagnostičkog procesa. Naime, neispravan rad sistema se uočava na osnovu prestanka funkcije, a funkcija kola se vidi na njegovom izlazu. Naravno, da bi se kompenzovao eventualno mali broj testnih tačaka, treba obaviti više merenja sa različitim tipovima signala, kako bi se dobila kompletna informacija o ponašanju sistema.

Za kompleksne analogne sisteme se, međutim, primenjuju hijerarhijski pristupi zasnovani na dekompoziciji [10], [11], [13], [39], pri čemu se mora voditi računa da se ne javi kašnjenje efekta defekta između delova sistema, što nije lako postići. Naravno, postoje kola koja se mogu podeliti na funkcionalne celine, što je *a priori* poznato iz procesa projektovanja. U [10] hijerarhijski pristup uvodi i novi postupak za izbor minimalnog broja testnih tačaka, pomoću kojih je moguće testirati sve testne kombinacije u novoformiranim testnim celinama. Metod dekompozicije u [39] takođe opisuje tehniku koja smanjuje zahteve koji se tiču broja pristupnih čvorova, a samim tim i povećava fleksibilnost dekompozicije.

Sledeći aspekt od fundamentalnog značaja vezan je za izbor izlaznih veličina koje se mere. U većini slučajeva to su naponi na izlazu kola koje se testira (CUT, *circuit-under-test*) ili u izabranim testnim tačkama. Pokazano je, međutim, da se merenje struje napajanja ( $I_{ddq}$ ) uspešno može iskoristiti za testiranje i analognih i digitalnih kola [48], [49], [50], [51], [52]. Ova ideja je iskorišćena za dijagnostiku analognih kola upotrebom veštačkih neuronskih mreža, i biće diskutovana kasnije.

Objavljeno je nekoliko rezultata gde su koncepti takozvane veštačke inteligencije primenjeni na analizu analognih, ili bar linearnih kola. U [53] za dijagnostiku defekata u linearnim kontinualnim vremenskim mrežama koristi se metod zasnovan na konceptu trajektorije defekta, koji se oslanja na evolutivne tehnike, gde se kodira genetski algoritam da bi se optimizovalo generisanje testnog vektora. Genetski algoritam je primenjen u [16] za generisanje "prenosnih funkcija" koje omogućavaju stvaranje novog tipa rečnika defekata. Klasičan rečnik signatura zamenjen je dekoderom defekata baziranim na prenosnim funkcijama. Da bi se dobila jasnija dijagnostika o mogućoj neispravnoj komponenti u kolu, u [17] se koristi alat zasnovan na kvalitativnom zaključivanju. Zapravo, rezultati su prečišćeni korišćenjem fazi tehnika. Ovo znači da su definisani ulazi, izlazi, pravila i odgovarajući operatori. Koncept veštačke inteligencije zasnovane na pravilu prikazan je u [14].

## 4.3 Različite primene VNM u dijagnostici analognih kola

VNM su primenjene na dijagnostiku u [18], [54], [55], [56], [57], [58], [59], [60], [61], [62], [63], [64], [65]. Kao što je slučaj sa klasičnim konceptima, i VNM su prvo primenjene na linearna analogna kola.

U [54] *feed-forward* (nerekurentna) neuronska mreža se koristi za identifikaciju nepoznatih parametara aktivnog filtra pobuđenog naponom. U [55] linearne mreže snage se dijagnosticiraju *feed-forward* mrežom. Opisani pristup omogućava

skalabilnost i dinamičku sposobnost prilagođavanja zahtevima. Da bi se poboljšale performanse neuronske mreže primenjene na dijagnostiku mekih defekata u linearnim aktivnim mrežama, u [18] se primenjuje novi “kriterijum”- selektivno merenje zasnovano na neslaganju autokorelacione funkcije ispravnog kola i korelacione funkcije ispravnog kola i kola sa defektom. Novi dijagnostički sistem se tako sastoji od generatora belog šuma i neuronske mreže koja analizira i klasifikuje odzive. Isti problem razmatran je u [56], [59] gde je opisan dijagnostički sistem zasnovan na neuronskim mrežama koje koriste dekompoziciju *wavelet*-a, analizu komponenti i normalizaciju podataka kao pretprocesore. Pomenuti sistem ima sposobnost identifikacije i detekcije neispravnih komponenti u analognom kolu analizom njegovog impulsnog odziva. Dekompozicija *wavelet*-a preprocesira impulsni odziv i tako drastično smanjuje broj ulaza u neuronsku mrežu. Razmatrani su samo meki defekti.

U [57] je opisan metod zasnovan na ekstrakciji “vektora karakteristika” iz razlike vektora napona čvorova ispravnog kola i kola sa defektom za svaki defekt. Ovaj vektor karakteristika se zatim vodi na VNM radi obučavanja. Primenjuje se dekompozicija mreže da bi se rešio problem složenosti kola sa 11 bipolarnih tranzistora. Svaki deo se zatim posmatra kao linearni iako se razmatraju katastrofalni defekti (npr. otkaćena baza tranzistora).

U [58] linearno otporno kolo se dijagnosticira korišćenjem *feed-forward* mreže. Razmatrani su samo katastrofalni defekti, uzeti su u obzir prekidi i kratki spojevi u svakoj grani u kolu. Na šemi prikazanoj u [63] (jedan operacioni pojačavač, jedan kondenzator, tri otpornika i dve diode) koristi se programabilni generator funkcija da bi se generisao skup pobuda sekvencijalno ubačenih na ulaz CUT-a. Izabrano je šest frekvencija. Za svaku pobudu razmatra se frekvencijski odziv CUT-a i analizatorom spektra se meri pet Furijeovih komponenti u izlaznoj testnoj tački. U cilju dijagnostike, koriste se četiri neuronske mreže. Neuronska mreža treba da uči Euklidovo rastojanje da bi se napravili zaključci o mestu nastanka defekta.

Dijagnostika bipolarnih analognih integrisanih kola i određivanje njihovih otpornosti iz amplituda Furijeovih harmonika u spektru odziva na ulazni sinusni testni signal pokazani su u [64]. Koristi se višeslojni perceptron koji klasifikuje odzive da bi se otkrio defekt. Ulazni vektor u VNM sadrži amplitude Furijeovih harmonika. Postupak obuhvata analizu osetljivosti da bi se otkrile amplitude koje su najosetljivije na defekte, kao i defekti na koje je funkcionisanje kola najosetljivije.

Statistička neuronska mreža primenjena je u [65]. To je četvoroslojna *feed-forward* neuronska mreža koja realizuje *Bay*-ov klasifikator. VNM generiše verovatnoću da je kolo neispravno i ukazuje na tip defekta. U [60] formiran je veliki broj verzija kola uvođenjem skupa modela za svaki pojedinačni defekt. Zapravo, razmatraju se katastrofalni defekti, tako što se kratki spojevi i prekidi modeluju otpornicima promenljive otpornosti. Onda se ekstrahuju statističke karakteristike vremenskog odziva (u ovom slučaju struje napajanja) na trapeznu pobudu da bi se dobila informacija o preslikavanju defekt-efekat defekta. Klasifikacija defekata obavlja se i na osnovu odziva kola u frekvencijskom domenu.

Struja napajanja je uspešno korišćena za dijagnostiku kratkih spojeva u oksidu gejta u CMOS operacionim pojačavačima pomoću VNM u [61], [62]. Nakon uvođenja neispravnog modela MOS tranzistora formiranog kao redna veza dva MOS tranzistora sa zajedničkim gejtom (posmatrajući ovo kao meki defekt), nekoliko defekata po tranzistoru (za sve tranzistore u operacionom pojačavaču od 11 tranzistora) je kreirano promenom mogućeg položaja kratkog spoja u odnosu na kraj kanala. Sinusni i linearno rastući signali se koriste za dobijanje rečnika defekata. Odziv, tj. struja napajanja se uzorkuje da bi se dobio niz vrednosti korišćenih za obučavanje *feed-forward* mreže [61], odnosno višeslojnih perceptrona i Kohonenove mape [62].

#### **4.4 Primer primene VNM na dijagnostiku defekata u kolu operacionog pojačavača**

U ovoj disertaciji opisujemo rezultate primene *feed-forward* neuronske mreže na dijagnostiku nelinearnih dinamičkih elektronskih kola, bez ograničenja na broj i tip defekata. Ovaj metod zasniva se na kreiranju rečnika defekata i korišćenju VNM za


kompresiju podataka pamćenjem tabele koja predstavlja rečnik defekata. Biće primenjena samo jednosmerna i sinusna pobuda malih signala, da bi se zadržao uobičajeni postupak merenja radi dobijanja podataka datih u dokumentaciji komponente i/ili kola. Tako dobijena VNM se koristi u postupku dijagnostike tako što se na nju priključuju signali dobijeni merenjem neispravne mreže. Ovaj proces može da se posmatra kao pretraživanje defekata u rečniku defekata. VNM pronalazi najverovatniji kod defekta koji odgovara merenim signalima.

Kada se ovo stavi u opšti kontekst dijagnostike, prvo primećujemo da rečnik defekata sadrži svo znanje koje nam je potrebno. Drugim rečima, primenom SBT koncepta sve hipoteze su zapamćene (u VNM), i nije više potrebno kreirati nove hipoteze kada je rečnik već poznat. Ovo je ekvivalentno strukturalnom konceptu testiranja. Defekt koji nije unapred smišljen ne može biti testiran, niti dijagnosticiran. Sada među hipotezama (pretraživanjem rečnika, tj. aktiviranjem VNM) tražimo najbližnju stvarnom (neispravnom) odzivu kola. Teškoće koje se ovde javljaju su složenost pretraživanja i algoritam odlučivanja koji pronalazi "najbližnji" zapis u rečniku. Kao što će biti pokazano u primeru, ovo može biti izuzetno težak zadatak. Uspešno je rešen korišćenjem VNM [66].

Mreža koja se koristi u ovom primeru je troslojna *feed-forward* neuronska mreža. Ona ima samo jedan skriveni sloj, koji se pokazao dovoljnim za ovu vrstu problema [6]. Neuroni u skrivenom sloju aktiviraju se sigmoidnom funkcijom, dok se neuroni u izlaznom sloju aktiviraju linearnom funkcijom. Algoritam za obučavanje ove neuronske mreže je verzija algoritma minimizacije najstrmijeg pada (*steepest-descent minimization algorithm*) [67].

#### 4.4.1 Kreiranje rečnika defekata

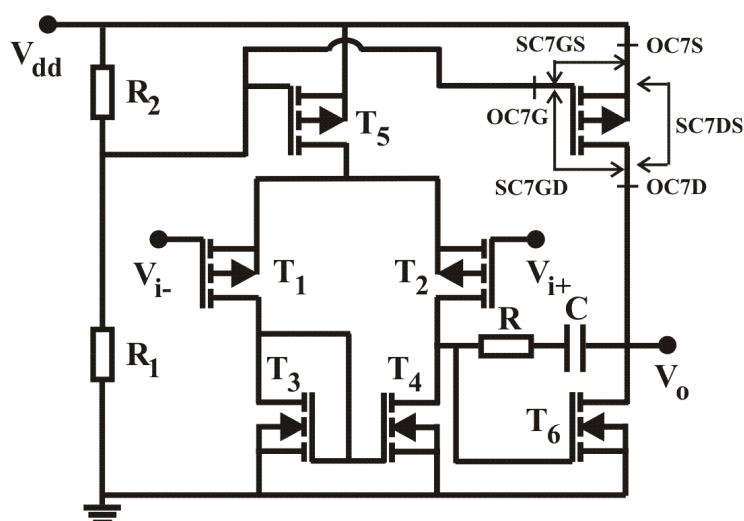
Da bismo opisali način na koji se kreira rečnik defekata, koristićemo kolo sa Slike 4.2 kao primer primene. To je operacioni pojačavač koji se sastoji od sedam tranzistora. Ovaj primer spada u kategoriju najsloženijih do sada objavljenih primera, kako sa stanovišta broja elemenata kola, tako i zbog broja razmatranih defekata. Primetimo da su po tri (nelinearna) kondenzatora vezana za svaki tranzistor, Slika 4.1, tako da je ukupan broj nelinearnih elemenata kola 28, ali ovo, radi jednostavnosti, nije prikazano na Slici 4.2. Da bi se istakao sam metod kao takav, iako imamo u vidu da se dijagnostički problem ovog kola ne rešava potpuno, i da kolo zaista sadrži brojne moguće defekte, ipak ćemo razmotriti smanjen skup defekata. Ograničićemo se samo na defekte tranzistora. Naravno, to neće uticati na opštost primenjenih ideja. Takođe, ne razmatra se istovremeno prisustvo više defekata.



**Slika 4.1** Tranzistor sa nelinearnim kapacitivnostima

Rečnik defekata za kolo sa Slike 4.2. dat je u Tabeli 4.1, gde  $m=0$  označava ispravno kolo. U rečniku je deset defekata po tranzistoru, šest katastrofalnih i četiri meka (parametarska). Kao što je prikazano na Slici 4.2 ( $T_7$  se koristi kao primer), za svaki tranzistor postoji po šest mogućih katastrofalnih defekata- tri defekta otvorenog

kola (*open circuit -OC*) i tri defekta kratkog spoja (*short circuit -SC*). Oznake u Tabeli 4.1 su sledeće: OC3G označava otvoreni gejt tranzistora  $T_3$ , a SC1DG označava kratak spoj između drejna i gejta tranzistora  $T_1$ . Nasuprot postupku u [60] i nekim drugim, u ovom primeru su kratki spojevi i prekidi zaista implementirani, umesto uobičajenog postupka korišćenja otpornika za modelovanje ovog tipa defekata. Zatim, meki (parametarski) defekti su posmatrani kao promena dužine i širine kanala tranzistora. Naime, razmatrane su po dve promene za svaku dužinu kanala ( $\pm 20\%$ ) (označeno kao  $L+$  i  $L-$  u Tabeli 4.1) i dve promene za svaku širinu kanala ( $\pm 20\%$ ) (označeno kao  $W+$  i  $W-$  u Tabeli 4.1). Parametarski defekti ovako prikazani trebalo bi da modeluju greške projektovanja, i, na specifičan način, kratak spoj u gejt oksida imajući u vidu model defekta pokazan u [61]. Za celo kolo tako imamo  $7 \cdot 10 = 70$  defekata koje analiziramo. Tabela 4.1 sastoji se iz dva dela. U prvom delu je rečnik katastrofalnih, a u drugom delu parametarskih defekata.



**Slika 4.2 Kolo operacionog pojačavača.**  
**SC (short circuit)- kratak spoj, OC (open circuit)- otvoreno kolo**

Simulacijom se najpre dobijaju jednosmerne izlazne vrednosti ( $V_{oDCm}$ ). Ovde  $m=0,1,2, \dots, 69$  označava kod defekta. Sledećom simulacijom dobija se frekvencijski odziv kola (neinvertujući ulaz operacionog pojačavača pobuđen je signalom amplitude 1mV). Kolo se analizira u određenom frekvencijskom opsegu da bismo dobili 2 parametra odziva: nominalno pojačanje ( $A_m$ ) i graničnu frekvenciju ( $f_{3\text{ dB } m}$ ). Za dati primer, smatra se da je ovakva signatura dovoljno kompleksna. Ako se uključuje još mogućih defekata, može se pomisliti da su korisna merenja još nekih veličina u kolu, kao na primer struje napajanja. Međutim, sa stanovišta struje napajanja, efekti većine defekata tipa prekid u drejnu i sorsu redno vezanih tranzistora, mogu imati iste signature (na primer, kroz tranzistore  $T_1$  i  $T_3$ , kao i kroz  $T_2$  i  $T_4$  teku iste struje).

Zbog nelinearnosti kola, očekuje se da svaki defekt promeni mirnu radnu tačku tranzistora. Zbog toga, napravljeni su novi linearni modeli tranzistora SPICE-like programom koji se koriste za frekvencijsku analizu za svaki defekt. Da bi se našle nove mirne radne tačke za svaki defekt, moramo da ubacimo defekt, tj. da kreiramo model sa defektom za svako kolo za jednosmernu analizu. Ovaj postupak je opisan u drugim radovima [68], [69], tako da ovde neće biti diskutovan. Defekt SC3DG nije moguće testirati jer kratka veza između gejta i drejna  $T_3$  već postoji. Ovo smanjuje rečnik defekata na 69 elemenata. Zbog toga, rečnik defekata koji je ovde kreiran ima 4 kolone koje sadrže skup performansi kola, tj. signature i kodove defekata:  $\{A_m, f_{3\text{ dB } m}, V_{oDC m}, m\}$ . Prva tri elementa smatramo za ulaz u neuronsku mrežu, dok kod defekta neuronska mreža uči i on se smatra izlazom neuronske mreže.

