



UNIVERZITET U NIŠU  
ELEKTRONSKI FAKULTET



**Tomislav I. Ćirić**

**NOVI PRISTUPI U MODELOVANJU  
RF MEMS PREKIDAČA**

DOKTORSKA DISERTACIJA

Niš, 2021.



UNIVERSITY OF NIŠ  
FACULTY OF ELECTRONIC ENGINEERING



**Tomislav I. Ćirić**

**NEW APPROACHES TO RF MEMS  
SWITCH MODELING**

DOCTORAL DISSERTATION

Niš, 2021.

## Подаци о докторској дисертацији

Ментор:

Prof. dr Zlatica Marinković, vanredni profesor, Univerzitet u Nišu, Elektronski fakultet

Наслов:

Novi pristupi u modelovanju RF MEMS prekidača

Резиме:

Modelovanje RF MEMS prekidača obuhvata modelovanje elektromagnetskih (EM) i mehaničkih karakteristika, koje se standardno vrši u komercijalnim EM (*full-wave*) i mehaničkim simulatorima. Iako ovi metodi obezbeđuju zadovoljavajuću tačnost, ograničeni su na jednu analizu za određenu strukturu, proračunski i vremenski su veoma zahtevni, a naročito u procedurama optimizacije dimenzija razmatrane strukture prekidača.

Kod modela RF MEMS prekidača često nedostaju direktne relacije između geometrijskih parametara prekidača i njegovih EM/mehaničkih karakteristika, koje bi se koristile pri optimizaciji karakteristika prekidača ili kola koja ih sadrže. Upravo iz tih razloga, u okviru ove disertacije predstavljena su istraživanja čiji je cilj razvoj novih pristupa za pouzdano i efikasno modelovanje karakteristika RF MEMS prekidača. Modelovanje RF MEMS prekidača vršeno je primenom veštačkih neuronskih mreža.

Razvijeni su novi pristupi za modelovanje EM i mehaničkih karakteristika: parametara rasejanja, rezonantne frekvencije, napona aktucije, kao i elemenata ekvivalentnog kola u zavisnosti od geometrijskih dimenzija RF MEMS prekidača.

Prikazana je primena razvijenih modela za analizu osetljivosti karakteristika kapacitivnih RF MEMS prekidača, kako bi se sagledalo ponašanje prekidača, tj. promena rezonantne frekvencije i napona aktucije sa promenama dimenzija mosta koje su uslovljene odstupanjima dimenzija pri fabrikaciji prekidača.

Predstavljen je novi pristup inverznog modelovanja kojim se znatno skraćuje vreme potrebno za optimizaciju karakteristika prekidača, tj. projektovanje prekidača u skladu sa željenim karakteristikama.

Sledeći razvijeni modeli odnose se na modelovanje elemenata ekvivalentnog kola RF MEMS prekidača u zavisnosti od lateralnih dimenzija mosta prekidača. Razvijeni su neuronski modeli za optimizaciju elemenata kola, tj. proračun elemenata ekvivalentnog kola za zadate lateralne dimenzije prekidača. Time je razvijen novi pristup koji značajno skraćuje vreme potrebno za određivanje elemenata i karakteristika RF MEMS prekidača.

Na kraju, razvijeni su hibridni inverzni modeli, preko kojih se za zadate vrednosti karakteristika prekidača, direktno određuju, odnosno optimizuju, dimenzije mosta prekidača i vrednosti elemenata ekvivalentnog kola.

Научна област:

Elektrotehničko i računarsko inženjerstvo, Telekomunikacije

Научна дисциплина:	Mikrotalasna elektronika
Кључне речи:	Veštačke neuronske mreže, RF MEMS prekidači, Modelovanje, Optimizacija
УДК:	004.032.26+(621.37:537-962)
CERIF класификација:	T 191 Visokofrekventna tehnologija, mikrotalasi
Тип лиценце Креативне заједнице:	<b>CC BY-NC-ND</b>

## Data on Doctoral Dissertation

Doctoral  
Supervisor:

Prof. Dr. Zlatica Marinković, Associate Professor, University of Niš,  
Faculty of Electronic Engineering

Title:

New approaches to RF MEMS switch modeling

Abstract:

Modeling of RF MEMS switches includes modeling of electromagnetic (EM) and mechanical characteristics, which is standardly performed in commercial EM (full-wave) and mechanical simulators. Although these methods provide necessary accuracy, they are generally limited to one analysis for a certain structure, also very computationally and time demanding, especially in the procedures of optimizing the dimensions of the considered switch structure.

RF MEMS switch models often lack direct relationships between the geometric parameters of the switch and its EM/mechanical characteristics, which would be used to optimize the characteristics of the switch or circuits that contain them. Precisely for these reasons, this dissertation presents a research whose goal is to develop new approaches for reliable and efficient modeling of the characteristics of RF MEMS switches. Modeling of RF MEMS switches was performed using artificial neural networks.

New approaches were developed for modeling EM and mechanical characteristics: scattering parameters, resonant frequencies, actuation voltages, as well as elements of the equivalent circuit depending on the geometric dimensions of RF MEMS switches.

Application of the developed models for the analysis of the sensitivity of the characteristics of capacitive RF MEMS switches is presented, in order to observe the behavior of the switches, i.e. change of resonant frequency and actuation voltage with changes of bridge dimensions which are conditioned by dimensional deviations during switches fabrication.

A new inverse modeling approach is presented, which significantly shortens the time required to optimize the characteristics of the switch, i.e. design of switches in accordance with the desired characteristics.

The further developed models refer to the modeling of the equivalent circuit elements of an RF MEMS switch depending on the lateral dimensions of the switch bridge. Neural models have been developed for the optimization of circuit elements, i.e. calculation of the equivalent circuit elements for the given lateral dimensions of the switch. This new approach provides significant shortening of the time required to determine the equivalent circuit elements and characteristics of RF MEMS switches.

Finally, hybrid inverse models have been developed, aimed for direct determination and optimization of the switch bridge dimensions and the values of the equivalent circuit elements for given characteristics of the switch.