Tabela 4.1 (prvi deo): Rečnik defekata za kolo sa Slike 4.2.  
Katastrofalni defekti

| Tip defekta | Kod | A                      | $f_{3dB}$ [MHz] | $V_{0DC}$ [V] |
|-------------|-----|------------------------|-----------------|---------------|
| FF          | 0   | 419                    | 0.01527         | 0.127         |
| SC1DG       | 6   | 0.042                  | 320.44          | 0.0458        |
| SC2DG       | 21  | 0.83                   | Neodređen       | 3.3           |
| SC4DG       | 31  | $A \rightarrow \infty$ | Neodređen       | 0.121         |
| SC5DG       | 11  | 0.211                  | Neodređen       | 0.022         |
| SC6DG       | 39  | $A \rightarrow \infty$ | Neodređen       | 0.8956        |
| SC7DG       | 36  | 0                      | Neodređen       | 0.8824        |
| SC1GS (7)   | 46  | 0.055                  | 515.993         | 3.3           |
| SC5GS (8)   | 2   | 0.109                  | 0.036           | 0             |
| SC1DS       | 12  | $A \rightarrow \infty$ | Neodređen       | 3.234         |
| SC2DS       | 27  | 0.071                  | 312.071         | 3.3           |
| SC4DS (9)   | 20  | 0                      | Neodređen       | 3.3           |
| SC5DS       | 55  | 0.656                  | 0.57            | 0.0186        |
| SC6DS       | 8   | 0                      | Neodređen       | 0             |
| OC1D (1)    | 29  | 0.31                   | Neodređen       | 0.0179        |
| OC2D        | 52  | 0.005                  | 133.757         | 3.3           |
| OC3D (2)    | 10  | 0.041                  | 365.8           | 3.3           |
| OC4D (3)    | 7   | 0.303                  | Neodređen       | 0.0458        |
| OC5D (4)    | 25  | 0.056                  | 507.298         | 3.3           |
| OC6D (5)    | 33  | 0.063                  | 0.039           | 3.3           |
| OC7D (6)    | 9   | $A \rightarrow \infty$ | Neodređen       | 0             |
| OC1G        | 49  | 0.047                  | 501.187         | 0.127         |
| OC2G        | 18  | 0.32                   | Neodređen       | 0.127         |
| OC3G        | 47  | 0.049                  | 544.042         | 0.093         |
| OC4G        | 19  | 0.318                  | Neodređen       | 0.064         |
| OC5G        | 26  | 11.739                 | 0.12            | 0.127         |
| OC6G        | 45  | 0.183                  | Neodređen       | 0.064         |
| OC7G        | 15  | 193                    | 0.023           | 0.127         |
| OC2S        | 54  | 0.041                  | 428.73          | 3.3           |

Kodiranje defekata je od velikog značaja. Zapravo, neki defekti imaju vrlo slične efekte defekta. Zbog toga ulazni podaci (signature) mogu da imaju veoma bliske numeričke vrednosti, i kada bi i izlazne vrednosti (kodovi defekata) bile takođe slične, neuronska mreža ne bi uvek bila uspešno obučena. Takav primer dat je na Slikama 4.3 i 4.4, gde je prikazano poređenje defekata. Pažljivim posmatranjem se uočava da jedino vrednosti  $f_{3dB}$  ukazuju na razliku između efekata defekata. Defekti su kodirani slučajno, tako da je mala verovatnoća da defekti sa sličnim efektima imaju slične kodove. Pokazano je da je ovaj pristup dobar, jer način kodiranja utiče na vreme obučavanja, i takođe, na grešku obučavanja, a vrlo često je čak nemoguće obučiti mrežu da uči ispravno ako je loše kodirana.


Tabela 4.1 (drugi deo): Rečnik defekata za kolo sa Slike 4.2.  
Parametarski defekti

| Tip defekta | Kod | A      | $f_{3dB}$ [MHz] | $V_{0DC}$ [V] |
|-------------|-----|--------|-----------------|---------------|
| 1W+         | 24  | 0.055  | 1.848           | 3.3           |
| 1W-         | 23  | 0.012  | 3.043           | 0.052         |
| 1L+         | 37  | 0.0053 | 6.791           | 0.0497        |
| 1L-         | 30  | 0.0416 | 4.058           | 3.3           |
| 2W+         | 22  | 0.022  | 2.113           | 0.0528        |
| 2W-         | 32  | 0.0478 | 2.196           | 3.3           |
| 2L+         | 48  | 0.042  | 3.286           | 3.3           |
| 2L-         | 43  | 0.0038 | 17.191          | 0.0509        |
| 3W+         | 4   | 0.0156 | 2.417           | 0.0525        |
| 3W-         | 44  | 0.0544 | 2.512           | 3.3           |
| 3L+ (10)    | 38  | 0.0543 | 2.371           | 3.3           |
| 3L-         | 51  | 0.0068 | 4.612           | 0.0515        |
| 4W-         | 14  | 0.0097 | 3.48            | 0.052         |
| 4L+         | 28  | 0.0093 | 3.687           | 0.0521        |
| 4L-         | 40  | 0.0525 | 3.162           | 3.3           |
| 5W+         | 35  | 209    | 0.0237          | 0.1092        |
| 5W-         | 3   | 6028   | 0.0015          | 0.1712        |
| 5L+         | 50  | 6030   | 0.0015          | 0.2466        |
| 5L-         | 42  | 152    | 0.0293          | 0.0934        |
| 6W+         | 17  | 195.7  | 0.022           | 0.0984        |
| 6W-         | 13  | 5770   | 0.0018          | 0.2146        |
| 6L+         | 16  | 8220   | 0.00126         | 0.4876        |
| 6L-         | 53  | 119.4  | 0.02712         | 0.0843        |
| 7W+         | 34  | 5809   | 0.00178         | 0.1811        |
| 7W-         | 41  | 174.7  | 0.0237          | 0.0925        |
| 7L+         | 1   | 129.6  | 0.0261          | 0.079         |
| 7L-         | 5   | 4453   | 0.0023          | 1.0255        |

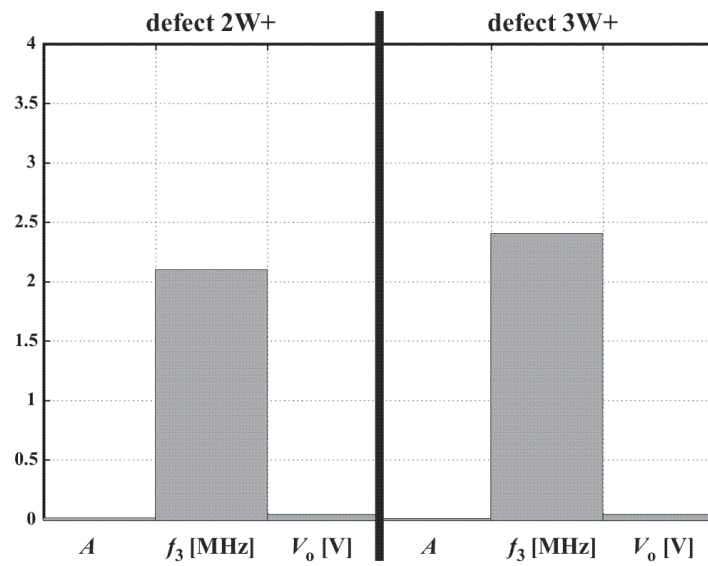
Uvid o težini problema može se steći na osnovu histograma prikazanim na Slikama 4.5, 4.6 i 4.7. Na histogramima su zapravo samo grafički predstavljeni podaci iz rečnika defekata kako bi moglo da se uoči da je nemoguće uspostaviti bilo kakvo pravilo koje bi povezivalo ove podatke.

Sada se postavljaju dodatna pitanja koja se tiču primenljivosti pristupa koji se zasniva na pravilu na dijagnostiku sistema ovog tipa. Zbog sličnog ponašanja kola u prisustvu različitih defekata, ne može se uspostaviti nijedan skup pravila na osnovu kojih bi se ova tri defekta razlikovala. Štaviše, ispitivanjem Tabele 4.1 i Slika 4.5, 4.6 i 4.7, možemo videti da dobijene vrednosti pokrivaju veliki opseg. Na primer, za pojačanje napona, najmanja vrednost u tabeli je 0.0053, a najveća 5770. Na osnovu ovoga ne možemo uspostaviti pravilo koje definiše razliku koja se javlja kao posledica prisustva određenog defekta. Ovi pristupi koji se zasnivaju na pravilu su nepraktični za sisteme čiji su odzivi kontinualne funkcije. Zatim, očekujemo da se podaci pojave sa šumom kada inženjer održavanja obavlja merenja što dalje komplikuje kreiranje bilo kakvih pravila. Možemo da tvrdimo da bi se isto desilo kada bi se koristila fazifikacija da bi se istakla razlika između različitih signatura. I dalje, ista verovatnoća događaja je za korišćenje koncepta simulacije posle testa.

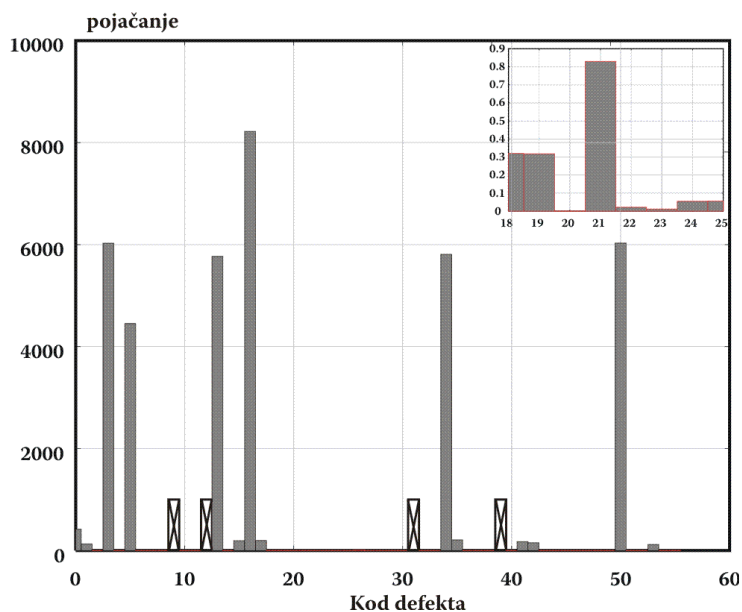




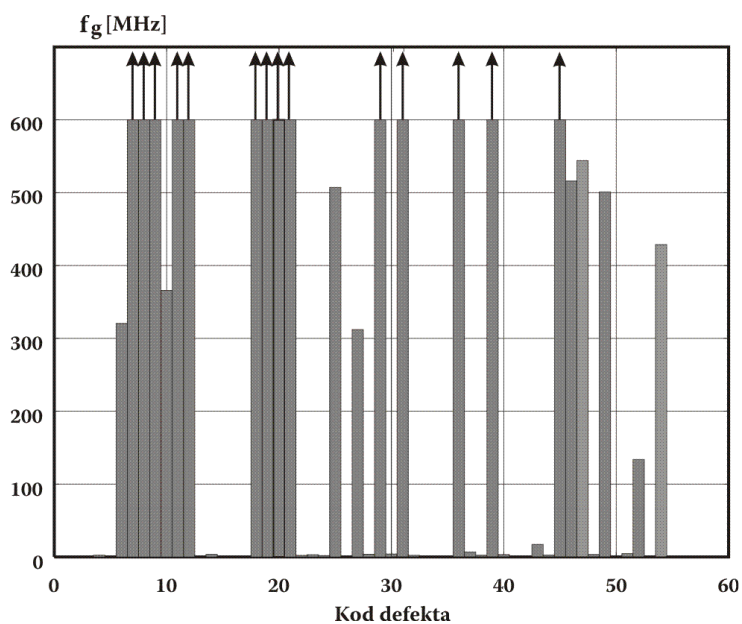
**Slika 4.3. Efekti defekata 4W-, 4L+ i 1W-**



**Slika 4.4 Efekti defekata 2W+ i 3W+**



**Slika 4.5 Vrednost pojaćanja za različite defekte.**  
**Pravougaonici sa X oznakom pokazuju defekte za koje nije moguće odrediti pojaćanje**




**Slika 4.6 Vrednost granične frekvencije za različite defekte.**  
**Strelice ukazuju da je frekvencija veća od 1GHz, ili da je nemoguće odrediti zbog nemogućnosti određivanja pojaćanja**

#### 4.4.2 Formiranje *ambiguity* grupa

Rečnik defekata se može još smanjiti uzimanjem u obzir *ambiguity* grupa, tj. grupa ekvivalentnih defekata. Imajući u vidu [70], “*ambiguity* grupa je grupa komponenata, među kojima, u slučaju greške, nije moguće identifikovati neispravnu”. U ovom slučaju, možemo reći da se *ambiguity* grupa sastoji od skupa defekata koji stvaraju

identične signature na izlazima, tako da su defekti detektibilni i kolo je testabilno, ali se ne može napraviti razlika između pojedinačnih defekata, što znači da ih je nemoguće dijagnosticirati. Tabela 4.2 pokazuje svih 10 *ambiguity* grupa za ovaj primer, sistematično organizovanih nakon simulacije. Defekti italizirani u Tabeli 4.2 predstavljaju istu topološku vezu u kolu, pa je prirodno očekivati isti efekat.



**Slika 4.7 Vrednost jednosmernog izlaznog napona za različite defekte**

Specifična *ambiguity* grupa dobija se za slučaj da pojačanje ( $A$ ), iako vrlo malo, stalno povećava vrednost u datom frekvencijskom opsegu. Ovo je označeno  $A \rightarrow \infty$ . Graničnu frekvenciju je nemoguće odrediti u ovom slučaju, pa u tabelama piše *neodređen*. Ova oznaka se takođe odnosi i na slučajeve kada je granična frekvencija veća od 1GHz, odnosno nalazi se van opsega od interesa. Treba primetiti da se ovakve situacije javljaju samo kada je u kolu prisutan katastrofalni defekt, što je i logično očekivati, jer se topologija kola u celosti menja. Neki od defekata pokazuju ovo svojstvo, međutim imaju različite  $V_{0DC}$  vrednosti, tako da ih je moguće razlikovati. U tim slučajevima, da bismo izbegli korišćenje beskonačnih vrednosti pri obučavanju VNM, pojačanju pridružujemo vrednost 1000. Ovo je slučaj kada se simuliraju defekti OCS7 i OCD7, ali pošto ovi defekti imaju potpuno isti efekat, formiraju *ambiguity* grupu 6.

Slična situacija se dešava kada je pojačanje skoro nula, pa to označavamo kao  $A=0$ . Graničnu frekvenciju je ponovo nemoguće odrediti. *Ambiguity* grupa broj 9 pokriva tri ovakva defekta, sa istim  $V_{0DC}$ .

Tabela 4. 2: *Ambiguity* grupe i efekti defekata

| <i>Ambiguity</i> grupa | Defekti | A                      | $f_{3dB}$ [MHz] | $V_{oDC}$ [V] |
|------------------------|---------|------------------------|-----------------|---------------|
| 1                      | OC1D    | 0.31                   | 20000           | 0.0179        |
|                        | OC1S    |                        |                 |               |
| 2                      | OC3D    | 0.041                  | 365.8           | 3.3           |
|                        | OC3S    |                        |                 |               |
| 3                      | OC4D    | 0.303                  | 20000           | 0.0458        |
|                        | OC4S    |                        |                 |               |
|                        | SC4GS   |                        |                 |               |
|                        | SC3GS   |                        |                 |               |
| 4                      | OC5D    | 0.056                  | 507.298         | 3.3           |
|                        | OC5S    |                        |                 |               |
| 5                      | OC6D    | 0.063                  | 0.039           | 3.3           |
|                        | OC6S    |                        |                 |               |
| 6                      | OC7D    | $A \rightarrow \infty$ | Ne-<br>određen  | 0             |
|                        | OC7S    |                        |                 |               |
| 7                      | SC1GS   | 0.055                  | 515.993         | 3.3           |
|                        | SC2GS   |                        |                 |               |
| 8                      | SC5GS   | 0.109                  | 0.036           | 0             |
|                        | SC7GS   |                        |                 |               |
| 9                      | SC4DS   | A=0                    | Ne-<br>određen  | 3.3           |
|                        | SC6GS   |                        |                 |               |
|                        | SC7DS   |                        |                 |               |
| 10                     | 3L+     | 0.05                   | 2.37            | 3.3           |
|                        | 4W+     |                        |                 |               |

U rečniku defekata je samo po jedan predstavnik svake *ambiguity* grupe, i to je u rečniku označeno sa, npr. OC1D (1), gde je OC1D predstavnik prve (1) *ambiguity* grupe, a ostali članovi te grupe prikazani su u Tabeli 4.2. Iz Tabela 4.1 i 4.2 se vidi da rečnik defekata u ovom slučaju ima  $70-1-24+10=55$  elemenata.

#### 4.4.3 Obučavanje neuronske mreže

Sa po tri podatka za svaki defekt, struktura neuronske mreže je ograničena na tri ulazna priključka. VNM obavlja dijagnostiku tako što na izlazu daje kod defekta ( $m$ ) kao nivo signala, tako da nam je potreban samo jedan izlazni neuron. Broj skrivenih neurona,  $n$ , ustanovljen je metodom probe i greške posle nekoliko iteracija, a na osnovu početne procene date u [71]. Cilj je pronaći optimalno  $n$  koje vodi zadovoljavajućoj klasifikaciji čak i sa pobudama sa šumom. Previše skrivenih neurona bi povećalo vreme obučavanja, ali sa premalim brojem mreža ne bi imala dovoljno podataka da reši problem. Takođe, preterani broj skrivenih neurona može da uzrokuje problem prezasićenja (*overfitting*), gde mreža ima toliku sposobnost da uči beznačajne aspekte skupova za obučavanje, beznačajnih za opšte karakteristike. U praksi je korišćeno 30 neurona. Posle uspešnog učenja, nije bilo grešaka za svih 55 defekata. U Tabeli 4.3 prikazani su parametri neuronske mreže, njene težine i pragovi.

Tabela 4.3. Težine i pragovi neuronske mreže

| skriveni neuron, $j$ | $w_i(1, j)$ | $w_i(2, j)$ | $w_i(3, j)$ | $\theta_{h_j}$ | izlazni neuron, $i$ | $w_o(i, 1)$ |
|----------------------|-------------|-------------|-------------|----------------|---------------------|-------------|
| 1                    | 45.3723     | 435.809     | 5306.02     | -437.298       | 1                   | 1352.45     |
| 2                    | 7196.2      | 11.9617     | 61.5354     | 1.18612        | 2                   | 2242.53     |
| 3                    | 40.7362     | 650.248     | 4328.6      | -651.107       | 3                   | -1418.56    |
| 4                    | -4339       | 19.4017     | 6.65367     | -36.1689       | 4                   | 134         |
| 5                    | 81.4        | -140.932    | 279.448     | -321.4         | 5                   | 76          |
| 6                    | -83.2479    | 21.0566     | 247.686     | -273.417       | 6                   | 226         |
| 7                    | -968        | -20.2338    | -1364.38    | 22.2452        | 7                   | 120.982     |
| 8                    | -11.5838    | -39.5919    | 15.7434     | 11.8389        | 8                   | -221.689    |
| 9                    | -559.002    | 230.109     | 354.089     | -508.706       | 9                   | -357.172    |
| 10                   | -490        | 172.392     | 82.2379     | -204.001       | 10                  | 339.18      |
| 11                   | -228        | -91.3381    | -11.4601    | 37.5154        | 11                  | 62.0392     |
| 12                   | -354.007    | -15.8781    | 218.871     | -220.14        | 12                  | 210.54      |
| 13                   | -178.7      | -48         | 184.997     | -196.003       | 13                  | 135         |
| 14                   | -353        | 14.0892     | 5.72919     | -29.7008       | 14                  | 46.3        |
| 15                   | -245.082    | -67.6464    | 7.22307     | 1.69063        | 15                  | -88.9606    |
| 16                   | -188.974    | 204.647     | -1.84568    | -205.917       | 16                  | 297.698     |
| 17                   | -97.7567    | 136.459     | -273.775    | 139.02         | 17                  | -270.868    |
| 18                   | 80.1604     | -6.73369    | 288.625     | -288.008       | 18                  | -105.401    |
| 19                   | 90.0461     | -821.052    | 296.787     | -295.214       | 19                  | -12.1073    |
| 20                   | -162.465    | 9.26943     | 186.092     | -199.024       | 20                  | 202         |
| 21                   | 20.6103     | -107.068    | -551.078    | 7.65247        | 21                  | -521.9      |
| 22                   | -194.9      | -14.67      | 175.049     | -232           | 22                  | -7.9        |
| 23                   | -198.382    | -13.3155    | -3.03887    | 1.12742        | 23                  | 84.2374     |
| 24                   | -66.0043    | -9.72197    | 275.114     | -278.803       | 24                  | 423.001     |
| 25                   | 9.1047      | 78.037      | 13.8488     | -12.2617       | 25                  | -146.625    |
| 26                   | -226.135    | -51.5305    | -118.967    | 0.539592       | 26                  | 1426.08     |
| 27                   | -236.9      | 897.478     | -80.749     | -304.982       | 27                  | -12.1553    |
| 28                   | 1645.07     | 191.6       | -131        | -311.1         | 28                  | 61.3416     |
| 29                   | -318.733    | 143.914     | 170.462     | -156.203       | 29                  | 17.8348     |
| 30                   | -247        | -231.002    | -121.685    | 233.157        | 30                  | -4.45909    |
|                      |             |             |             |                | $\theta_{o,1}$      | -1807.55    |

Sposobnost generalizacije mreže verifikovana je dovođenjem podataka sa šumom na njene ulaze. Ovo je pokazano u Tabeli 4.4. Ispitano je 30 uzoraka. Za svaki uzorak, jedan ulaz (boldovan u Tabeli 4.4) promenjen je za +5% ili -5%, predstavljajući šum koji se generiše u procesu merenja. Odzivi mreže dati su u poslednjoj koloni Tabele. Odziv neuronske mreže smatra se ispravnim (tj. prihvatljivim) kada je vrednost odziva u opsegu  $[(m-0.5), (m+0.5)]$ . Možemo videti da je sve defekte još uvek moguće dijagnosticirati uprkos nekim poteškoćama ( $m=20, 35$  i  $54$ ).

Predstavljeni metod je nova tehnika za dijagnostiku defekata u nelinearnim dinamičkim kolima, i može se sažeti na sledeći način.

Skup testnih tačaka u skup merenja treba odrediti u skladu sa nekim opštim principima. Broj testnih tačaka treba da bude što manji, ali tako da se što više koriste primarni ulazi i izlazi. Zatim, broj zahtevanih merenja za uspešnu dijagnostiku mora biti mali, dok, istovremeno, ne bi trebalo primenjivati merenja sa specifičnim signalima. Imajući u vidu mogućnost održavanja, koja je osnovna svrha dijagnostike, treba koristiti merenja koja su već preporučena u dokumentaciji proizvoda.



Tabela 4.4. Ulazi sa šumom i odzivi neuronske mreže

| DIAGNOSTIKA NELIN | Kod | A                   | $f_{3\text{ dB}}$<br>[MHz] | $V_{\text{ODC}}$<br>[V] | VNM<br>odziv     |
|-------------------|-----|---------------------|----------------------------|-------------------------|------------------|
|                   | 0   | 419                 | <b>0.0145</b>              | 0.127                   | -<br>0.021<br>28 |
|                   | 1   | 129.6               | <b>0.0248</b>              | 0.079                   | 1.090<br>57      |
|                   | 2   | 0.109               | 0.036                      | <b>-0.05</b>            | 2.014<br>05      |
|                   | 3   | 6028                | <b>0.00157<br/>5</b>       | 0.1712                  | 2.938<br>68      |
|                   | 5   | 4453                | <b>0.00241<br/>5</b>       | 1.0255                  | 5.032<br>03      |
|                   | 6   | <b>0.0441</b>       | 320.44                     | 0.0458                  | 6.032<br>24      |
|                   | 9   | 1000                | 1000                       | <b>-0.05</b>            | 9.070<br>7       |
|                   | 10  | <b>0.043</b>        | 365.8                      | 3.3                     | 10.02<br>78      |
|                   | 12  | 1000                | 1000                       | <b>3.39</b>             | 12.17<br>71      |
|                   | 13  | 5770                | <b>0.00171</b>             | 0.2146                  | 13.23<br>76      |
|                   | 16  | 8220                | <b>0.00197</b>             | 0.4876                  | 16.03<br>1       |
|                   | 18  | 0.32                | 1000                       | <b>0.133</b>            | 17.84<br>58      |
|                   | 20  | 0                   | 1000                       | <b>3.46</b>             | 20.44<br>09      |
|                   | 21  | 0.83                | 1000                       | <b>3.46</b>             | 20.64<br>97      |
|                   | 25  | <b>0.0588</b>       | 507.298                    | 3.3                     | 25.06<br>05      |
|                   | 26  | 11.739              | <b>0.114</b>               | 0.127                   | 26.00<br>98      |
|                   | 27  | 0.071               | 312.071                    | <b>3.46</b>             | 27.00<br>91      |
|                   | 34  | 5809                | <b>0.00169</b>             | 0.1811                  | 33.75<br>41      |
|                   | 35  | 209                 | 0.0237                     | <b>0.115</b>            | 35.47            |
|                   | 36  | <b>0.05</b>         | 1000                       | 0.8824                  | 36.35<br>14      |
|                   | 37  | <b>0.0055<br/>6</b> | 6.791                      | 0.0497                  | 37.26<br>52      |
|                   | 43  | <b>0.004</b>        | 17.191                     | 0.0509                  | 43.00<br>08      |
|                   | 46  | <b>0.0523</b>       | 515.993                    | 3.3                     | 45.99            |
|                   | 47  | <b>0.0514</b>       | 544.042                    | 0.093                   | 47.01<br>33      |
|                   | 49  | <b>0.0493<br/>5</b> | 501.19                     | 0.127                   | 49.04<br>2       |
|                   | 50  | 6030                | <b>0.00142<br/>5</b>       | 0.2466                  | 49.92<br>84      |
|                   | 52  | 0.005               | 133.757                    | <b>3.46</b>             | 52.00<br>44      |
|                   | 53  | 119.4               | <b>0.0258<br/>55</b>       | 0.0843                  | 53.02<br>05      |
|                   | 54  | 0.041               | <b>428</b>                 | 3.3                     | 53.53<br>46      |
|                   | 55  | <b>0.688</b>        | 0.57                       | 0.0186                  | 54.86            |

Treba obaviti pažljivu analizu liste defekata. Opšte govoreći, broj defekata koji se mogu pojaviti u kolu je ogroman. Broj kratkih spojeva između linija, na primer, je problem kombinatorike koji, čak i kod jednostavnih kola vodi u “prokletstvo dimenzionalnosti”. Zbog toga treba ustanoviti listu mogućih defekata pre nego što projekat počne.

Na osnovu liste defekata kreira se rečnik defekata ubacivanjem modela defekata u netlistu kola i ponavljanjem simulacije sistema koji se testira.

Rečnik defekata, koji je zapravo preslikavanje defekata u skup efekata defekata, pamti veštačka neuronska mreža. Merene (ili simulirane) karakteristike sistema se koriste kao ulazni signalu u VNM, dok je njen izlaz kod defekta. Od projektanta zavisi kako se kod defekta izražava. Ovde se predlaže da je izlazni neuron linearan, tako da nivo signala pokazuje kod. Alternativno, moguće je da nekoliko izlaznih neurona kodira signal. Na primer, šest izlaznih neurona može da kreira šestobitnu reč na izlazu.

Kada nauči rečnik defekata, i kada su joj dati odgovarajući parametri sistema, VNM je sposobna da dijagnosticira sistem čak i sa podacima sa šumom. U nekim slučajevima VNM može biti hardverski implementirana i korišćena *on-line*, čak i u realnom vremenu. Takve primene zahtevaju da merenja budu jednostavna, naročito kada se preporučuje dodatna obrada merenih podataka.

Primenom VNM na dijagnostiku nelinearnih dinamičkih kola, kao što je dato u prethodnom primeru, pokazali smo implementaciju metoda i skup rezultata. Ovi rezultati opravdavaju metodu. U daljem radu nameravamo da rešimo elemente *ambiguity* grupa. Zatim, posmatraće se složeniji sistemi i biće generisani veći rečnici defekata. Zbog toga će biti potreban dodatna merenja da bi se zadržao mali broj testnih tačaka.



## 5 Dijagnostika defekata u hibridnom kolu

Brz razvoj tehnologije integrisanih kola doneo je sa sobom neke teškoće pri testiranju. Porast broja hibridnih kola u poslednje vreme još više komplikuje problem testiranja. Postaje sve složenije odrediti skup ulaznih signala i izlaznih merenja koja bi obezbedila visok stepen pokrivenosti defekata. Postoji takođe i vremenski problem pri testiranju čak i kada se koristi najbrža automatizovana oprema.

U sledećem poglavlju pokušaćemo da dijagnosticiramo defekte u jednom hibridnom kolu. Kao primer složenog hibridnog kola, uzeto je kolo sigma-delta modulatora. Najpre se ispituju defekti u kolu tako što se simulacijom dobije odziv kola sa defektom, a zatim se posmatra spektar tog odziva koji se dobija brзом Furijeovom transformacijom. Zatim, u drugom delu poglavlja, dijagnostika se obavlja na osnovu vremenskog odziva kola.

### 5.1 Arhitektura sigma-delta modulatora

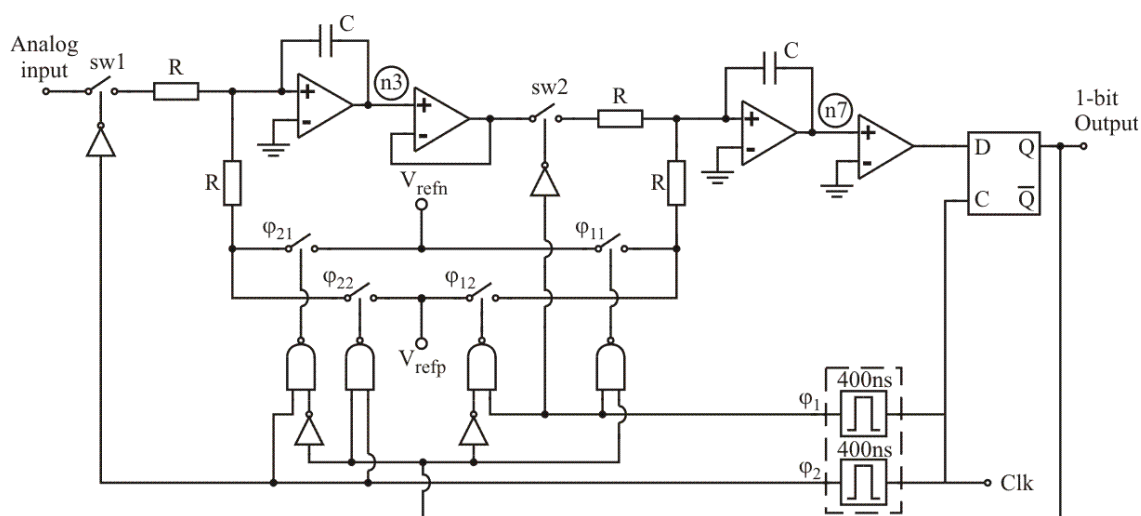
Sigma-delta modulatori su veoma atraktivni za projektovanje analogno digitalnih konvertora visoke rezolucije za niskofrekventne signale (govor, muzika i sl.), jer postižu visoku rezoluciju na račun brzine semplovanja. Oni koriste kvantizaciju sa malim brojem nivoa (grubu kvantizaciju) i jednu ili više povratnih petlji. Kada se sempljuje brzinom koja je mnogo veća od širine opsega signala, moguće je da povratne petlje uobliče šum kvantizacije tako da se većina snage šuma pomera iz propusnog opsega signala. Šum van propusnog opsega se slabi digitalnim filtrom. Stepem potiskivanja kvantizacionog šuma zavisi od reda modulatora i od odnosa frekvencije semplovanja i Nikvistove frekvencije (*oversampling* odnos) [72].