Scientific Field:	Electrical and Computer Engineering, Telecommunications
Scientific Discipline:	Microwave electronics
Key Words:	Artificial neural networks, RF MEMS switch, Modeling, Optimization
UDC:	004.032.26+(621.37:537-962)
CERIF Classification:	T 191 High frequency technology, microwaves
Creative Commons License Type:	<b>CC BY-NC-ND</b>

# SADRŽAJ

<b>SPISAK TABELA</b> .....	<b>i</b>
<b>SPISAK SLIKA</b> .....	<b>iii</b>
<b>SPISAK SKRAĆENICA</b> .....	<b>viii</b>
<b>SPISAK SIMBOLA</b> .....	<b>x</b>
<b>1 UVOD</b> .....	<b>1</b>
<b>2 RF MEMS PREKIDAČI</b> .....	<b>8</b>
2.1 OSNOVE MIKROELEKTROMEHANIČKIH SISTEMA .....	8
2.2 ISTORIJAT I PRAVCI DALJEG RAZVOJA MEMS-A .....	9
2.3 UPOREDNE KARAKTERISTIKE MEMS PREKIDAČA SA POLUPROVODNIČKIM PREKIDAČIMA .....	13
2.4 KONFIGURACIJA RF MEMS PREKIDAČA .....	15
2.5 RF MEMS PREKIDAČI ZA PRIMENU U TELEKOMUNIKACIJAMA .....	18
2.5.1 Opis fizičkih karakteristika MEMS kapacitivnog prekidača u paralelnoj konfiguraciji .....	20
2.5.2 Opis fizičkih karakteristika MEMS omskog prekidača u serijskoj konfiguraciji .....	22
2.6 MODELOVANI RF MEMS KAPACITIVNI I OMSKI PREKIDAČI .....	25
<b>3 VEŠTAČKE NEURONSKE MREŽE</b> .....	<b>28</b>
3.1 MODELI NEURONA VEŠTAČKE NEURONSKE MREŽE .....	30
3.2 NEURONSKA MREŽA .....	34
3.3 SLOJEVITA NEURONSKA MREŽA-MLP .....	38
3.1.1 Backpropagation algoritam .....	40
3.4 NEURONSKA MREŽA SA RADIJALNOM FUNKCIJOM (RBF MREŽA) .....	43
3.5 SPOSOBNOST GENERALIZACIJE.....	45
3.6 TESTIRANJE VEŠTAČKIH NEURONSKIH MREŽA .....	47
3.7 STRUKTURE NEURONSKIH MODELA PREDLOŽENIH ZA MODELOVANJE RF MEMS PREKIDAČA .....	49
3.7.1 Priprema podataka za neuronske modele .....	51
<b>4 BLACK-BOX MODELI KARAKTERISTIKA RF MEMS PREKIDAČA</b> .....	<b>54</b>
4.1 MODELOVANJE EM KARAKTERISTIKA - PARAMETRI RASEJANJA .....	57

4.2	MODELOVANJE EM KARAKTERISTIKA - REZONANTNA FREKVENCIJA .....	62
4.3	MODELOVANJE MEHANIČKIH KARAKTERISTIKA - NAPON AKTUACIJE .....	64
4.4	PRIMENA RAZVIJENIH BLACK-BOX MODELA ZA ANALIZU I PROJEKTOVANJE RF MEMS PREKIDAČA .....	68
4.4.1	<i>Analiza osetljivosti rezonantne frekvencije RF MEMS kapacitivnog prekidača.....</i>	68
4.4.2	<i>Analiza osetljivosti napona aktucije RF MEMS kapacitivnog prekidača .....</i>	74
4.4.3	<i>Analiza osetljivosti S-parametara RF MEMS omskog prekidača.....</i>	80
4.4.4	<i>Primena razvijenih black-box modela za projektovanje RF MEMS kapacitivnog prekidača u električnom domenu.....</i>	90
4.4.5	<i>Primena razvijenih black-box modela za projektovanje RF MEMS kapacitivnog prekidača u mehaničkom domenu.....</i>	96
4.5	UPOREDNA ANALIZA PRIMENJIVOSTI RBF I MLP NEURONSKIH MODELA ZA MODELOVANJE KARAKTERISTIKA RF MEMS PREKIDAČA.....	101
<b>5</b>	<b>HIBRIDNI MODELI RF MEMS PREKIDAČA .....</b>	<b>106</b>
<b>6</b>	<b>INVERZNO MODELOVANJE RF MEMS PREKIDAČA KORIŠĆENJEM NEURONSKIH MODELA.....</b>	<b>114</b>
6.1	INVERZNI NEURONSKI MODELI ZA EM I MEHANIČKE KARAKTERISTIKE RF MEMS PREKIDAČA .....	117
6.2	INVERZNI NEURONSKI MODELI ZA ELEKTRO-MEHANIČKE KARAKTERISTIKE RF MEMS PREKIDAČA ...	122
6.3	PRIMENA INVERZNIH NEURONSKIH MODELA .....	130
6.3.1	<i>Primena inverznog modela EM karakteristika za projektovanje RF MEMS prekidača .....</i>	131
6.3.2	<i>Primena inverznog modela mehaničkih karakteristika za projektovanje RF MEMS prekidača. ...</i>	133
6.3.3	<i>Primena elektro-mehaničkog neuronskog modela u analizi RF MEMS prekidača .....</i>	135
<b>7</b>	<b>HIBRIDNI PRISTUPI ZA INVERZNO MODELOVANJE RF MEMS PREKIDAČA.....</b>	<b>138</b>
7.1	HIBRIDNI PRISTUPI ZA INVERZNO MODELOVANJE ZA ZADATU REZONANTNU FREKVENCIJU .....	139
7.1.1	<i>Hibridni inverzni model sa ulaznim vrednostima <math>f_{res}</math> i <math>L_s</math>.....</i>	139
7.1.2	<i>Hibridni inverzni model sa ulaznim vrednostima <math>f_{res}</math> i <math>L_s</math>.....</i>	146
7.2	HIBRIDNI PRISTUP ZA INVERZNO MODELOVANJE RF MEMS PREKIDAČA SA ZADATOM VREDNOŠĆU JEDNOG ELEMENTA EKVIVALENTNOG KOLA.....	150
<b>8</b>	<b>ZAKLJUČAK.....</b>	<b>154</b>
<b>9</b>	<b>LITERATURA .....</b>	<b>160</b>
	<b>BIOGRAFIJA AUTORA.....</b>	<b>168</b>