Pored neosetljivosti na tolerancije analognih elemenata u kolu, A/D konvertori koji koriste frekvenciju odmeravanja višu od Nikvistove (*oversampled* A/D konvertori), pojednostavljaju zahteve koje treba da ispune analogna kola. Analogni signal se

sempluje frekvencijom mnogo višom od Nikvistove, pa je precizno kolo za uzorkovanje i odmeravanje (*sample-and-hold*) nepotrebno. Takođe, zahtevi koji se tiču *antialiasing* filtra (filtra za eliminisanje izobličenja u spektru signala) su smanjeni. Ovaj filter se implementira kao digitalni, što omogućava da se projektuje i realizuje veoma precizno, uključujući i linearnu faznu karakteristiku.


## 5.2 Defekti u kolu sigma-delta modulatora

Kao primer složenog kola, izabrano je kolo sigma-delta modulatora sa Slike 5.1. [73].



**Slika 5.1. Arhitektura sigma-delta modulatora**

Ovo je hibridno kolo, koje sadrži i analogne i digitalne elemente. Prekidači u kolu su modelovani kao pravi idealni prekidači, koji imaju otpornost nula kada su zatvoreni i beskonačnu otpornost kada su otvoreni [74], [75].



**Slika 5.2. Rezultati simulacije za linearnu sinusnu pobudu**

Vreme punjenja kondenzatora je nepromenljivo u odnosu na takt, da bi se pojačanje održalo konstantnim. Ovo znači da analogni prekidač mora da bude zatvoren u nekom fiksnom vremenskom intervalu bez obzira na signal takta. Taj efekat se postiže korišćenjem monostabilnog multivibratora kao generatora impulsa fiksne širine u kolu. Monostabilni multivibrator se u kolu nalazi između ulaza za takt i bloka sa kontrolnim prekidačima i ima zadatak da generiše kontrolne signale fiksne trajanja. Na Slici 5.2 pokazani su odzivi sistema na sinusnu pobudu.

Pristup koji ćemo sada pokazati podrazumeva posmatranje spektra izlaznog signala, i to najpre za ispravno kolo, a zatim i za kolo sa različitim defektima (posmatraju se samo jednostruki defekti). Ideja je da se na izlazni signal u vremenskom domenu primeni Brza Furijeova Transformacija (*Fast Fourier Transformation-FFT*), i da se iz tako dobijenog spektra ekstrahuju informacije koje su potrebne za dijagnostiku. Naime, istraživanje je obavljeno u cilju da se posmatra efekat i parametarskih i katastrofalnih defekata u kolu, pa da se na osnovu dobijenih spektara proceni koji parametri spektra mogu da se iskoriste kao ulazna informacija za obučavanje dijagnostičke VNM.

Simulacije se obavljaju korišćenjem Alecsis [76] simulatora. Koristi se 256k uzoraka da bi se dobilo dovoljno podataka za FFT.


Na ulaz modulatora je priključen sinusni signal, 2Vpp, frekvencije 10kHz, Frekvencija takta  $f_s$ , je 833.33kHz. Operacioni pojačavači su idealni, sa pojačanjem  $10^5$  i naponom napajanja  $\pm 12V$ . Elementi kola su:  $R=1k\Omega$ ,  $C=800pF$ .

Spektar snage modulatora bez defekta prikazan je na Slici 5.3. Sa slike se vidi da je frekvencija nosioca 10kHz, a nivo šuma raste 40dB/dec. Ova arhitektura realizuje uobličavanje šuma drugog reda.


Prikazani spektri su normalizovani u odnosu na maksimalnu spektralnu komponentu.

Slučajevi kada su prekidači u povratnoj petlji ( $\phi_{11}$ ,  $\phi_{12}$ ,  $\phi_{21}$ ,  $\phi_{22}$ ) stalno zatvoreni nisu uzeti u obzir, jer bi tada izvori napajanja  $V_{refp}$  i  $V_{refn}$  bili kratkospojeni.

U ovom kolu se posmatraju i katastrofalni (tvrđi) i parametarski (meki) defekti.



**Slika 5.3. FFT za kolo bez defekta**




**Slika 5.4. FFT izlaza kola kada je prekidač sw1 stalno otvoren, "stuck-at-OFF"**

### 5.2.1 Tvrdi defekti

Tvrđi defekti se odnose na analogna kola [77], i njihovo pojavljivanje menja topologiju kola. U kolu sa Slike 5.1, tvrđi defekti se modeluju kao prekidači koji su ili permanentno otvoreni, "stuck-at-OFF", ili permanentno zatvoreni, "stuck-at-ON".

Modelovanje defekata u digitalnim kolima je znatno jednostavnije. Digitalni signal može biti ili u stanju permanentne jedinice (“*stuck-at-1*”), ili u stanju permanentne nule (“*stuck-at-0*”). U kolu sa Slike 5.1, digitalni signali kontrolišu analogne prekidače, tako da postoje parovi istih efekata defekata, kao što su: efekat je isti kada je prekidač permanentno zatvoren (otvoren) i kada je u digitalnom kolu permanentna jedinica (permanentna nula). Zato ćemo te defekte modelovati prekidačima koji su stalno otvoreni, odnosno stalno zatvoreni.




**Slika 5.5. FFT izlaza kola kada je prekidač *sw1* stalno zatvoren, “*stuck-at-ON*”**

Na Slici 5.4, prikazan je izlaz kola kada je prekidač *sw1* stalno otvoren, “*stuck-at-OFF*”. Prekidač *sw1* je vezan na sam ulaz kola, tako da kada je stalno otvoren, nema ulaznog signala u kolo. Ovaj defekt se manifestuje tako što izlaz nema nosilac, samo niži harmonik na frekvenciji  $f_s/4$ .

Slika 5.5 prikazuje spektar izlaznog signala kada je prekidač *sw1* stalno zatvoren, “*stuck-at-ON*”. Prvi stepen modulatora u tom slučaju stalno integriše, tako da dolazi do zasićenja, tj. premašenja dinamičkog opsega integratora jer se dostigne napon napajanja. SFDR (*Spurious Free Dynamic Range*) je smanjen zbog zasićenja, i usled nelinearnih izobličenja dolazi do pojave harmonika.

Na Slici 5.6., imamo situaciju kada je prekidač  $\phi_{11}$  stalno otvoren, “*stuck-at-OFF*”. Napon  $V_{\text{refn}}$  je onda isključen, tako da je smanjena sposobnost praćenja ulaznog napona. Integrator onda ide u zasićenje što zatim smanjuje SNDR (*Signal to Noise Distortion Ratio*), što se vidi sa Slike 5.6.



**Slika 5.6. FFT izlaza kola kada je prekidač  $\phi_{11}$  stalno otvoren, "stuck-at-OFF"**


### 5.2.2 Meki defekti

Meki (parametarski) defekti se javljaju u kolu kada je vrednost nekog parametra promenjena. U frekvencijskom domenu mogu se lako iskazati katastrofalne posledice nekatastrofalnog (mekog) defekta. Naime, ako usled priraštaja jednog kritičnog elementa u kolu, dođe do neprihvatljive promene granične frekvencije kola ili sistema, ono postaje neupotrebljivo i pored toga što topologija kola nije poremećena.


Sigma-delta modulator je kolo veoma tolerantno na promene parametara kola, tako da je efekte defekata teže prepoznati.

Da bismo dobili efekte parametarskih defekata, razmatrali smo promene pojačanja operacionog pojačavača i promene vrednosti kapacitivnosti. Prvi stepen modulatora je osetljiviji na promene parametara, dok promene u drugom stepenu imaju vrlo mali uticaj, zbog uobličavanja šuma. Na Slici 5.7 prikazan je FFT kola kada je pojačanje prvog operacionog pojačavača smanjeno sa  $10^5$  na 100. Malo DC pojačanje može da uzrokuje curenje integratora na niskim frekvencijama. Uticaj ove promene nije mnogo vidljiv. Promena u spektru, iako je promena pojačanja znatna, je previše mala da bi bila korisna za dijagnostiku.

Promena vrednosti kapacitivnosti može takođe da utiče na izlaz kola. Na Slici 5.8 prikazan je FFT kola kada je vrednost kapacitivnosti u prvom stepenu promenjena, jer smo već naglasili da promene u drugom stepenu nemaju mnogo uticaja. Smanjenje kapacitivnosti povećava izlazni napon integratora, tako da dolazi do zasićenja, što dalje uzrokuje smanjenje SNDR-a.



**Slika 5.7. FFT izlaza kola kada je pojačanje prvog operacionog pojačavača smanjeno na 100**




**Slika 5.8. FFT izlaza kola kada je vrednost C smanjena 60%**

### 5.3 Dijagnostika defekata u digitalnom delu sigma-delta modulatora korišćenjem vremenskog odziva kola

Spektri izlaznog signala pokazani u prethodnim primerima [78] analizirani su da bi se iz dobijenih rezultata ekstrahovali podaci neophodni za obučavanje dijagnostičke neuronske mreže. Naime, cilj je bio da neki parametri spektra ispravnog kola i kola sa

defektom, kao npr. visina nosioca, nivo šuma, i sl. budu ulazi u neuronsku mrežu, a da izlaz neuronske mreže, kao i u prethodnim slučajevima, bude kod defekta. Da bi takva dijagnostička neuronska mreža radila dobro, odnosno ispravno razlikovala defekte, njeni ulazi treba da budu definisani i dovoljno različiti. Iz pokazanih primera se vidi da su spektri izlaza kola sa katastrofalnim defektima veoma različiti, ali u nekim slučajevima gube svoje osnovne karakteristike, kao na primer, spektar na Slici 5.4, tako da nije moguće dobiti potrebne ulazne parametre. S druge strane, efekte mekih defekata skoro da je nemoguće primetiti u spektru. Iz svih ovih razloga, zaključili smo da nema smisla koristiti ove podatke za obučavanje neuronske mreže, pa je kolo analizirano u vremenskom domenu da bi se dobili neki korisniji rezultati.

Analizom kola u vremenskom domenu biće obuhvaćeni samo efekti defekata u digitalnom delu kola [79]. Kao što smo rekli, digitalni signal može biti ili u stanju permanentne jedinice, ili u stanju permanentne nule, i kao u prethodnom primeru, te defekte ćemo modelovati prekidačima koji su stalno otvoreni, odnosno stalno zatvoreni. Na ulaz kola se sada dovodi linearno rastući signal (rampa). Odziv kola na linearno rastuću pobudu prikazan je na Slici 5.9.



**Slika 5.9. Odziv kola na linearno rastuću pobudu**

U pristupu koji je ovde prikazan, povorku izlaznih impulsa (nula ili jedinica) dobijamo registrovanjem vrednosti signala nakon svake periode takta, a ne nakon svake promene vrednosti izlaza (tj. nakon svakog događaja), kao što je to uobičajeno. Ove digitalne izlazne vrednosti formiraju izlaznu signaturu. Pošto se te signature sastoje od velikog broja bitova, prikazane su u kompaktnijoj heksadecimalnoj prezentaciji. Na osnovu toga je formiran rečnik defekata prikazan u Tabeli 5.1. U prvoj koloni Tabele 5.1, nabrojano je osam izabranih defekata. FF označava kolo bez defekata. Kao i u primeru sa Furijeovom transformacijom, slučajevi kada su prekidači u povratnoj petlji ( $\phi_{11}$ ,  $\phi_{12}$ ,  $\phi_{21}$ ,  $\phi_{22}$ ) stalno zatvoreni nisu uzeti u obzir, jer bi tada izvori napajanja  $V_{refp}$  i  $V_{refn}$  bili kratkospojeni. U drugoj koloni Tabele su signature koje se vide na izlazu. Signatura se kodira kao što je prikazano u trećoj koloni. U procesu kodiranja uzeto je u obzir da slični odzivi ne smeju da imaju kodove bliske po vrednosti (na primer odziv 99999 i AAAAA (heksadecimalna vrednost A predstavlja se neuronskoj mreži kao decimalna vrednost 10)).




Tabela 5.1 Rečnik defekata

| Tip defekta         | Signatura | Kod defekta |
|---------------------|-----------|-------------|
| FF                  | C9CA9     | 0           |
| sw <sub>1</sub> OFF | 99999     | 1           |
| φ <sub>12</sub> OFF | 38E38     | 2           |
| φ <sub>21</sub> OFF | 00000     | 3           |
| φ <sub>22</sub> OFF | FFFFF     | 4           |
| sw <sub>1</sub> ON  | 63655     | 5           |
| φ <sub>11</sub> OFF | 1F07C     | 6           |
| sw <sub>2</sub> ON  | E0F83     | 7           |
| sw <sub>2</sub> OFF | AAAA<br>A | 8           |

Veštačka neuronska mreža se zapravo obučava za modelovanje *look-up* tabele. To je *feed-forward* neuronska mreža sa samo jednim skrivenim slojem. Signature su ulazi u mrežu, a kod defekta je izlaz koji mreža treba da nauči. To znači da neuronska mreža ima pet ulaznih (po jedan za svaku heksadecimalnu cifru) i jedan izlazni neuron. Heksadecimalne vrednosti se predstavljaju kao decimalne. Nakon obučavanja neuronske mreže, broj skrivenih neurona je bio tri [6], [71]. Struktura dobijene mreže prikazana je na Slici 5.10, a njeni parametri u Tabeli 5.3.

Struktura i parametri dobijene VNM verifikovani su tako što je VNM pobuđena ulazima koji se odnose na kola sa defektima. Odzivi mreže pokazuju da nije bilo greške u identifikovanju defekata, što je predstavljano u Tabeli 5.2. Mogu se primetiti zanemarljiva neslaganja (manje od 0.5%).



**Slika 5.10. Struktura VNM koja se koristi za dijagnostiku digitalnih defekata u kolu sa Slike 5.1**

Tabela 5.2. Izlazni kodovi VNM

| Tip defekta         | Kod defekta | Izlaz VNM  |
|---------------------|-------------|------------|
| FF                  | 0           | 0.00754392 |
| sw <sub>1</sub> OFF | 1           | 1.00436    |
| φ <sub>12</sub> OFF | 2           | 2          |
| φ <sub>21</sub> OFF | 3           | 2.99988    |
| φ <sub>22</sub> OFF | 4           | 4.00265    |
| sw <sub>1</sub> ON  | 5           | 5.00078    |
| φ <sub>11</sub> OFF | 6           | 5.9999     |
| sw <sub>2</sub> ON  | 7           | 7.0013     |
| sw <sub>2</sub> OFF | 8           | 8.00416    |

Tabela 5.3. Parametri veštačke neuronske mreže

| Težina         | Vrednost |
|----------------|----------|
| w (1,1)(2,1)   | 120.812  |
| w (1,2)(2,1)   | -71.5911 |
| w (1,3)(2,1)   | -170.517 |
| w (1,4)(2,1)   | 145.099  |
| w (1,5)(2,1)   | 10.6883  |
| w (1,1)(2,2)   | 104.461  |
| w (1,2)(2,2)   | -85.9051 |
| w (1,3)(2,2)   | -181.814 |
| w (1,4)(2,2)   | 142.592  |
| w (1,5)(2,2)   | 5.02798  |
| w (1,1)(2,3)   | 118.426  |
| w (1,2)(2,3)   | -80.095  |
| w (1,3)(2,3)   | -166.541 |
| w (1,4)(2,3)   | 139.481  |
| w(1,5)(2,3)    | -8.45216 |
| w (2,1)(3,1)   | 14.4496  |
| w (2,2)(3,1)   | 10.0822  |
| w (2,3)(3,1)   | -14.6015 |
|                |          |
| Prag           | Vrednost |
| $\theta$ (2,1) | -18.3932 |
| $\theta$ (2,2) | 5.31276  |
| $\theta$ (2,3) | 0.747092 |
| $\theta$ (3,1) | 0.25     |

Dijagnostika je bila uspešna. Iako su dijagnosticirani samo katastrofalni defekti u ovom primeru, jednostavno je analizirati i parametarske. U skladu sa tim, još jednom zaključujemo da su VNM pogodno i moćno sredstvo za dijagnostiku, i što je najvažnije, moguće ih je hardverski realizovati.

## 6 Modelovanje i simulacija defekata u mikro-elektro-mehaničkom sistemu

Napredak u tehnologiji poluprovodnika i ekonomski razvoj koji je za to vezan, upućuju na brzo pojavljivanje i značajne potencijale nove silicijumske infrastrukture, ili na novo tržište koje podrazumeva projektovanje za proizvodnju (*design-for-manufacturability market-DFM*).

DFM tržište obuhvata implementaciju dizajna, sintezu maski, i napredne tehnike litografije. U toku 2003 godine, analitičari su projektovali povećanje tržišta za 64% [80].

Neki od poslednjih ciljeva DFM-a su isključivanje projektanta iz detalja procesa, tako da industrija saraduje sa sve manje DFM platformi. Idealna DFM platforma trebalo bi da obuhvata sve podatke, uključujući projektovanje, litografiju, proizvodnju, ali projektantski sistem koji povezuje sve ove faze i dalje je daleko od realnosti.

Kada je model sistema dostupan, i kada su poznate njegove karakteristike, automatizacija projektovanja bi dozvolila projektantu da ekstrahuje, analizira, simulira, i optimizuje kolo pre nego ono ode u proizvodnju. Ovo obezbeđuje uverenje da dizajn funkcioniše kako je projektovan.

Ovaj potpuniji model zahteva novu infrastrukturu koja podržava povratnu spregu između projektanta i proizvođača. Ova povratna sprega uključuje sredstva koja definišu i prenose ograničenja proizvodnje, verifikuju leaute integrisanih kola, i prikazuju projektantu izveštaje koji se tiču proizvodnje.

Simulacija i sinteza testnog signala su, po našem mišljenju, ključni pojmovi u razvoju ovakvog modela. Ideje koje se odnose na ovaj koncept prikazane su u daljem tekstu.

Pošto ciklus razvoja proizvoda u tehnologiji mikrosistema, tj. u tehnologiji Mikro-Elektro-Mehaničkih Sistema (MEMS), retko traje manje od 5 godina, projektovanje za

proizvodnju je od najvećeg značaja. Nedovoljni alati za automatizaciju projektovanja postaju ograničavajući faktor za nove primene MEMS-a. U poređenju sa digitalnim, analognim i čak i proizvodima sa mešovitim signalima, loši alati mogu da uspore ciklus razvoja proizvoda i za nekoliko redova veličine. Ova kašnjenja uglavnom nastaju zbog velikog broja koraka “pokušaj-greška” koji su, između ostalog, nastali zbog nedovoljno razvijenih alata za simulaciju i neodgovarajućih metodologija modelovanja.

Ovaj problem postaje još drastičniji kada se razmatraju testiranje i dijagnostika. Potrebne su ponovljene analize ne samo da bi se dizajn verifikovao i optimizovao, već i da se verifikuje pokrivenost defekata i kreiranje rečnika defekata. Ne bi trebalo zaboraviti da govorimo o sistemima na čipu koji obuhvataju analognu i digitalnu elektroniku i različite (uglavnom mehaničke) komponente opisane specifičnim modelima (najčešće parcijalnim diferencijalnim jednačinama). Neuporedivo veći broj defekata se očekuje u električnom delu, što znači da treba očekivati ogroman broj simulacija. Nemoguće je dopustiti simulaciju mehaničkih delova na najnižem nivou. Potrebni su nam MEMS modeli na višem nivou da bismo izbegli rešavanje sistema parcijalnih jednačina.


U narednom tekstu ćemo kroz primer objasniti standardni pristup MEMS simulaciji. Zatim ćemo predstaviti modelovanje crne kutije upotrebom veštačkih neuronskih mreža i primeniti ga na kondenzator čija kapacitivnost je nelinearna funkcija pritiska [81]. Ovaj model je onda implementiran u funkcionalni sistem i simulator kola da bi se pokazala efikasnost ideje.

## 6.1 Simulacija mikro-elektro-mehaničkog sistema

Razmotrimo problem simulacije jednostavnog kola sa Slike 6.1. Ovo je mikro-elektro-mehanički sistem sa kapacitivnošću osetljivom na pritisak. Sastoji se od elektro-mehaničkog dela koji je kondenzator sa membranom koja se pomera tako da promena pritiska rezultuje promenom kapacitivnosti, i elektronskog SC kola koje generiše povorku impulsa fiksne frekvencije. Amplituda impulsa na izlazu zavisi od vrednosti kapacitivnosti, tako da zapravo ceo sistem konvertuje pritisak u amplitudu impulsa.

Za simulaciju ovog i drugih sličnih sistema implementirali smo “Alecsis- simulator kola i sistema” [82], [83], [84], [85], [86], [74], [87]. To je simulator mešovityh signala (analognih i diskretnih), mešovityh nivoa (sistemski nivo i analogni i digitalni, električni nivo, nivo digitalnih gejtova i mehanički grid nivo), i mešovityh opisa. Razvijena je i biblioteka ugrađenih modela.

Zatim, razvijen je i jezik za opis hardvera pod imenom AleC++, kao nadskup C++ da bi opis modela bio izvodljiv [88], [89], [90].



**Slika 6.1. Mikro-elektro-mehanički sistem sa kapacitivnošću osetljivom na pritisak**

Parcijalna diferencijalna jednačina za senzorsku membranu je:

$$D\left(\frac{\partial^4 w}{\partial x^4} + 2\frac{\partial^4 w}{\partial x^2 \partial y^2} + \frac{\partial^4 w}{\partial y^4}\right) = p + \rho h \frac{\partial^2 w}{\partial t^2} + k \frac{\partial w}{\partial t} \quad (6.1)$$

gde su  $x$  i  $y$  prostorne koordinate,  $p$  je efektivni pritisak,  $w$  je pomeraj membrane,  $\rho$  je gustina materijala,  $h$  je debljina membrane,  $k$  je koeficijent slabljenja i  $D$  je koeficijent krutosti. Jednačina (6.1) je primenljiva samo na izotropne materijale. Takođe, ne može se rešiti u zatvorenom obliku, neophodno je numeričko rešenje.

Ako je membrana pravougaonog oblika fiksirana u uglovima, granični uslovi su:


$$\begin{aligned} w(x=0 \wedge x=L) &= 0, & \frac{dw}{dx}(x=0 \wedge x=L) &= 0 \\ w(y=0 \wedge y=W) &= 0, & \frac{dw}{dy}(y=0 \wedge y=W) &= 0 \end{aligned} \quad (6.2)$$

$L$  i  $W$  su dužina i širina membrane, respektivno. Granični uslovi mogu da se promene ukoliko je fiksiranje ivice membrane od značaja i mora da bude modelovano.

Za modelovanje kapacitivnosti, koristi se aproksimacija paralelnih ravni. Kapacitivnost u Alecsisu modelovana je sledećim izrazom:

$$C = \varepsilon \int_{x=0}^L \int_{y=0}^W \frac{dx dy}{l - w(x,y)} \quad (6.3)$$

gde je  $C$  kapacitivnost,  $\varepsilon$  je dielektrična konstanta dielektričnog materijala kondenzatora, i  $l$  je rastojanje između uzemljene ploče i neopterećene membrane.



**Slika 6.2. Pomeraj senzorske membrane kada je korak simulacije 0.0004s**

Veza između mehanike i elektronike modeluje se u skladu sa jednačinom:

$$i = \frac{dQ}{dt} = C \frac{dv}{dt} + v \frac{dC}{dt} \quad (6.4)$$


gde je  $Q$  ukupno naelektrisanje na kondenzatoru,  $i$  je električna struja kroz kontakte kondenzatora,  $v$  je napon na kondenzatoru.

Na osnovu ovih jednačina, obavlja se simulacija u Alecsisu, i dobija se zavisnost kapacitivnosti od pritiska, prikazana na Slici 6.3. Na Slici 6.2 pokazani su još neki rezultati simulacija sistema sa Slike 6.1. Mehanički i električni deo su modelovani u okviru istog opisa i simulacija istovremeno računa sve promenljive sistema (u ovom slučaju to su pomeraji, naponi, struje i stanja).

Koncept predložen u ovoj simulaciji je više puta korišćen [91], [92], [93], [94], [95], [96]. U nekim slučajevima taj pristup je usvojen kao osnova za dalja istraživanja [97].

U toku života proizvoda, testiranje se obavlja i u fazi proizvodnje i u fazi implementacije. Ovde se, međutim, tvrdi, da održivost proizvoda u velikoj meri zavisi od faze projektovanja. Tako, da bi proizvod bio održiv, treba projektovati testnu proceduru i sintetizovati testne signale u ranoj fazi projektovanja.

Često je moguće izvesti funkcionalnu verifikaciju sistema. To se najčešće dešava kada postoji mali broj ulaznih/izlaznih priključaka. U većini slučajeva međutim, sveobuhvatno funkcionalno testiranje zahteva puno vremena i neprihvatljivo je. Zbog toga mi koristimo strukturalno testiranje, usmereno ka defektu.



**Slika 6.3. Rezultati vremenske simulacije sistema sa Slike 6.1.**  
**Prikazani signali su pritisak, pomeraj senzora pritiska,**  
**kapacitivnost senzora i izlazni napon**

Smatramo da testiranje obuhvata: izbor skupa defekata koji se smatraju najverovatnijim; opis skupa merenja; izbor skupa testnih tačaka (ili izlaznih signala); i što je najvažnije, sintezu optimalnih testnih signala koji se vode na ulaze sistema radi detekcije i observabilnosti efekata defekata. Ovde “optimalno” znači da pokriva što je moguće više defekata.

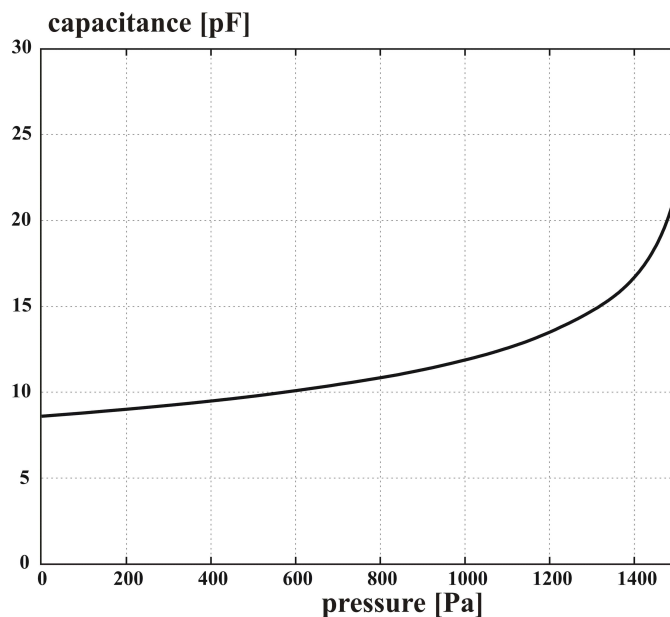
Kada se izaberu testni signali, pažnju treba usmeriti na pokrivanje što većeg broja defekata. Da bi se obezbedio što veći broj defekata, treba formirati onoliko verzija originalnog kola koliko želimo defekata da uključimo. U slučaju složenih sistema koji sadrže mehaničke, analogne i digitalne delove, broj verzija postaje veliki. Svaka verzija ima po jedan ubačeni defekt. Pokrivenost defekata procenjuje se nakon simulacije sistema sa defektom poređenjem tako dobijenih rezultata sa odzivom ispravnog sistema. Ako se ova dva odziva razlikuju, defekt je pokriven.

## 6.2 Modelovanje MEMS-a crnom kutijom

Kao što je već pomenuto, simulacija sistema koji se razmatra zahteva određeno vreme, i to je problem za sebe. Postavlja se pitanje da li treba da ponavljamo simulacije na nivou parcijalnih diferencijalnih jednačina, koje zahtevaju najviše vremena, kada se defekt pojavljuje u analognom ili digitalnom delu sistema.

Ovo bi se izbeglo modelovanjem pomoću crne kutije neelektričnih delova (mehaničkih, optičkih, elektromagnetnih itd.), tako što bi se sakupile njihove karakteristike i na taj način omogućila radikalno brža simulacija. Mi dobijamo podatke o ponašanju crne kutije upotrebom veštačkih neuronskih mreža. Kao što je već pokazano [98], [99], [100], [101], [102], [103], [104], [105], ovaj pristup je uspešno korišćen u modelovanju nelinearnih dinamičkih elektronskih sistema.

U sledećem tekstu pokazaćemo kako se sistem sa Slike 6.1 može pojednostaviti zamenom membrane (nelinearne u odnosu na pritisak) kondenzatorom sa raspedeljenim parametrima koji se modeluje korišćenjem VNM. Biće ubačeni defekti i biće pokazana simulacija ispravnog kola i kola sa defektima.




**Slika 6.4. Kapacitivnost membrane sa Slike 6.1 prikazana u funkciji pritiska**

### 6.2.1 Modelovanje kapacitivnosti neuronskom mrežom

Na početku je formirana VNM koja modeluje model sa raspodeljenim parametrima kapacitivnog pojačavača. Veštačke neuronske mreže se ovde posmatraju kao univerzalni aproksimatori [19], što je pogodno za modelovanje crne kutije. Postupak počinje ekstrakcijom zavisnosti  $C(p)$  iz “Aleccis” simulacije sistema sa Slike 6.1. Ovde  $C$  označava kapacitivnost, dok je  $p$  pritisak. Za ekstrakciju je korišćen treći grafik sa Slike 6.3, i dobijeni rezultati prikazani su na Slici 6.4.

Struktura korišćene VNM prikazana je na Slici 6.5. To je jednostavna *feed-forward* VNM sa samo jednim skrivenim slojem. Skriveni neuroni imaju sigmoidne aktivacione funkcije, a izlazni linearne. Tabela 6.1 sadrži težine i pragove neuronske mreže dobijene nakon obučavanja mreže standardnim algoritmom, [67].



**Slika 6.5. VNM struktura koja se koristi za aproksimaciju krive sa Slike 6. 4. ( $w$  označava težinu, a  $\theta$  prag)**



Tabela 6.1 Težine i pragovi VNM koja se koristi za aproksimaciju krive sa Slike 6.4

| Skriveni neuroni         | Izlazni neuroni          |
|--------------------------|--------------------------|
| $w(1,1)(2,1) = 33.1034$  | $w(2,1)(3,1) = 2.32691$  |
| $w(1,1)(2,2) = 3.92046$  | $w(2,2)(3,1) = 17.8609$  |
| $w(1,1)(2,3) = 4.04654$  | $w(2,3)(3,1) = -15.9505$ |
| $\theta(2,1) = -35.6658$ | $\theta(3,1) = 0.354662$ |
| $\theta(2,2) = -3.88227$ |                          |
| $\theta(2,3) = -3.88324$ |                          |

Jednačina kondenzatora

$$i_c = C(p) \frac{dv_c}{dt} \quad (6.5)$$

primenjena je u skladu sa [84]. Jednačina se najpre diskretizuje:

$$i_c^{n+1} = C(p^{n+1}) \cdot (A \cdot v_c^{n+1} + B_v^n) \quad (6.6)$$

gde su A i B konstante dobijene iz diskretizacionog pravila.  $n$  označava brojač iteracija.

Nakon diskretizacije, primenjuje se Njutnov metod linearizacije:

$$i_c^{n+1,m+1} = i_c^{n+1,m} + G_v^{n+1,m} \cdot (v_c^{n+1,m+1} - v_c^{n+1,m}) + G_p^{n+1,m} (p^{n+1,m+1} - p^{n+1,m}) \quad (6.7)$$

gde je

$$i_c(p^{n+1,m}) = i_c^{n+1,m} = C(p^{n+1,m}) \cdot (A \cdot v_c^{n+1,m} + B_v^n) \quad (6.8)$$


$$G_v^{n+1,m} = \left. \frac{\partial i_c}{\partial v_c} \right|_{v_c = v_c^{n+1,m}} = A \cdot C(p^{n+1,m}) \quad (6.9)$$

i


$$G_p^{n+1,m} = \left. \frac{\partial i_c}{\partial p} \right|_{p = p^{n+1,m}} = (A \cdot v_c^{n+1} + B_v^n) \cdot \left. \frac{\partial C(p)}{\partial p} \right|_{p = p^{n+1,m}} \quad (6.10)$$

## 6.2.2 Simulacija sistema sa VNM

Diskretizovan i linearizovan model nelinearnog kondenzatora predstavljen jednačinom (6.7) može se prikazati električnom šemom, kako je pokazano na Slici 6.6 [106]. Da bismo primenili ovaj model moramo da računamo odziv VNM koji je zapravo  $C(p)$ , i njegove izvode u odnosu na  $p$ .