## SPISAK TABELA

Tabela 2.1 <i>Uporedni pregled karakteristika MEMS, PIN i FET prekidača [1]</i> .....	13
Tabela 2.2 <i>Karakteristike različitih konfiguracije MEMS komponenti</i> .....	17
Tabela 4.1 <i>Rezultati testiranja modela na test skupu</i> .....	63
Tabela 4.2 <i>Rezultati testiranja neuronskih modela sa različitim brojem skrivenih neurona</i> ...	66
Tabela 4.3 <i>Rezultati testiranja neuronskog modela za napon aktivacije RF MEMS prekidača</i>	67
Tabela 4.4 <i>Promena <math>f_{res}</math> za istovremenu promenu dimenzija za <math>\pm 5 \mu m</math> i <math>\pm 3 \mu m</math></i> .....	74
Tabela 4.5 <i>Promena <math>V_{PI}</math> za istovremene promene dimenzija <math>\pm 5 \mu m</math> i <math>\pm 3 \mu m</math></i> .....	80
Tabela 4.6 <i>Devijacije povratnog i unutrašnjeg slabljenja pri promenama <math>L_b</math> za <math>\pm 3 \mu m</math></i> .....	82
Tabela 4.7 <i>Devijacije povratnog i unutrašnjeg slabljenja pri promenama <math>W_b</math> za <math>\pm 3 \mu m</math></i> .....	83
Tabela 4.8 <i>Devijacije povratnog i unutrašnjeg slabljenja pri promenama <math>L_g</math> za <math>\pm 3 \mu m</math></i> .....	84
Tabela 4.9 <i>Devijacije povratnog i unutrašnjeg slabljenja pri promenama <math>W_g</math> za <math>\pm 3 \mu m</math></i> .....	85
Tabela 4.10 <i>Devijacije povratnog i unutrašnjeg slabljenja pri istovremenim promenama dve dimenzije za <math>\pm 3 \mu m</math></i> .....	87
Tabela 4.11 <i>Devijacije povratnog i unutrašnjeg slabljenja pri istovremenim promenama dimenzija mosta i procepa za <math>\pm 3 \mu m</math></i> .....	90
Tabela 4.12 <i>Test rezultati razvijenih RBF neuronskih modela</i> .....	103
Tabela 4.13 <i>Pregled test rezultata RBF i MLP neuronskih modela za vrednosti <math>V_{PI}</math></i> .....	103
Tabela 5.1 <i>Kombinacije dimenzija, induktivnosti i otpornosti korišćene za trening skup</i> .....	109
Tabela 5.2 <i>Kombinacije dimenzija, induktivnosti i otpornosti korišćene za test skup</i> .....	109
Tabela 5.3 <i>Test rezultati za induktivnost</i> .....	110
Tabela 5.4 <i>Test rezultati za otpornost</i> .....	110
Tabela 5.5 <i>Induktivnost realizovane komponente dobijena neuronskim modelima</i> .....	112
Tabela 5.6 <i>Otpornost realizovane komponente dobijena neuronskim modelima</i> .....	112
Tabela 6.1 <i>Inverzno modelovanje RF MEMS prekidača - određivanje <math>L_f</math></i> .....	117
Tabela 6.2 <i>Inverzno modelovanje RF MEMS prekidača - određivanje <math>L_s</math></i> .....	118

Tabela 6.3 Inverzno modelovanje RF MEMS prekidača - određivanje $L_f$ .....	120
Tabela 6.4 Inverzno modelovanje RF MEMS prekidača - određivanje dimenzije $L_s$ .....	120
Tabela 6.5 Test rezultati izabranog neuronskog modela (3-10-20-1) za određivanje $L_f$ .....	124
Tabela 6.6 Test rezultati izabranog neuronskog modela (3-20-10-1) za određivanje $L_s$ .....	125
Tabela 6.7 Rezultati inverznog modelovanja dimenzije $L_f$ RF MEMS prekidača: $f_{res}$ .....	128
Tabela 6.8 Rezultati inverznog modelovanja dimenzije $L_f$ RF MEMS prekidača: $V_{PI}$ .....	128
Tabela 6.9 Rezultati inverznog modelovanja dimenzije $L_s$ RF MEMS prekidača: $f_{res}$ .....	128
Tabela 6.10 Rezultati inverznog modelovanja dimenzije $L_s$ RF MEMS prekidača: $V_{PI}$ .....	129
Tabela 7.1 Rezultati određivanja otpornosti $R$ neuronskim modelom VNM 2.....	143
Tabela 7.2 Vrednosti elemenata ekvivalentnog kola .....	143
Tabela 7.3 Rezultati određivanja otpornosti $R$ neuronskim modelom VNM 2.....	147
Tabela 7.4 Elementi ekvivalentnog kola.....	148
Tabela 7.5 Rezultati testiranja VNM 1 na trening skupu za određivanje dimenzija $L_s$ .....	152
Tabela 7.6 Rezultati testiranja VNM 1 na test skupu za određivanje dimenzija $L_s$ .....	152
Tabela 7.7 Rezultati testiranja VNM 2 na trening skupu za određivanje dimenzija $L_f$ .....	152
Tabela 7.8 Rezultati testiranja VNM 2 na test skupu za određivanje dimenzija $L_f$ .....	153

## SPISAK SLIKA

Slika 2.1 Osnovne tehnike (optika, mehanika i elektronika) za razvoj MEMS, MOEMS, optoelektronike i optomehanike .....	9
Slika 2.2 MEMS tržište sa projekcijom razvoja do 2025. godine .....	11
Slika 2.3 RF MEMS prekidači u odnosu na vrstu kontakta: a) omski i b) kapacitivni .....	16
Slika 2.4 RF MEMS prekidači sa različitim tipovima mehaničkih kontakata: a) elektrostatički, b) elektromagnetni, c) piezoelektrični, d) elektrotermički.....	16
Slika 2.5 Konfiguracije RF MEMS prekidači u odnosu na signalnu liniju: a) serijska konfiguracija, b) paralelna konfiguracija .....	18
Slika 2.6 Serijski prekidači: a) analogni prekidač sa metalnim kontaktima, b) Rockwell Scientific prekidač .....	19
Slika 2.7 Paralelni MEMS prekidači: a) Lincoln Labs, b) Raytheon prekidač .....	19
Slika 2.8 MEMS paralelni prekidač u poprečnoj i vertikalnoj ravni sa odgovarajućim strujnim kolom.....	20
Slika 2.9 MEMS omski prekidač: a) u serijskoj vezi, b) u vertikalnoj ravni, c) u poprečnoj ravni i d) sa odgovarajućim strujnim kolom .....	23
Slika 2.10 Modelovani prekidač sa šemom poprečnog preseka u FBK tehnologiji .....	25
Slika 2.11 Omski RF MEMS prekidač: a) u serijskoj topologiji, b) uprošćena konfiguracija	26
Slika 3.1 Prirodni neuron.....	29
Slika 3.2 Nelinearni model neurona .....	30
Slika 3.3 Nelinearan model neurona sa proširenim ulazom .....	32
Slika 3.4 Linearna prenosna funkcija neurona .....	32
Slika 3.5 Odskočne prenosne funkcije neurona: a) u opsegu $[0,1]$ i b) u opsegu $[-1,1]$ .....	33
Slika 3.6 Sigmoidne prenosne funkcije neurona: a) log-sigmoidna i b) tan-sigmoidna.....	34
Slika 3.7 Klase učenja neuronskih mreža: a) Nadgledano učenje, b) Učenje sa podsticanjem i	

c) Nenadgledano učenje .....	36
Slika 3.8 Slojevita MLP neuronska mreža .....	39
Slika 3.9 Procesiranje informacije u $i$ – tom neuronu $l$ – tog sloja MLP mreže .....	40
Slika 3.10 Struktura RBF neuronske mreže .....	43
Slika 3.11 Gausova funkcija.....	44
Slika 3.12 Primer odziva nedovoljno obučene neuronske mreže.....	46
Slika 3.13 Primer odziva preobučene neuronske mreže .....	46
Slika 3.14 Zavisnost greške od broja epoha [31] .....	47
Slika 3.15 Primer korelacionog dijagrama.....	49
Slika 3.16 Osnovni neuronski model („black-box“) .....	50
Slika 3.17 Neuronski model zasnovan na dekompoziciji .....	50
Slika 3.18 Neuronski model baziran na preslikavanju prostora ulaznih veličina .....	51
Slika 4.1 Predloženi black-box neuronski model .....	55
Slika 4.2 Blok dijagram razvoja i validacije predloženog neuronskog modela.....	56
Slika 4.3 Dvoprilazna mreža .....	57
Slika 4.4 Neuronski model za $S$ -parametre u zavisnosti od dimenzija mosta i frekvencije .....	58
Slika 4.5 Parametar $S_{11}$ za test skup .....	59
Slika 4.6 Parametar $S_{21}$ za test skup .....	60
Slika 4.7 Izolacija realizovanog RF MEMS kapacitivnog prekidača .....	61
Slika 4.8 Veštačka neuronska mreža za modelovanje RF MEMS prekidača.....	62
Slika 4.9 Korelacija izlaznih vrednosti test skupa .....	64
Slika 4.10 Neuronski model za određivanje zavisnosti napona aktuacije od dimenzija prekidača [23].....	65
Slika 4.11 Korelacija izlaza VNM i referentnih vrednosti za trening podatke [75] .....	66
Slika 4.12 Korelacija izlaza VNM i referentnih vrednosti iz test skupa [91, 92] .....	67
Slika 4.13 Rezonantna frekvencija RF MEMS prekidača u zavisnosti od $L_f$ .....	69
Slika 4.14 Rezonantna frekvencija RF MEMS prekidača u zavisnosti od $L_s$ .....	69
Slika 4.15 Promene rezonantne frekvencije RF MEMS prekidača u zavisnosti od $L_f$ : a) $L_s =$ $200 \mu\text{m}$ , b) $L_s = 300 \mu\text{m}$ i c) $L_s = 450 \mu\text{m}$ .....	70
Slika 4.16 Promene rezonantne frekvencije RF MEMS prekidača u zavisnosti od $L_s$ : a) $L_f =$ $20 \mu\text{m}$ , b) $L_f = 50 \mu\text{m}$ i c) $L_f = 80 \mu\text{m}$ .....	71
Slika 4.17 Prosečne devijacije rezonantne frekvencije za promene $L_s$ .....	72
Slika 4.18 Prosečne devijacije rezonantne frekvencije za promene $L_f$ .....	73
Slika 4.19 Napon aktuacije RF MEMS prekidača u zavisnosti od $L_f$ .....	75

Slika 4.20 Napon aktivacije RF MEMS prekidača u zavisnosti od $L_s$ .....	75
Slika 4.21 Promene napona aktivacije RF MEMS prekidača u zavisnosti od $L_f$ : a) $L_s= 200$ $\mu\text{m}$ , b) $L_s= 300 \mu\text{m}$ i c) $L_s= 450 \mu\text{m}$ .....	76
Slika 4.22 Promene napona aktivacije RF MEMS prekidača u zavisnosti od $L_s$ : a) $L_f= 20 \mu\text{m}$ , b) $L_f= 50 \mu\text{m}$ i c) $L_f= 80 \mu\text{m}$ .....	77
Slika 4.23 Prosečne devijacije napona aktivacije za promene $L_s$ .....	78
Slika 4.24 Prosečne devijacije napona aktivacije za promene $L_f$ .....	79
Slika 4.25 Predloženi model za generisanje S-parametara RF MEMS omskog prekidača .....	81
Slika 4.26 Najizraženiji uticaj promena $L_b$ dimenzije: a) Povratno slabljenje za prekidač (400, 20, 30, 150) i b) Unutrašnje slabljenje za prekidač (1000, 220, 30, 20) .....	83
Slika 4.27 Najizraženiji uticaj promena $W_b$ dimenzije: a) Povratno slabljenje za prekidač (400, 20, 30, 150) i b) Unutrašnje slabljenje za prekidač (800, 20, 50, 110) .....	84
Slika 4.28 Najizraženiji uticaj promena $L_g$ dimenzije: a) Povratno slabljenje za prekidač (400, 20, 30, 150) i b) Unutrašnje slabljenje za prekidač (800, 20, 50, 110) .....	85
Slika 4.29 Najizraženiji uticaj promena $W_g$ dimenzije: a) Povratno slabljenje za prekidač (400, 20, 30, 150) i b) Unutrašnje slabljenje za prekidač (800, 20, 50, 110).....	86
Slika 4.30 Maksimalan uticaj istovremenih promena $L_b$ i $W_b$ : a) Povratno slabljenje (prekidač 400, 20, 30, 150) i b) Unutrašnje slabljenje (prekidač 800, 20, 50, 110).....	88
Slika 4.31 Maksimalan uticaj istovremenih promena $L_g$ i $W_g$ : a) Povratno slabljenje (prekidač 400, 20, 30, 150) i b) Unutrašnje slabljenje (prekidač 800, 20, 50, 110) 89	
Slika 4.32 Vrednosti rezonantne frekvencije generisane razvijenim neuronskim modelom ....	91
Slika 4.33 Vrednosti rezonantne frekvencije za razmatrane opsege dimenzija mosta: a) dimenzije osnove mosta, b) dimenzije prsta mosta .....	92
Slika 4.34 Ukupna dužina mosta u odnosu na $f_{res}$ u razmatranom opsegu dimenzija mosta ...	93
Slika 4.35 Moguće vrednosti dimenzija mosta u odnosu na rezonantnu frekvenciju i različite dimenzije ukupne dužine mosta $L_t$ : a) procentualni odnos, b) u odnosu na dimenzije $L_s$ , c) u odnosu na dimenzije $L_f$ .....	95
Slika 4.36 Moguće vrednosti dimenzija mosta u odnosu na rezonantnu frekvenciju i ukupnu dužinu mosta od $L_t = 400 \mu\text{m}$ .....	95
Slika 4.37 Vrednosti napona aktivacije izračunate neuronskim modelom .....	96
Slika 4.38 Vrednosti napona aktivacije za razmatrane opsege dimenzija mosta: a) dimenzije osnove mosta, b) dimenzije prsta mosta.....	97
Slika 4.39 Ukupne dužine mosta u odnosu na $V_{PI}$ u razmatranom opsegu dimenzija mosta... 98	