**Slika 6.6. Diskretizovan i linearizovan model kondenzatora kontrolisanog pritiskom**



**Slika 6.7. Ulazni signal za simulaciju**

Slika 6.7 pokazuje ulazni signal (pritisak) u pojačavač koji se koristi za simulacije pri modelovanju crne kutije (signal je ponovljen sa Slike 6.3). Sada se izvodi nova simulacija za ispravno kolo (kolo sa Slike 6.1), s razlikom što je membrana zamenjena modelom kondenzatora sa raspodeljenim parametrima opisanim veštačkom neuronskom mrežom. Rezultati simulacije su pokazani na Slici 6.8, i kao što se vidi, odlično se slažu sa onima koji su dobijeni ranije i prikazani na četvrtom grafiku Slike 6.3.



**Slika 6.8. Rezultati simulacije kola sa Slike 6.1 sa membranom zamenjenom modelom kondenzatora sa raspodeljenim parametrima**

Koja je razlika između ova dva odziva? Da bismo dobili rezultat sa Slike 6.8 moramo da simuliramo kolo opisano sa samo 5 promenljivih, u poređenju sa mnogo više promenljivih da bismo opisali originalno kolo. Ovo omogućava dostupnu, jeftinu ponovnu simulaciju sistema sa ubačenim defektima.

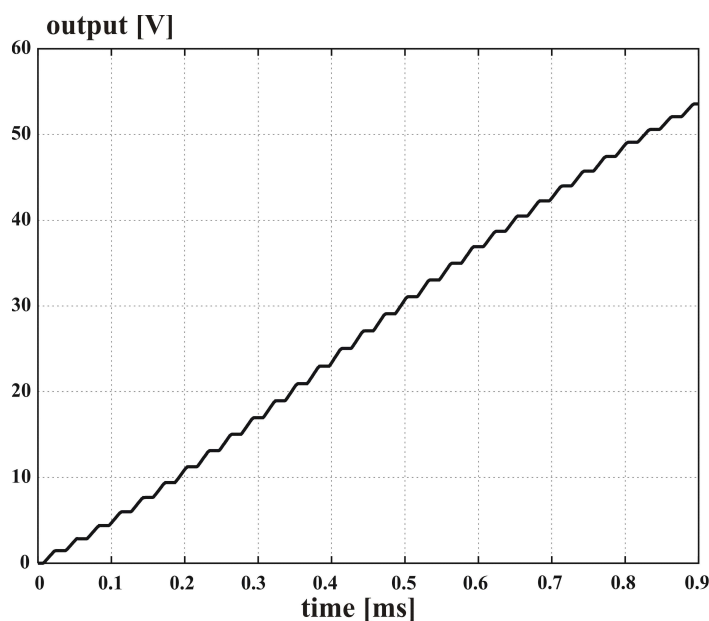
### 6.3 Testiranje i dijagnostika kola sa VNM

U daljem tekstu biće razmatrana simulacija radi testiranja i dijagnostike [107], [108].


Radi jednostavnosti pokazivanja metoda, izabrano je samo pet defekata za koje postoji verovatnoća da se pojave u kolu:

1.  $S_I-On$ : Prekidač u povratnoj petlji operacionog pojačavača je stalno zatvoren
2.  $C_r+$ : Vrednost kondenzatora u povratnoj petlji operacionog pojačavača je promenjena +20%
3.  $S_I-Off$ : Prekidač u povratnoj petlji operacionog pojačavača je stalno otvoren
4.  $C_r-$ : Vrednost kondenzatora u povratnoj petlji operacionog pojačavača je promenjena -20%
5.  $C_s-flat$ : Membrana je “*stuck-at-flat*” (iz nekog razloga membrana ne prati promene pritiska i kapacitivnost ima konstantnu vrednost).

Rezultati simulacije za situaciju kada su treći i peti defekt ubačeni u kolo prikazani su na Slikama 6.9 i 6.10, respektivno.




**Slika 6.9. Odziv neispravnog kola kada je prekidač u povratnoj petlji operacionog pojačavača stalno otvoren**



**Slika 6.10. Odziv neispravnog kola kada je membrana "stuck-at-flat"**

Kao specifičan primer simulacije, na Slici 6.11 je prikazan odziv neispravnog kola kada su istovremeno prisutna dva defekta:  $C_r+$  i  $S_l-Off$ . Ovaj primer je dat samo u cilju da se pokaže da simulacija nije skupa i da svaka ideja projektanta može lako biti verifikovana.

Možemo primetiti da je ubacivanje modela defekta u električni deo kola (i analogni i digitalni) jednostavno i lako za implementaciju [87], [91], ali da je potrebno još dosta rada vezanog za neelektrične strukture, čiji je membrana najjednostavniji primer.



**Slika 6.11. Odziv kola u prisustvu dva defekta:  $C_r+$  i  $S_l-Off$**

Implementacija predloženog sistema, međutim, omogućava brzo kreiranje liste pokrivenosti defekata za veliki skup testnih signala, i istovremeno, kreiranje složenih rečnika defekata koji su neophodni radi dijagnostike.

Tabela 6.2 sadrži podatke koji sačinjavaju rečnik defekata za model sa jednostrukim defektom. Nakon opisa defekta, u drugoj koloni je prikazan kod defekta. Dijagnosticira se pet defekata. Shodno tome, rečnik defekata ima šest vrsta numerisanih od 0 do 5, jer nulta vrsta označava sistem bez defekata (FF). Poslednja kolona u Tabeli 6.2 prikazuje odziv sistema, pri čemu je računat jednosmerni napon na izlazu,  $V_{oDC}$  za kolo bez defekata i za kolo sa defektom. Pošto su jednosmerne vrednosti napona vrlo bliske, što se može videti u Tabeli 6.2, računate su efektivne vrednosti napona, i prikazane u Tabeli 6.3. Iz Tabele 6.3 se vidi da je opseg vrednosti ipak veći, što olakšava obučavanje neuronske mreže.

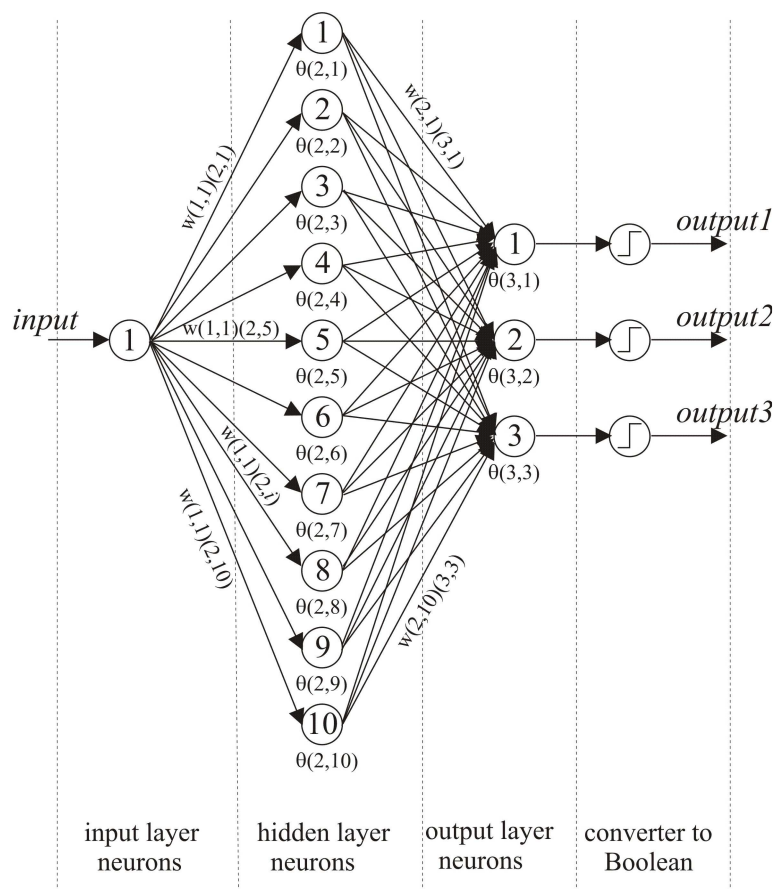
Tabela 6.2  
Rečnik defekata za jednosmerni napon na izlazu

| Skriveni neuroni  | Izlazni neuroni           | Izlazni neuroni          |
|---|---------------------------|--------------------------|
| $w(1,1)(2,1) = 12.4799$                                 | $w(2,1)(3,1) = 19.5394$   | $w(2,1)(3,3) = -22.0716$ |
| $w(1,1)(2,2) = -15.0718$                                | $w(2,2)(3,1) = -12.5252$  | $w(2,2)(3,3) = 10.2405$  |
| $w(1,1)(2,3) = 11.8711$                                 | $w(2,3)(3,1) = -32.8497$  | $w(2,3)(3,3) = 5.63089$  |
| $w(1,1)(2,4) = -29.4443$                                | $w(2,4)(3,1) = -138.649$  | $w(2,4)(3,3) = -79.3972$ |
| $w(1,1)(2,5) = -16.7436$                                | $w(2,5)(3,1) = 123.841$   | $w(2,5)(3,3) = -24.5848$ |
| $w(1,1)(2,6) = 6.74961$                                 | $w(2,6)(3,1) = -10.697$   | $w(2,6)(3,3) = 47.3628$  |
| $w(1,1)(2,7) = -8.57606$                                | $w(2,7)(3,1) = 24.3227$   | $w(2,7)(3,3) = 54.7337$  |
| $w(1,1)(2,8) = -15.0182$                                | $w(2,8)(3,1) = -147.391$  | $w(2,8)(3,3) = 36.1544$  |
| $w(1,1)(2,9) = 8.8202$                                  | $w(2,9)(3,1) = -32.3196$  | $w(2,9)(3,3) = 29.0514$  |
| $w(1,1)(2,10) = 3.31237$                                | $w(2,10)(3,1) = -59.4686$ | $w(2,10)(3,3) = 27.5506$ |
| Rečnik defekata za efektivne vrednosti napona na izlazu |                           |                          |
| (2,1) = 59.707  | $w(2,1)(3,2) = 67.4601$   | (3,1) = -4.73863         |
| (2,2) = 14.5716   | $w(2,2)(3,2) = -62.865$   | (3,2) = 82.086           |
| (2,3) = -10.5942  | $w(2,3)(3,2) = -131.908$  | (3,3) = -52.2716         |
| (2,4) = 15.4416   | $w(2,4)(3,2) = 57.3764$   |                          |
| (2,5) = 13.8512   | $w(2,5)(3,2) = -282.713$  |                          |
| (2,6) = -8.06869  | $w(2,6)(3,2) = 77.912$    |                          |
| (2,7) = 21.1432   | $w(2,7)(3,2) = -41.986$   |                          |
| (2,8) = 12.4734   | $w(2,8)(3,2) = -243.29$   |                          |
| (2,9) = -16.8585  | $w(2,9)(3,2) = 61.0503$   |                          |
| (2,10) = -13.2239                                       | $w(2,10)(3,2) = -43.1172$ |                          |

Kod defekta je prikazan binarno, tako da su na izlazima neuronske mreže samo jedinice i nule. Pošto ima samo 5 defekata, za kodiranje su dovoljna 3 bita. Parametri obučene neuronske mreže dati su u Tabeli 6.4. Parametri obučene neuronske mreže dati su u Tabeli 6.4, a njena struktura prikazana je na Slici 6.12.

Parametri i struktura obučene VNM provereni su pobuđivanjem mreže istom pobudom koja je korišćena pri obučavanju. Odzivi VNM na pobudu bez šuma su pokazani u Tabeli 6.5, i vidi se da greška ne postoji.

Sposobnost generalizacije mreže prikazana je u Tabeli 6.6, gde je mreža pobuđivana pobudom kojoj je dodavan određeni šum. Rezultati pokazuju da ponovo greška ne postoji.



**Slika 6.12. Struktura VNM za dijagnostiku defekata u kolu sa Slike 6.1**

Tabela 6.5 Odzivi VNM na pobudu bez šuma

| Tip defekta | Kod | $V_{SR}$ [V] | Izlaz VNM    |              |            |
|-------------|-----|--------------|--------------|--------------|------------|
| FF          | 000 | 2.829738     | -1.57174e-05 | -0.00362631  | -0.0155174 |
|             |     |              | 0            | 0            | 0          |
| $S_1$ ON    | 001 | 2            | 0.000521721  | -0.000524629 | 0.99966    |
|             |     |              | 0            | 0            | 1          |
| Cr+         | 010 | 2.691447     | -0.0125319   | 0.9913191    | 0.487591   |
|             |     |              | 0            | 1            | 0          |
| $S_1$ OFF   | 011 | 26.8489      | 0.0131203    | 1.00295      | 0.513954   |
|             |     |              | 0            | 1            | 1          |
| Cr-         | 100 | 3.037174     | 0.999802     | -0.00304068  | 0.00156264 |
|             |     |              | 1            | 0            | 0          |
| Cs          | 101 | 2.555527     | 0.999702     | -0.00284052  | 1.01253    |
|             |     |              | 1            | 0            | 1          |

Kako bi se smanjilo vreme koje je potrebno da proizvod dospe na tržište i povećala pouzdanost MEMS-a, potrebni su alati za modelovanje, simulaciju i dijagnostiku čitavog sistema. Do sada je to bilo moguće samo modelovanjem mehaničkih delova na nivou parcijalnih diferencijalnih jednačina, što je dovodilo do preterano dugih simulacija i činilo simulaciju defekata praktično nemogućom.

Tabela 6.6 Odzivi VNM na pobudu sa šumom

| Tip defekta | Kod | $V_{SR}$ [V] | Izlaz VNM |           |           |
|-------------|-----|--------------|-----------|-----------|-----------|
| FF          | 000 | 2.886        | 0.229347  | -0.396346 | -0.143539 |
|             |     | +3%          | 0         | 0         | 0         |
| $S_1ON$     | 001 | 2.02         | 0.394233  | -0.404712 | 1.18239   |
|             |     | +1%          | 0         | 0         | 1         |
| Cr+         | 010 | 2.758        | -0.129275 | 0.624862  | 0.226112  |
|             |     | +2.5%        | 0         | 1         | 0         |
| $S_1OFF$    | 011 | 26.2241      | 0.384996  | 0.817382  | 0.762281  |
|             |     | +1%          | 0         | 1         | 1         |
| Cr-         | 100 | 3.18         | 0.998     | 0.0004068 | 0.01562   |
|             |     | +5%          | 1         | 0         | 0         |
| Cs          | 101 | 2.5          | 1.60018   | -1.05702  | 1.20387   |
|             |     | -2.5%        | 1         | 0         | 1         |

Ovde smo pokazali da je moguće precizno modelovanje mikro-mehaničkih delova sistema crnom kutijom, i, što je najznačajnije, ovi modeli mogu biti efikasno opisani korišćenjem VNM.

Takav pristup omogućava brzu simulaciju i simulaciju defekata i dopušta dalji razvoj integrisanih alata za projektovanje za čitav mikro-elektro-mehanički sistem.

## 7 Zaključak

Dijagnostika elektronskih kola i veštačke neuronske mreže su dve oblasti koje su, same za sebe, vrlo zahvalne za istraživanje jer postoje njihove brojne nove primene, koje po pravilu daju odlične rezultate.

U ovoj disertaciji pokušali smo da spojimo ove dve oblasti, i da ih kao takve primenimo na dijagnostiku defekata u različitim elektronskim kolima. Ova kombinacija se pokazala kao inspirativna, ali uzevši u obzir i brojnu literaturu, i kao vrlo originalna. Mali broj autora je istraživao u tom pravcu, a svi dobijeni rezultati se odnose na vrlo jednostavna, uglavnom linearna kola. Mi smo pokušali da taj pristup uopštimo, trudeći se da ga primenimo na “najnezahvalnije” primere. Pristup se pokazao kao dobar, a svaki od primera opisan je u jednom od poglavlja.