Slika 4.40 Napon aktivacije za različite vrednosti ukupne dužine mosta prekidača u odnosu na: a) procenete, b) $L_s$ , (c) $L_f$ .....	100
Slika 4.41 Moguće vrednosti dimenzija mosta u odnosu na napon aktivacije za ukupnu dužinu mosta od $L_t=400 \mu\text{m}$ .....	101
Slika 4.42 Predloženi neuronski model na bazi RBF mreže .....	102
Slika 4.43 Korelacija vrednosti dobijenih pomoću RBF neuronskog modela i ciljnih vrednosti napona aktivacije .....	104
Slika 4.44 Grafik generisanih vrednosti napona aktivacije MLP i RBF neuronskih modela.	104
Slika 5.1 Predloženi hibridni model.....	107
Slika 5.2 Neuronski modeli: a) dve zasebne VNM, b) jedna VNM .....	107
Slika 5.3 $S_{21}$ vrednosti RF MEMS prekidača sa dimenzijama $L_s = 350 \mu\text{m}$ i $L_f = 25 \mu\text{m}$ .....	111
Slika 5.4 $S_{11}$ vrednosti RF MEMS prekidača sa dimenzijama $L_s = 350 \mu\text{m}$ i $L_f = 25 \mu\text{m}$ .....	112
Slika 5.5 Uporedni pregled vrednosti $S_{21}$ dobijenih hibridnim modelom u odnosu na referentne simulacije i realizovanu komponentu RF MEMS prekidača .....	113
Slika 6.1 Direktni neuronski model.....	115
Slika 6.2 Inverzni neuronski modeli za određivanje: a) $L_f$ ; b) $L_s$ .....	115
Slika 6.3 Procedure razvoja modela za inverzno modelovanje RF MEMS prekidača sa generisanjem trening podataka korišćenjem direktnih neuronskih modela .....	116
Slika 6.4 Prostor ulaznih veličina za inverzne EM modele na osnovu generisanih vrednosti iz direktnih neuronskih modela za određivanje: a) $L_f$ i b) $L_s$ .....	119
Slika 6.5 Prostor ulaznih veličina za inverzne mehaničke modele na osnovu generisanih vrednosti iz direktnih neuronskih modela za određivanje: a) $L_f$ i b) $L_s$ .....	121
Slika 6.6 Predloženi inverzni elektro-mehanički modeli za određivanje: a) $L_f$ i b) $L_s$ .....	123
Slika 6.7 Grafički prikaz tačnosti modelovanja: a) $L_f$ i b) $L_s$ .....	126
Slika 6.8 Prostor mogućih kombinacija ulaznih veličina $f_{res} - V_{PI}$ .....	130
Slika 6.9 Dužina mosta u odnosu na fres u razmatranom opsegu dimenzija prekidača.....	131
Slika 6.10 Određivanje dimenzija $L_s$ i $L_f$ za zadatu ukupnu dužinu mosta $L_t = 300 \mu\text{m}$ : a) prikaz za celi opseg $L_s$ i b) uveličani prikaz za $L_s$ od 200 do 300 $\mu\text{m}$ .....	132
Slika 6.11 Ukupna dužina mosta prekidača u odnosu na napon aktivacije u razmatranom opsegu dimenzija prekidača .....	133
Slika 6.12 Određivanje dimenzija $L_s$ i $L_f$ za zadatu ukupnu dužinu mosta $L_t = 300 \mu\text{m}$ : a) prikaz za celi opseg $L_s$ i b) uveličani prikaz za $L_s$ od 200 do 300 $\mu\text{m}$ .....	134
Slika 6.13 Određivanje dimenzija mosta prekidača za ukupnu dužinu mosta $L_t = 260 \mu\text{m}$ ..	136
Slika 7.1 Predloženi hibridni inverzni model [106].....	140

Slika 7.2 Blok dijagram procedure razvoja hibridnog inverznog modela.....	141
Slika 7.3 Vrednosti parametara $S_{11}(a)$ i $S_{21}(b)$ za dimenzije $L_s = 100 \mu\text{m}$ i $L_f = 75 \mu\text{m}$ (RLC model – crvena linija, full-wave simulator - plava linija).....	144
Slika 7.4 Vrednosti parametara $S_{11}(a)$ i $S_{21}(b)$ za dimenzije $L_s = 350 \mu\text{m}$ i $L_f = 25 \mu\text{m}$ (RLC model - crvena linija, full-wave simulator - plava linija) .....	145
Slika 7.5 Predloženi pristup hibridnog modela [105] .....	146
Slika 7.6 Vrednosti parametara $S_{11}(a)$ i $S_{21}(b)$ za dimenzije $L_f = 75 \mu\text{m}$ i $L_s = 100 \mu\text{m}$ (RLC model - crvena linija, full-wave simulator - plava linija) .....	148
Slika 7.7 Vrednosti parametara $S_{11}(a)$ i $S_{21}(b)$ za dimenzije $L_f = 25 \mu\text{m}$ i $L_s = 350 \mu\text{m}$ (RLC model - crvena linija, full-wave simulator - plava linija) .....	149
Slika 7.8 Inverzni neuronski modeli za a) $L_s$ i b) $L_f$ .....	150

## SPISAK SKRAĆENICA

ADS	simulator mikrotalasnih kola ( <i>Advanced Design System</i> )
ANN	veštačka neuronska mreža ( <i>Artificial Neural Network</i> )
ATE	srednja greška testiranja ( <i>Average Test Error</i> )
CPW	vrsta planarne prenosne linije ( <i>Coplanar Waveguide</i> )
DARPA	Agencija za napredna istraživanja u oblasti odbrane ( <i>Defence Advanced Research Projects Agency</i> )
DC	jednosmerna struja ( <i>Direct Current</i> )
ECP	elementi ekvivalentnog kola ( <i>Equivalent Circuit Parameters</i> )
FBK	Istraživački institut Fondacija Bruno Kesler, Italija ( <i>Fondazione Bruno Kessler</i> )
FEM	metod konačnih elemenata ( <i>Finite Element Method</i> )
FET	tranzistor sa efektom polja ( <i>Field-Effect Transistor</i> )
IoE	prošireni koncepti IoT, inteligentna veza ljudi, procesa, podataka i uređaja ( <i>Internet of Everything</i> )
IoT	Internet inteligentnih uređaja ( <i>Internet of Things</i> )
LIDAR	tehnologija prostornog laserskog snimanja ( <i>Light Detection and Ranging</i> )
LTCC	tehnologija izrade mikroelektronskih komponenti, zasnovana na niskotemperaturno pečenoj keramici ( <i>Low Temperature Co-fired Ceramic</i> )
MATLAB	softver za numerički proračun i programiranje ( <i>MATrix LABoratory</i> )
MEMS	mikro-elektro-mehanički sistemi ( <i>Micro-Electro-Mechanical Systems</i> )
MLP	višeslojna veštačka neuronska mreža ( <i>Multi-Layer Perceptron</i> )
MOEMS	mikro-opto-elektro-mehanički sistemi ( <i>Micro-Opto-Electro-Mechanical Systems</i> )
MSE	srednja kvadratna greška ( <i>Mean Squared Error</i> )



RBF	VNM sa radijalnom baznom funkcijom ( <i>Radial Base Function</i> )
RF	radio frekvencija ( <i>Radio Frequency</i> )
RF MEMS	RF mikroelektromehanički sistemi ( <i>Micro-Electro-Mechanical Systems</i> )
SM	preslikavanje prostora ulaznih veličina ( <i>Space Mapping</i> )
VAR	blokovi promenjivih i izraza u mikrotalasnim simulatorima ( <i>Variable and Equation</i> )
WCE	maksimalna greška ( <i>Worst Case Error</i> )

## SPISAK SIMBOLA

$A$	površina kapacitivnog sloja RF MEMS prekidača
$c$	centar vektora RBF veštačke neuronske mreže
$C_d$	kapacitivnost RF MEMS prekidača sa mostom u spušenom položaju
$C_p$	parazitna kapacitivnost
$C_s$	serijska kapacitivnost
$C_u$	kapacitivnost RF MEMS prekidača sa mostom u podignutom položaju
$E$	razlika stvarnih i željenih izlaza veštačke neuronske mreže
$f_c$	granična frekvencija
$f_{res}$	rezonantna frekvencija
$g$	rastojanje mosta prekidača od izolatorskog sloja
$j$	ulaz sinapse
$k$	neuron veštačke neuronske mreže
$L$	broj slojeva u veštačkoj neuronskoj mreži
$L$	induktivnost
$L$	dužina mosta RF MEMS prekidača
$L_b$	dužina mosta omskog RF MEMS prekidača
$L_f$	dužina prsta mosta kapacitivnog RF MEMS prekidača
$L_g$	lateralni procep kod omskog RF MEMS prekidača
$L_{oss}$	slabljenje RF MEMS prekidača
$L_s$	dužina osnove mosta kapacitivnog RF MEMS prekidača
$L_t$	ukupna dužina mosta prekidača ( $L_t=L_s+L_f$ )
$N$	broj skrivenih neurona u RBF veštačkoj neuronskoj mreži
$P$	broj trening uzoraka
$p_j$	ulazni signal u j-ti neuron

$R$	otpornost
$r$	korelacioni koeficijent ( <i>Pearson –Product Moment</i> )
$R_c$	otpornost kontaktinih polja RF MEMS prekidača
$R_s$	serijska otpornost
$S_{11}$	koeficijent refleksije na ulazu kada je izlaz prilagođen
$S_{12}$	koeficijent transmisije od izlaza ka ulazu
$S_{21}$	koeficijent transmisije od ulaza ka izlazu
$S_{22}$	koeficijent refleksije na izlazu kada je ulaz prilagođen
$t$	debljina mosta RF MEMS prekidača
$t_d$	debljina izolatorskog sloja kod kapacitivnog RF MEMS prekidača
$V$	napon
$V_1^+$	direktni (incidentni) talas na ulazu (prilaz 1)
$V_1^-$	reflektovani talas na ulazu (prilaz 1)
$V_2^+$	direktni (incidentni) talas na izlazu (prilaz 2)
$V_2^-$	reflektovani talas na izlazu (prilaz 2)
$V_{pi}$	napon aktivacije RF MEMS prekidača
$W$	širina signalne linije RF MEMS prekidača
$w$	širina mosta RF MEMS prekidača
$W_b$	širina mosta omskog RF MEMS prekidača
$W_g$	longitudinalni procep kod omskog RF MEMS prekidača
$w_{kj}$	težina sinpse neurona $k$
$x_k$	argument prenosne funkcije neurona $k$
$y_k$	izlazni signal neurona $k$
$Z_0$	karakteristilna impedansa signalne linije
$Z$	impedansa prekidača
$Z_s$	impedansa kapacitivnog prekidača u paralelnoj vezi
$\lambda$	standardna devijacija RBF veštačke neuronske mreže
$\eta$	stopa učenja
$\sigma^2$	standardna devijacija testiranja veštačke neuronske mreže
$\ell$	rastojanje od referentne ravni do kraja mosta prekidača
$\theta_k$	težinski koeficijent jediničnog ulaza u neuron
$\varepsilon_r$	realtivna dielektrična konstanta
$f(x)$	aktivaciona (prenosna, transfer) funkcija

# 1 UVOD

RF mikroelektromehanički sistemi (Micro-Electro-Mechanical Systems - MEMS) imaju veoma važnu ulogu u savremenim komunikacionim sistemima. RF MEMS komponente po definiciji obuhvataju RF komponente i sklopove submilimetarskih dimenzija, čije karakteristike se menjaju pokretima mehaničkih delova, a samim tim i karakteristike RF kola u koji su ugrađeni [1, 2]. Drugim rečima, RF MEMS komponente kombinuju električne i mehaničke delove proizvedene primenom tehnologije mikrofabrikacije [3]. Razvoj RF MEMS sklopova je proistekao iz potrebe za minijaturizacijom komponenti i uređaja u području mikrotalasne elektronike [4]. Mogućnost rekonfiguracije sopstvene topologije omogućila je RF MEMS komponentama rad u različitim frekvencijskim opsezima. Pored toga karakterišu se malim dimenzijama, izrazito linearnim karakteristikama i veoma malom potrošnjom u poređenju sa poluprovodničkim komponentama baziranim na PIN diodama i FET (*Field Effect Transistors*) tranzistorima [1]. Iz tog razloga, našli su široku primenu za realizaciju senzora, aktuatora, mikroprekidača, kondenzatora i kalemova. Pored toga, često su integrisani u veća kola, kao što su prekidačke matrice, pomerači faze, rekonfigurabilne antene, podesivi filtri, širokopolasni tjuneri, promenjivi prigušivači, itd [5-13]. Svakako jedan od najvećih podsticaja za inovativni razvoj i upotrebu RF MEMS komponenti i sklopova je neprekidni tehnološki napredak mobilnih telekomunikacija, a koji se ogleda u razvoju 5G mobilnih komunikacionih sistema. Takođe, razvoj i implementacija tehnologije Internet inteligentnih uređaja (*Internet of Things-IoT* i *Internet of Everything-IOE*) je oblast koja će u velikoj meri opredeliti razvoj i implementaciju RF MEMS u širokom dijapazonu telekomunikacionih komponenti i uređaja [14-16].

Ova doktorska disertacija je posvećena modelovanju RF MEMS prekidača primenom veštačkih neuronskih mreža.

Pojedinačni RF MEMS prekidači se standardno modeluju u komercijalnim elektromagnetskim (*full-wave*) i mehaničkim simulatorima [1]. Što se tiče elektromagnetskih (EM) modela, obzirom da su u pitanju 3D strukture, obično se primenjuju 3D diskretizacioni modeli bazirani na metodu konačnih razlika ili konačnih elemenata, ali kako RF MEMS prekidači imaju velike lateralne dimenzije i malu visinu, mogu se primenjivati i 2.5D softverski alati, kao i 3D planarni alati [17]. Iako svi ovi metodi obezbeđuju zadovoljavajuću tačnost, obično su ograničeni na jednu analizu za određenu strukturu RF MEMS prekidača. Navedene procedure su bazirane na kompleksnim matematičkim proračunima i vremenski su naročito zahtevne kada je potrebno izvršiti određene optimizacije razmatrane strukture. Takođe, kada je nekoliko prekidača uključeno u veće kolo, elektromagnetska analiza cele strukture postaje vremenski izuzetno zahtevna. Iz tih razloga je u simulatorima kola neophodno koristiti odgovarajuće modele prekidača. Pored elektromagnetske analize potrebno je uporedo vršiti i simulacije mehaničkih karakteristika, koje su, takođe, veoma vremenski zahtevne [18-20]. Kod modela RF MEMS prekidača često nedostaju direktne relacije između geometrijskih parametara prekidača i njegovih elektromagnetskih/mehaničkih karakteristika, koje bi bile upotrebljene pri optimizaciji karakteristika RF MEMS prekidača ili kola koja ih sadrže. Ove relacije mogu biti efikasno uspostavljene pomoću veštačkih neuronskih mreža [21- 23], na osnovu kojih će u ovoj disertaciji biti predloženi novi pristupi za modelovanje RF MEMS kapacitivnog i omskog prekidača.