Umesto da dajemo pregled sadržaja svakog poglavlja, kao što je to urađeno u Uvodu, u Zaključku ćemo ukratko opisati dalji tok istraživanja u ovoj oblasti.

Na prvom primeru, prikazanom u trećem poglavlju disertacije, dat je sam koncept dijagnostike koji se zasniva na upotrebi veštačke neuronske mreže, zatim način formiranja rečnika defekata, određivanje strukture neuronske mreže za dati dijagnostički problem, pokazivanje svojstva generalizacije neuronske mreže, itd. To je zapravo i prvi primer na ovu temu, koji je bio koristan jer je na njemu razrađen metod, ali je prilično jednostavan jer se odnosi na otporno kolo u kome su razmatrani samo katastrofalni defekti, pa kao takav, nije interesantan za dalja istraživanja.

Sledeći primer, opisan u četvrtom poglavlju disertacije, odnosi se na dijagnostiku defekata u analognom nelinearnom dinamičkom kolu. U konkretnom slučaju, to je operacioni pojačavač koji se sastoji od sedam tranzistora, i razmatraju se kako parametarski, tako i katastrofalni defekti, i dijagnosticiraju se istom neuronskom mrežom. U okviru primera se uvodi pojam tzv. *ambiguity* grupa, tj. grupa ekvivalentnih ili vrlo sličnih defekata. U daljem radu nameravamo da rešimo elemente *ambiguity* grupa, odnosno da pronađemo odgovarajuće pobudne signale, tako da efekti tih, do sada istih defekata, budu različiti. Sledeći cilj je i posmatranje složenijih sistema i generisanje većih rečnika defekata. Ovo iziskuje dodatna merenja (simulacije) jer je veoma važno zadržati mali broj testnih tačaka.

U petom poglavlju koncept je proširen i na hibridno kolo. Izabran je primer sigma-delta modulatora, kola koje je veoma tolerantno na promene parametara u kolu, tako da je efekte defekata teže prepoznati, što predstavlja dodatni izazov. Korisne informacije za dijagnostiku smo najpre pokušali da ekstrahujemo iz spektra snage izlaznog signala. Ispitali smo efekte i parametarskih i katastrofalnih defekata, ali ovaj pristup se nije pokazao kao mnogo zahvalan, jer se neki efekti jedva i primećuju u spektru izlaznog signala. U drugom pokušaju smo informaciju potrebnu za dijagnostiku dobijali iz vremenskog odziva kola, što se pokazalo kao uspešno i efikasno, ali smo dijagnosticirali samo defekte u digitalnom delu kola. U budućem radu uzećemo u obzir



i defekte iz analognog dela kola. Rečnik defekata u digitalnom delu kola proširićemo defektima kašnjenja signala kroz logičke gejtove.

Kako bi se smanjilo vreme koje je potrebno da proizvod dospe na tržište i povećala pouzdanost MEMS-a, potrebni su alati za modelovanje, simulaciju i dijagnostiku celog sistema. Do sada je to bilo moguće samo modelovanjem mehaničkih delova na nivou parcijalnih diferencijalnih jednačina, što je dovelo do preterano dugih simulacija i činilo simulaciju defekata praktično nemogućom. U radu smo pokazali da je moguće precizno modelovanje mikro-mehaničkih delova sistema crnom kutijom, i, što je najznačajnije, ovi modeli mogu biti efikasno opisani korišćenjem VNM. Takav pristup omogućava brzu simulaciju i simulaciju defekata i dopušta dalji razvoj integriranih alata za projektovanje za celav mikro-elektro-mehanički sistem.

U skladu sa tim, još jednom zaključujemo da su VNM pogodno i moćno sredstvo za dijagnostiku, i što je najvažnije, moguće ih je hardverski realizovati.

## Literatura

- [1] Hagan, M. T., Demuth, H. B., Beale, M. H., “Neural Network Design”, <http://hagan.okstate.edu/nnd.html>.
- [2] Haykin, S., “Neural Networks: A Comprehensive Foundation”, *Macmillan College Publishing Company, Inc.*, 1994.
- [3] Kröse, B., and Smagt van der, P., “An introduction to neural networks”, *University of Amsterdam*, Holland, 1996.
- [4] Milenković, S., “Veštačke neuronske mreže“, *Zadužbina Andrejević*, Beograd, 1997.
- [5] Hecht-Nielsen, R., “Neurocomputing”, *Addison-Wesley Publishing Company*, Reading, MA, 1989.
- [6] Masters, T., “Practical Neural Network Recipes in C++”, *Academic Press*, San Diego, 1993.
- [7] 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.
- [8] Huang, G.-B., Babri, H. A., “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.
- [9] Benjamins, R., and Jansweijer, W., “Toward a competence theory of diagnosis”, *IEEE Expert*, Vol. 9, No. 5, October 1994, pp. 43-52.
- [10] Ho, C. K., Eberhardt, F., and Tenten, W., “Hierarchical fault diagnosis of analog integrated circuits”, *IEEE Trans. On CAS – II: Analog and Digital Signal Processing*, Vol. 48, No. 8, August 2001, pp. 921-9.
- [11] Sheu, H. -T., and Chang, Y.-H., “Robust fault diagnosis for large-scale analog circuits with measurement noises”, *IEEE Trans. CAS-I*, 1997, Vol. 44, pp. 198-209.
- [12] Soma, M., Huynh, S., Zhang, J., “Hierarchical ATPG for Analog Circuits and Systems”, *IEEE Design & Test of Computers*, January-February 2001, pp. 72-81.
- [13] Bandler, J., and Salama, A., “Fault diagnosis of analog circuits”, *Proceedings of the IEEE*, Vol. 73, No. 8, August 1985, pp. 1279-1325.
- [14] Pipitone, F., Dejong, K., and Spears, W., “An artificial intelligence approach to analogue system diagnosis”, in Liu, R.-W., editor, “Testing and diagnosis of analog circuits and systems”, *Van Nostrand Reinhold*, New York, 1991, pp. 187-215.
- [15] Hayashi, S., Asakura, T., and Zhang, S., “Study of Machine Fault Diagnosis System Using Neural Networks”, *Proc. of the Int. Joint Conf. on Neural Networks*, Honolulu, Hawaii, May 2002, pp. 233-8.

- [16] Golonek T., Rutkowski J., "Use of Genetic Programming to Analog Fault Decoder Design", *Int. Conf. ICSES '2002*, Wrocław-Świeradów Zdrój, 2002.
- [17] Pous, C., Colomer, J., Meléndez J., and de la Rosa, J.L., "Introducing Qualitative Reasoning in fault dictionaries techniques for analog circuits analysis", *Sixteenth International Workshop on Qualitative Reasoning*, June 10-12, 2002, Barcelona, Spain.
- [18] Spina, R., and Upadhyaya, S., "Linear circuit fault diagnosis using neuromorphic analysers", *IEEE Trans. On CAS – II: Analog and Digital Signal Processing*, Vol. 44, No. 3, March 1997, pp. 188-196.
- [19] Scarselli, F., and Tsoi, A. C., "Universal approximation using feed-forward neural networks: A survey of some existing methods and some new results", *Neural Networks*, Elsevier, Vol. 11, No. 1, 1998, pp. 15-37.
- [20] Balakrishnan, K., and Honavar, V., "Intelligent diagnosis systems", [http://msi.postech.ac.kr/intro/sfcs/Function\\_architecture%5CFunc\\_archi\\_MNT1.pdf](http://msi.postech.ac.kr/intro/sfcs/Function_architecture%5CFunc_archi_MNT1.pdf)
- [21] Dvorak, D., and Kuipers, B., "Process monitoring and diagnosis", *IEEE Expert*, Vol. 6, No. 3, June 1991, pp. 67-73.
- [22] Fisher, D., et al., "Applying AI clustering to engineering tasks", *IEEE Expert*, Vol. 4, No. 6, December 1993, pp. 51-60.
- [23] Paasch, R.K., and Agogino, A.M., "A structural and behavioral reasoning system for diagnosing large-scale systems", *IEEE Expert*, Vol. 8, No. 4, August 1993, pp. 31-36.
- [24] Kaufman, A., and Gupta, M. M., "Fuzzy mathematical models in engineering and management science", *Noth-Holand*, Amsterdam, 1988.
- [25] Kosko, B., "Neural networks and fuzzy systems, Dynamic systems approach to machine intelligence", *Prentice Hall*, Englewood Cliffs, 1991.
- [26] Babuška, R., "Neuro-fuzzy methods for modelling and identification", in Abraham, A., Jain, Lc.C., and Kacprzyk, J., editors, "Recent Advances in Intelligent Paradigms and Applications", *Springer-Verlag*, Heidelberg, pp. 161-186.
- [27] Ariton, V., Negoita, M., and Bumbaru, S., "A fuzzy-neuro architecture for modular fault isolation on complex systems in industry", *Proc. of ICONIP'99*, Perth, Australia, 1999, pp. 765-770.
- [28] Palade, V., Patton, R. J., Uppal, F. J., Quevedo, J., and Dale, S., "Fault diagnosis of an industrial gas turbine using neuro-fuzzy methods", *Proc. of the 15th IFAC World Congress*, Barcelona-Spain, July 2002, pp. 2477-2482.
- [29] Altug, S., Chow, M.-Y., and Trussell, H. J., "Fuzzy Inference Systems Implemented on Neural Architectures for Motor Fault Detection and Diagnosis", *IEEE Trans. on Industrial Electronics*, Vol. 46, No. 6, Dec. 1999, pp. 1069-1079.
- [30] Uppal, F. J., and Patton, R. J., "Fault diagnosis of an electro-pneumatic valve actuator using neural networks with fuzzy capabilities", *Proc. of the ESANN'22-European symposium on artificial neural networks*, Brugges, Belgium, April 2002, pp. 501-506.

- [31] Milor, L., Visvanathan, V., "Detection of Catastrophic Faults in Analog Integrated Circuits", *IEEE Tran. Computer-Aided Design*, Vol. 8, No. 2, Feb 1989, pp. 114-130.
- [32] Luchetta, A., Manetti, S., and Piccirilli, M. C., "Critical comparison among some analog fault diagnosis procedures based on symbolic techniques", *Proc. of DATE'02*, Paris, France 2002, p. 1105.
- [33] Catelani, M., Giraldi, S., "Fault diagnosis of analog circuits with model based techniques", *IEEE Instrumentation and Measurement Technology Conference*, Vol. V1, 1998, pp. 501-504.
- [34] Alippi, C., Catelani, M., Mugnaini, M., "SBT Soft Fault Diagnosis in Analog Electronic Circuits: A Sensitivity-Based Approach by Randomized Algorithms", *IEEE Tran. on Instrumentation and measurement*, Vol. 51, No. 5, 2002, pp. 1116-1125.
- [35] Huang, J.-L., and Cheng, K.-T., "Test point selection for analog fault diagnosis of unpowered circuit boards", *IEEE Trans. On CAS – II: Analog and Digital Signal Processing*, Vol. 47, No. 10, October 2000, pp. 977-87.
- [36] Yoon, H., Hou, J., Bhattacharya, S. K., Chatterjee, A. and Swaminathan, M., "Fault Detection and Automated Fault Diagnosis for Embedded Integrated Electrical Passives", *The Journal of VLSI Signal Processing*, Volume 21, Number 3, July 1999.
- [37] Chang, Y.-H., "Frequency-domain grouping robust fault diagnosis for analog circuits with uncertainties", *International Journal of Circuit Theory and Applications*, Vol. 30, 2002, pp. 65-86.
- [38] Liu, D., and Starzyk, A., "A generalized fault diagnosis method in dynamic analogue circuits", *International Journal of Circuit Theory and Applications*, Vol. 30, 2002, pp. 487-510.
- [39] Starzyk, J. A., and Liu, D., "A Decomposition Method for Analog Fault Location", *IEEE International Symposium on Circuits and Systems*, May 26-29, Scottsdale, Arizona, 2002, pp. III-157-160.
- [40] Tadeusiewicz, M., Halgas, S., and Korzybski, M., "An algorithm for soft-fault diagnosis of linear and nonlinear circuits", *IEEE Trans. On CAS – II: Analog and Digital Signal Processing*, Vol. 49, No. 11, Nov. 2002, pp. 1648-53.
- [41] Worsman, M., and Wong, M. W. T., "Non-linear analog circuit fault diagnosis with large change sensitivity", *International Journal of Circuit Theory and Applications*, Vol. 28, 2000, pp. 281-303.
- [42] Cota, É. F., Carro, L., Lubaszewski, M., "A Method to Diagnose Faults in Linear Analog Circuits Using an Adaptive Tester", *Proc. Design, Automation and Test in Europe Conference, DATE '99*, Munich, Germany, 1999, pp.184-188.
- [43] Cherubal, S., Chatterjee, A., "Parametric Fault Diagnosis for Analog Systems Using Functional Mapping", *Proc. Design, Automation and Test in Europe (DATE '99)*, vol. 00, 1999, p. 195.
- [44] El-Yazeed, M.F. Abu, Mohsen, Adel A.K., "A Preprocessor for Analog Circuit Fault Diagnosis Based on Prony's Method", *International Journal of Electronics and Communications*, No. 1, 2003, pp. 16-22.

- [45] Dai, Y., and Xu., "Analog circuit fault diagnosis based on noise measurements", *Microelectronics and Reliability*, 1999, Vol. 39(8), pp. 1293-1298.
- [46] Pinjala, K.K., Kim, B.C., Varuyam, P., "Automatic Diagnostic Program Generation for Mixed Signal Load Board", *Proc. International Test Conference*, Charlotte, NC, USA, 2003, pp. 403-409.
- [47] Liobe, J., and Margala, M., "Fault diagnosis of a GHz CMOS LNA Using High-speed ADC-based BIST", *Proc. of the IEEE Defect-Based Testing Workshop*, Napa, CA, April, 2004, pp. 85-89.
- [48] Dragic, S., and Margala, M., "A 1.2 V Built-in Architecture for High Frequency On-Line Iddq/delta Iddq Test", *Proc. IEEE Computer Society Annual Symposium on VLSI*, 25-26 April 2002, pp. 148-153.
- [49] Margala, M., Dragic, S., El-Abasiry, A., Ekpe, S., Stopjakova, V., "1-V Fast IDDQ Current Sensor for On-Line Mixed-Signal/Analog Test", *IEEE Computer Society Annual Symposium on VLSI*, Pittsburgh, PA, USA, 2002. pp. 165-170.
- [50] Papakostas, D.K., and Hatzopoulos, A.A., "Supply current testing in linear bipolar ICs", *Electronics letters*, Vol. 30, No. 2, 1991, pp. 128-130.
- [51] Bell, I. M., Camplin, D. A., Taylor, G. E., Bannister, B. R., "Supply Current Testing Of Mixed Analogue And Digital ICs", *Electronics letters*, Vol. 27, No. 17, 1991, pp. 1591-1583.
- [52] Zwolinski, M., Bartt, A., Wilkins, B. R., Suparjo, B. S., "Analogue Circuit Test using RMS Supply Current Monitoring", *Proceedings of IEEE International Mixed Signal Testing Workshop*, 1996.
- [53] Savioli, C.E, Calvano, J.V., de Mesquita Filho, A.C., "Fault-Trajectory Approach for Fault Diagnosis on Analog Circuits", *Proc. Design, Automation and Test in Europe Conference, DATE '05*, Munich, Germany, March 2005, pp. 174-177.
- [54] Materka, A., "Neural network for parametric testing of mixed-signal circuits", *Electronics Letters*, Vol. 31, No. 3, 2<sup>nd</sup> February 1994, pp. 183-4.
- [55] Rodrigez, C., et al., "A modular neural network approach to fault diagnosis", *IEEE Transactions on Neural Networks*, Vol. 7., No. 2., March 1996, pp. 326-40.
- [56] Aminian, M., and Aminian, F., "Neural-network based analog-circuit fault diagnosis using wavelet transform as preprocessor", *IEEE Trans. on CAS – II: Analog and Digital Signal Processing*, Vol. 47, No. 2, Feb. 2000, pp. 151-6.
- [57] He, Y.-G., Tan, Y.-H., and Sun, Y., "A neural network approach for fault diagnosis of large-scale analog circuits", *Proc. of ISCAS'02*, 2002, pp. I: 153-6.
- [58] Andrejević, M., Litovski, V., "ANN application in electronic diagnosis-preliminary results", *Proc. of IEEE 24<sup>th</sup> International Conference on Microelectronics (MIEL 2004)*, Niš, May 2004, pp. 597-600.
- [59] Aminian, F., Aminiam, M., Collins, H. W., "Analog Fault Diagnosis of Actual Circuits Using Neural Networks", *IEEE Trans. On Instrumentation and Measurement*, Vol. 51, No. 3, June 2002, pp. 544-50.
- [60] Stopjakova, V., Malošek, P., Mišučik, D., Matej, M., Margala, M., "Classification of Defective Analog Integrated Circuits Using Artificial Neural Networks", *Journal of Electronic Testing: Theory and Applications* 20, 2004, pp. 25-37.