Veštačke neuronske mreže (VNM) su nelinearne strukture, napravljene po ugledu na prirodni nervni sistem. U osnovi, veštačke neuronske mreže čine osnovne procesne jedinice, veštački neuroni. Veštačka neuronska mreža odlikuje se grupisanjem neurona u slojeve, pri čemu je svaki neuron iz jednog sloja povezan sa svim neuronima iz susednog sloja, a da pri tome ne postoje veze između neurona istog sloja. Karakteristika svakog veštačkog neurona je prenosna (aktivaciona) funkcija, a svakoj vezi između neurona je dodeljena težina. Osnovna odlika veštačkih neuronskih mreža je sposobnost učenja zavisnosti između dva skupa veličina [24-25]. Učenje može biti nadgledano (primenjeno u ovoj disertaciji) i nenadgledano. U procesu nadgledanog učenja, mreži se predstavljaju skupovi vrednosti ulaznih-izlaznih veličina na osnovu čega se vrši podešavanje parametra mreže (težine veza i pragovi aktivacionih funkcija neurona). Cilj obučavanja neuronske mreže je ekstrahovanje zavisnosti između ulaznih i izlaznih podataka. Po završenom postupku učenja mreža je sposobna da da korektni izlaz za sve ulaze koji su joj bili predstavljeni tokom učenja. Bitna činjenica je da dobro obučena mreža ima sposobnost generalizacije, tj. sposobnost da generiše korektan odziv i za one vrednosti ulaznih parametara koji joj nisu bili predstavljeni u toku procesa

obučavanja. Pri tome, po završenom obučavanju, struktura neuronske mreže i njeni parametri ostaju nepromenjeni. Zahvaljujući sposobnosti učenja nelinearnih zavisnosti, veštačke neuronske mreže mogu biti primenjene za rešavanje velikog broja problema. Korišćenjem neuronskih mreža mogu se formirati modeli koji su validni u širokom opsegu ulaznih parametara. Posebno su pogodne za rešavanje problema koji nisu, ili su delimično matematički definisani, a gde su poznate vrednosti ulazno-izlaznih podataka koji opisuju problem. Takođe, jednim neuronskim modelom moguće je predstaviti problem kod koga za svaku određenu oblast važenja (npr. oblast rada komponente) postoje različiti modeli. Neuronski modeli imaju jednostavnu strukturu i dobijanje njihovih odziva je praktično trenutno, jer se bazira na izvršavanju elementarnih matematičkih operacija i izračunavanju osnovnih matematičkih funkcija. Karakteristike i prednosti veštačkih neuronskih mreža opredelile su njihovu primenu kao efikasno sredstvo u postupcima modelovanja, simulacije i optimizacije u oblasti mikrotalasa [26-86].

Nakon Uvoda, u drugoj glavi ove disertacije biće date osnove mikroelektromehaničkih sistema, a kasnije će biti opisane strukture i princip rada RF MEMS prekidača. Poseban akcenat je na opisu fizičkih karakteristika RF MEMS kapacitivnog i omskog prekidača u serijskoj i paralelnoj konfiguraciji. Osnove i opšta teorija veštačkih neuronskih mreža biće opisani u trećoj glavi. Kako su veštačke neuronske mreže matematičke strukture napravljene po ugledu na neuronsku strukturu prirodnog nervnog sistema, najpre će biti opisan prirodni nervni sistem čoveka. Uvod u teoriju višeslojnih neuronskih mreža obuhvatiće još i opis njihove strukture i funkcionisanja. Posebno će biti opisana dva tipa slojevitih veštačkih neuronskih mreža, višeslojna perceptronska mreža (*Multi-Layer Perceptron-MLP*) i neuronska mreža sa radijalnom funkcijom (*Radial Base Function-RBF*), kao vrste veštačkih neuronskih mreža koje će biti korišćene u predloženim pristupima za modelovanje RF MEMS prekidača. Zatim, detaljno će biti opisan postupak obuke i testiranja veštačkih neuronskih mreža. Na kraju, biće opisane strukture neuronskih modela korišćenih za modelovanje RF MEMS prekidača, kao i postupak pripreme podataka koji se koriste u tu svrhu.

Kao što je već pomenuto, projektovanje elektronskih kola koja sadrže RF MEMS prekidače zahteva veliki broj simulacija i/ili optimizacija za koje je potrebno poznavati karakteristike prekidača. Često je potrebno vršiti simulacije i optimizaciju karakteristika kola pre nego što se prekidač realizuje. Iz tog razloga, neophodni su pouzdani modeli RF MEMS prekidača koji bi se koristili u procedurama projektovanja kola. Standardno modelovanje EM karakteristika RF MEMS prekidača vrši se u *full-wave* simulatorima [1, 17-19], dok se određivanje mehaničkih karakteristika prekidača vrši u mehaničkim simulatorima baziranim

na metodu konačnih elemenata (*Finite Element Method-FEM*) [19, 20]. Ovakve procedure zahtevaju poznavanje detaljnih fizičkih karakteristika prekidača, značajne računarske resurse i vremenski su dugotrajne, uzimajući u obzir ukupno vreme potrebno za simulaciju i optimizaciju elektronskog kola u koje se ugrađuje RF MEMS prekidač. Moguća alternativa su analitički postupci koji mogu biti upotrebljeni samo za jednostavnije konfiguracije prekidača, a koji takođe mogu zahtevati kompleksnije proračune. Druga opcija je primena modela baziranih na ekvivalentnom kolu, koji često ne daju potrebnu tačnost, pa se iz tog razloga koriste u preliminarnim analizama karakteristika kola.