- [61] Yu, S., Jervis, B.W., Eckersall, K.R., Bell., I.M., Hall, A.G., and Taylor, G.E., "Neural Network Approach To Fault Diagnosis In CMOS Opamps With Gate Oxide Short Faults", *Electronics Letters*, 1994, Vol. 30, No. 9, pp. 695-696.
- [62] Collins, P., Yu, S., Eckersall, K.R., Jervis, B.W., Bell., I.M., and Taylor, G.E., "Application Of Cohonen and Supervised Forced Organization Maps to Fault Diagnosis in CMOS Opamps", *Electronics letters*, 1994, Vol. 30, No. 22, pp.1846-1847.
- [63] Catelani, M. and Gori, M., "On the application of neural networks to fault diagnosis of electronic analog circuits", *Measurement*, 1996, Vol. 17, pp. 73-80.
- [64] Maidon, Y., Jervis, B.W., Dutton, N., Lesage, S., "Diagnosis of multifaults in analogue circuits using multilayer perceptrons", *IEE Proc.-Circuits Devices Syst.*, Vol. 144, No.3, June 1997, pp. 149-154.
- [65] Yang, Z. R., Zwolinski, M., Chalk, C. D., and Williams, A. C., "Applying a robust heteroscedastic probabilistic neural network to analog fault detection and classification", *IEEE Trans. on CAS of International Circuits and Systems*, Vol. 19, No. 1, January 2000, pp. 142-151.
- [66] Litovski, V., Andrejević, M., Zwolinski, M., "Analogue Electronic Circuit Diagnosis Based on ANNs", *Microelectronics Reliability*, u štampi.
- [67] Zografski, Z., "A Novel Machine Learning Algorithm and Its Use in Modeling and Simulation of Dynamical Systems", *Proceedings of 5th Annual European Computer Conference, COMPEURO'91*, Bologna, Italy 1991, pp. 860-4.
- [68] Milovanović, D., and Litovski, V., "Fault models of CMOS transmission gate", *Int. Journal of Electronics*, Vol. 71, No. 4, Oct. 1991, pp. 675-683.
- [69] Milovanović, D., and Litovski, V., "Fault models of CMOS circuits", *Microelectronics Reliability*, Vol. 34, No. 5, 1994, pp. 883-896.
- [70] Manetti, S., and Piccirilli, C., "A singular-value decomposition approach for ambiguity determination in analog circuits", *IEEE Trans. on Circuits and Systems, -I: Fundamental Theory and Applications*, Vol. 50, No. 4, April 2003, pp. 477-87.
- [71] Baum, E. B., and Haussler, D., "What size net gives valid generalization", *Neural Computing*, Vol. 1, 1989, pp. 151-60.
- [72] Candy, J., Temes, G., "Oversampling methods for A/D and D/A conversion", in *Oversampling Delta-Sigma Data Converters.*, New York: *IEEE Press*, 1992, pp. 1-29.
- [73] Xu, X., and Lucas, M. S. P., "Variable-Sampling-Rate Sigma-Delta Modulator for Instrumentation and Measurement", *IEEE Transactions on Instrumentation and Measurement*, Vol. 44, No. 5, October 1995, pp. 929-932.
- [74] Mrčarica, Ž., Ilić, T., Litovski, V., "Time-Domain Analysis of Nonlinear Switched Networks With Internally Controlled Switches", *IEEE Transactions on Circuits and Systems I*, Vol. 46, No. 3, March, 1999, pp. 373-378.
- [75] Litovski, V., Savić, M., Mrčarica, Ž., "Electronic Circuit Simulation with Ideal Switches", *HAIT Journal of Science and Engineering B*, Vol 2, Iss. 3-4, 2005, pp. 476-495.

- [76] Glozić, D., "Alecsis 2.1: Objektno-orijentisani hibridni simulator", *Doktorska disertacija*, Univerzitet u Nišu, Srbija, 1994.
- [77] Litovski, V. B., "Projektovanje elektronskih kola: simulacija, optimizacija, testiranje, fizičko projektovanje", *Nova Jugoslavija*, Vranje, 2000.
- [78] Andrejević, M., Savić, M., Nikolić, M., "Fault effects in sigma-delta modulator", *ETRAN*, Budva, Jun 2005, pp. 83-86.
- [79] Litovski, V., Andrejević, M. and Zwolinski, M., "Fault Diagnosis in Digital Part of Mixed-Mode Circuit", *MIEL2006*, Niš, 2006, prihvaćeno za objavljivanje.
- [80] Vandenberg, C., "Back to basics: The IC Industry's reintegration and dynamics of a newly emergent full-chip, design-for-manufacturability infrastructure", *IEEE Design and Test of Computers*, Vol. 21, No. 3, 2004, p. 180.
- [81] Litovski, V., Andrejević, M. and Zwolinski, M., "Acceleration of MEMS Fault Simulation Using ANNs", *Small Systems Simulation Symposium- SSSS 2005*, Niš, 28.-29.3.2005, pp. 50-54.
- [82] Jakovljević, M., Mrčarica, Ž., Fotiu, P., Detter, H., Litovski, V., "Implementation of Finite Elements Using An A-HDL Environment", *Numerische Simulation in Feinwerk-/Mikrotechnik und Elektronik*, Munchen, Germany, March 4-5, 1998.
- [83] Jakovljević, M., Mrčarica, Ž., Fotiu, P., Detter, H., Litovski, V., "Transient Electro-Thermal Simulation Of Microsystems With Space-Continuous Thermal Models In Analogue Behavioural Simulator", *Microelectronics and Reliability*, Vol. 40, No. 3, March 2000, pp. 507-516.
- [84] Litovski, V., and Zwolinski, M., "VLSI Circuit Simulation and Optimization", *Chapman and Hall*, London, 1997.
- [85] Maksimović, D., Litovski, V., "Logic simulation methods for longest path delay estimation", *IEE Proceedings Computers and Digital Techniques*, Vol. 149, No. 2, 2002, pp. 53-59.
- [86] Mrčarica, Ž., Risojević, V., Lenczner, M., Jakovljević, M. and Litovski, V., "Integrated simulator for MEMS using FEM implementation in AHDL and frontal solver for large-sparse system of equations", *Proc. of Design and Test of Microsystems*, Paris, March 1999, pp. 271-278.
- [87] Petković, P., Milovanović, D., Litovski, V., "Symbolic Fault Modeling And Test Generation of MOS Circuits", *Microelectronics and Reliability*, Vol. 37, No. 1, 1997, pp. 137-157.
- [88] Litovski, V., Maksimović, D., and Mrčarica, Ž., "Mixed-signal modeling with AleC++: Specific features of the HDL", *Simulation Practice and Theory*, Vol. 8, 2001, pp. 433-449.
- [89] Mrčarica, Ž., Ilić, T., Glozić, D., Litovski, V., and Detter, H., "Mechatronic Simulation Using Alecsis: Anatomy of the Simulator", *Proc. of Eurosim '95*, Vienna, Austria, Sept. 1995, pp. 651-656.
- [90] Mrčarica, Ž., Litovski, V., Detter, H., "Modeling And Simulation of Microsystems Using Hardware Description Language", *Research Journal on Microsystem Technologies*, Vol. 3, No. 2, Feb., 1997, pp. 80-85.
- [91] Chappel, B., "The fine art of IC design", *IEEE Spectrum*, Vol. 36, No. 7, July 1999., pp. 30-34.

- [92] Endemano, A., et al., "VHDL-AMS modeling and simulation of a planar electrostatic micromotor", *Journal of Micromechanics and Microengineering*, Vol. 13, 2003, pp. 580-590.
- [93] Gerlach, G., Schroth, A., and Klein, A., "Modellierung nichtelektrischer Komponenten in heterogenen und komplexen Mikrosystemen", *Workshop: Methoden und Werkzeuge zum Entwurf von Microsystemen*, Frankfurt a.M., Jun 1996, pp. 12-21.
- [94] Haase, J., Vermeiren, W., Clauss, C., und Schwarz, P., "Erste Erfahrungen mit der simulation von Mixed-Signal-Schaltungen mit einem VHDL-AMS-Simulator", ASIM-Tagung, *Simulationstechnik*, Weimar, 17.09. 1999, Praxisforum, pp. 33-38.
- [95] Haase, J., Schwarz, P., Trappe P., und Vermeiren, W., "Erfahrungen mit VHDL-AMS bei der Simulation heterogener Systeme", *ITG/GI/GMM Workshop, "Methoden und beschreibungssprachen zur modellierung und verifikation von Schaltungen und Systemen"*, Frankfurt/M, 28-29.02.2000, pp. 167-175.
- [96] Senturia, S. D., "CAD challanges for Microsensors, Microactuators, and Microsystems", *Proceedings of the IEEE*, Vol. 86, No. 8, August 1998., pp. 1611-1626.
- [97] Zhang, T., Chakrabarty, K., and Fair, R. B., "Behavioral modeling and performance evaluation of microelectrofluidics-based PCR systems using SystemC", *IEEE Trans. on CAD of Integrated circuits and Systems*, Vol. 23, No. 6, June 2004, pp. 843-858.
- [98] Andrejević, M., "Modelovanje nelinearnih reaktivnih elektronskih kola primenom veštačkih neuronskih mreža", *Magistarska teza*, januar 2003.
- [99] Andrejević, M., "Neuronske mreže u modelovanju", *Zadužbina Andrejević*, Beograd, 2004.
- [100] Andrejević, M., Litovski, V., "Electronic Modeling Using ANNs For Analogue and Mixed-Mode Behavioural Simulation", *Proc. of Neurel 2002*, Belgrade, 2002, pp. 113-118.
- [101] Andrejević, M., Litovski, V., "Electronic Modeling Using ANNs For Analogue and Mixed-Mode Behavioural Simulation", *Journal of Automatic Control*, Vol. 13, No. 1, 2003, pp. 31-37.
- [102] Litovski, V., Rađenović, J., Mrčarica, Ž., Milenković, S., "MOS Transistor Modeling Using Neural Network", *Electronics Letters*, Vol. 28, No. 18, August, 1992, pp. 1766-1768.
- [103] Litovski, V., Mrčarica, Ž., Ilić, T., "Simulation Of Non-Linear Magnetic Circuits Modelled Using Artificial Neural Network", *Simulation Practice and Theory*, Vol. 5, 1997, pp. 553-570.
- [104] Litovski, V. B., Andrejević, M., Petković, P., Damper, R., "ANN Application to Modeling of the D/A and A/D Interface for Mixed-Mode Behavioural Simulation", *Journal of Circuits, Systems and Computers*, Vol. 13, No. 1, February 2004, pp. 181-192.
- [105] Zwolinski, M., Brown A.D., "Behavioural Modelling Of Analogue Faults In VHDL-AMS — A Case Study", *ISCAS*, Vancouver, Canada, 2004.



- [106] Andrejević, M., Litovski, V., Zvolinski, M., "Black-box application in modeling of micro-electro-mechanical systems", *Electronics*, University of Banja Luka, Vol. 8, No. 2, December 2004, pp. 27-30.
- [107] Litovski, V., Andrejević, M. and Zvolinski, M., "Behavioural Modelling, Simulation, Test and Diagnosis of MEMS using ANNs", *Proceedings of International Symposium on Circuits and Systems*, Kobe, Japan, May 2005, Vol 5, pp. 182-185.
- [108] Litovski, V., Andrejević, M. and Zvolinski, M., "ANN Based Modeling, Testing and Diagnosis of MEMS", *Neurel 2004*, Beograd, 23.9.-25.9.2004, pp. 183-188.

## **Sadržaj**

|                                   |          |
|-----------------------------------|----------|
| <b>Summary</b>                    | <b>1</b> |
| <b>Uvod</b>                       | <b>3</b> |
| <b>1 Veštačke neuronske mreže</b> | <b>5</b> |

---

|          |   |           |
|----------|---|-----------|
| 1.1      | Prirodni neuron   | 5         |
| 1.2      | Veštački neuron   | 8         |
| 1.3      | Nerekurentna ( <i>feed-forward</i> ) neuronska mreža  | 9         |
| 1.4      | Složenost mreže   | 11        |
| <b>2</b> | <b>Osnovni koncepti dijagnostike</b>  | <b>12</b> |
| 2.1      | Uvod u dijagnostiku   | 13        |
| 2.2      | Dijagnostički sistemi   | 14        |
|          | 2.2.1 Ekspertni sistemi   | 14        |
|          | 2.2.2 Sistemi zasnovani na modelu   | 15        |
|          | 2.2.3 RMS sistemi   | 15        |
|          | 2.2.4 CBR sistemi   | 15        |
|          | 2.2.5 Induktivni dijagnostički sistemi  | 16        |
| 2.3      | Dijagnostika zasnovana na veštačkoj inteligenciji   | 17        |
|          | 2.3.1 Zadatak detekcije simptoma  | 18        |
|          | 2.3.2 Zadatak generisanja hipoteza  | 20        |
|          | 2.3.3 Zadatak odvajanja hipoteza  | 23        |
| 2.4      | Fazi-neuro koncept  | 26        |
|          | 2.4.1 Fazi modeli   | 26        |
|          | 2.4.2 Primena neuro-fazi koncepta na dijagnostiku   | 26        |
| <b>3</b> | <b>Dijagnostika defekata u otpornom kolu</b>  | <b>27</b> |
| 3.1      | Primer kola sa zvezdastom strukturom  | 28        |
| <b>4</b> | <b>Dijagnostika nelinearnih dinamičkih analognih kola</b>   | <b>41</b> |
| 4.1      | Koncepti dijagnostike analognih kola  | 41        |
| 4.2      | Izbor testnih tačaka i izlaznih veličina koje se mere   | 43        |
| 4.3      | Različite primene VNM u dijagnostici analognih kola   | 43        |
| 4.4      | Primer primene VNM na dijagnostiku defekata u kolu operacionog pojačavača                         | 44        |
|          | 4.4.1 Kreiranje rečnika defekata  | 45        |
|          | 4.4.2 Formiranje ambiguity grupa  | 50        |
|          | 4.4.3 Obučavanje neuronske mreže  | 52        |
| <b>5</b> | <b>Dijagnostika defekata u hibridnom kolu</b>   | <b>57</b> |
| 5.1      | Defekata kola sigma-delta modulatora  | 57        |
|          | 5.2.1 Tvrdi defekti   | 60        |
|          | 5.2.2 Meki defekti  | 62        |
| 5.3      | Dijagnostika defekata u digitalnom delu sigma-delta modulatora korišćenjem vremenskog odziva kola | 63        |

---

---

|          |  |           |
|----------|--|-----------|
| <b>6</b> | <b>Modelovanje i simulacija defekata u</b>         |           |
|          | <b>mikro-elektro-mehaničkom sistemu</b>            | <b>67</b> |
| 6.1      | Simulacija mikro-elektro-mehaničkog sistema        | 68        |
| 6.2      | Modelovanje MEMS-a crnom kutijom                   | 71        |
|          | 6.2.1 Modelovanje kapacitivnosti neuronskom mrežom | 72        |
|          | 6.2.2 Simulacija sistema sa VNM                    | 73        |
| 6.3      | Testiranje i dijagnostika kola sa VNM              | 75        |
| <b>7</b> | <b>Zaključak</b>                                   | <b>80</b> |
|          | <b>Literatura</b>                                  | <b>82</b> |