Kako bi se prevazišla sva navedena ograničenja i pojednostavila procedura modelovanja, u četvrtoj glavi biće predložen alternativni način modelovanja EM i mehaničkih karakteristika RF MEMS prekidača u zavisnosti od geometrijskih dimenzija prekidača baziran na primeni neuronskih modela. Naime, najpre će biti prikazani razvijeni neuronski modeli za određivanje EM karakteristika prekidača (S-parametri i rezonantna frekvencija) u zavisnosti od frekvencije i geometrijskih parametara prekidača [74, 75, 87-90], a zatim i neuronski modeli za određivanje mehaničkih karakteristika prekidača (napon aktuacije) [91, 92]. Za obučavanje veštačkih neuronskih mreža koristiće se podaci dobijenim određenim brojem *full-wave* numeričkih simulacija karakteristika prekidača u standardnom EM simulatoru i podaci dobijeni simulacijama baziranim na metodu konačnih elemenata. Validacija predloženih modela izvršiće se direktnim upoređivanjem rezultata dobijenih modelima baziranim na veštačkim neuronskim mrežama sa rezultatima iz EM i mehaničkih simulatora, kao i sa raspoloživim merenim karakteristikama odgovarajućih realizovanih komponenti. Primenjivost razvijenih neuronskih modela biće predstavljena kroz analizu osetljivosti karakteristika RF MEMS prekidača i kroz postupak brzog i efikasnog projektovanja prekidača u skladu sa definisanim zahtevima [93-99]. Zatim biće predstavljene mogućnosti neuronskih modela zasnovanih na veštačkim neuronskim mrežama sa radijalnom baznom funkcijom u modelovanju RF MEMS prekidača, sa ciljem sagledavanja tačnosti RBF neuronskih modela u određivanju karakteristika RF MEMS prekidača. Dalje, rezultati dobijeni pomoću RBF modela biće upoređeni sa rezultatima koji se postižu sa prethodno razvijenim MLP neuronskim modelima [100]. U analizi osetljivosti karakteristika RF MEMS prekidača razvijeni modeli mogu se koristiti za sagledavanje uticaja malih promena dimenzija mosta prekidača (promene u granicama fabričkih tolerancija nastalih tokom fabrikacije komponente) na parametre rasejanja, rezonantnu frekvenciju i napon aktuacije prekidača. Druga primena razvijenih neuronskih modela obuhvata postupak brzog i efikasnog određivanja dimenzija prekidača u cilju dostizanja željenih električnih karakteristika. Na taj način je olakšan i

pojednostavljen postupak projektovanja prekidača, a analiza karakteristika prekidača vrši se u značajno kraćem vremenskom periodu [98, 99].

Treba naglasiti da se dosadašnja istraživanja drugih autora koja su prikazana u postojećoj literaturi odnose na mogućnosti primene veštačkih neuronskih mreža za modelovanje određenih karakteristika RF MEMS prekidača sa pravougaonim oblikom mosta [64, 66, 72, 73]. U ovoj disertaciji biće modelovane karakteristike RF MEMS prekidača koji imaju kompleksniju strukturu i oblik mosta prekidača.

Određivanje električnih karakteristika RF MEMS prekidača često se vrši korišćenjem modela baziranih na ekvivalentnom kolu u simulatoru elektronskih kola, što je vremenski manje zahtevna procedura od *full-wave* simulacija. Vrednosti elemenata ekvivalentnog kola određuju se postupkom optimizacije. Međutim i takav pristup je složen postupak jer u slučaju kada se razmatra veći broj komponenti čije se dimenzije razlikuju, postupak određivanja elemenata ekvivalentnog kola se ponavlja za svaku kombinaciju vrednosti dimenzija.

U cilju povećanja efikasnosti modelovanja, u petoj glavi disertacije biće predložena upotreba hibridnih modela RF MEMS prekidača. Predloženi hibridni modeli koriste VNM za veoma efikasno generisanje vrednosti elemenata ekvivalentnog kola RF MEMS prekidača (otpornost i induktivnost) za zadate lateralne dimenzije mosta. Drugim rečima, pridruživanjem razvijenih neuronskih modela razmatranom ekvivalentnom kolu dobija se skalabilni model, koji se bez ikakvih dodatnih izmena može koristiti za prekidače različitih dimenzija. Validacija predloženih modela biće izvršena kroz proveru tačnosti S-parametara između vrednosti dobijenih na osnovu predloženog hibridnog modela i vrednosti koje su dobijene u *full-wave* simulacijama [101].

Pored modelovanja karakteristika RF MEMS prekidača, u praksi bi bilo od značaja razviti i pouzdan model koji bi vršio predikciju dimenzija mosta prekidača za zadate vrednosti EM i mehaničke karakteristike prekidača. U konkretnom slučaju optimizacija podrazumeva određivanje dimenzija mosta RF MEMS prekidača za zadate vrednosti rezonantne frekvencije i/ili napona aktivacije. Standardan proces optimizacije parametara RF MEMS prekidača je vremenski veoma zahtevan i složen proces, naročito u slučajevima optimizacije RF MEMS prekidača sa složenom strukturom mosta prekidača. Iz tog razloga, potrebno je pronaći pouzdan, efikasan ali i jednako tačan model, koji bi vršio optimizaciju dimenzija prekidača za kratko vreme. Uzimajući navedeno u obzir, biće predložen postupak razvoja inverznih neuronskih modela u cilju prevazilaženja složenih i vremenski zahtevnih optimizacionih postupaka u standardnim simulatorima, odnosno modela koji vrše direktno određivanje geometrijskih parametara prekidača bez postupka optimizacije.



U šestoj glavi doktorske disertacije biće opisan postupak razvoja inverznih neuronskih modela EM karakteristika RF MEMS prekidača. Kako bi se obezbedila potrebna tačnost inverznih neuronskih modela, za njihovu obuku potreban je trening skup sa velikim brojem odgovarajućih trening podataka. Navedeni trening podaci obezbediće se direktnim neuronskim modelima koji su opisani u četvrtoj glavi. Biće opisan postupak razvoja dve vrste inverznih neuronskih modela. Prva vrsta inverznog neuronskog modela podrazumeva određivanje lateralnih dimenzija prekidača zasebno na osnovu zadate vrednosti električne karakteristike prekidača (rezonantna frekvencija) ili zadate vrednosti mehaničke karakteristike prekidača (napon aktivacije) [23, 89, 102]. Druga vrsta inverznog modelovanja istovremeno razmatra električne i mehaničke karakteristike prekidača, što je proisteklo iz činjenice da dimenzije mosta prekidača istovremeno utiču na promene EM i mehaničkih karakteristika [103]. Na kraju glave biće predstavljena praktična primenjivost predloženih inverznih neuronskih modela u projektovanju i analizi RF MEMS prekidača [98, 99, 104].

Prethodno je navedeno da modeli koji baziraju na ekvivalentnim kolima su brže simulacione procedure u odnosu na *full-wave* simulacije. Međutim, ukoliko se analiziraju različite dimenzije i strukture mosta prekidača, potrebno je izvršiti veći broj ponavljanja procedura za određivanje elemenata ekvivalentnog kola, što je vremenski veoma zahtevan postupak. U cilju prevazilaženja višestrukih optimizacionih postupaka koji se sprovode u procesu određivanja elemenata ekvivalentnog kola RF MEMS prekidača, u sedmoj glavi biće predloženo alternativno rešenje, odnosno hibridni pristup inverznog modelovanja, koji predstavlja kombinaciju korišćenja inverznih neuronskih modela sa modifikacijom hibridnog modela baziranog na ekvivalentnom kolu. Ovakav hibridni model, pored određivanja dimenzija prekidača, određuje i elemente ekvivalentnog kola. Dobijene vrednosti elemenata ekvivalentnog kola kasnije se mogu koristiti za simulacije kola koji sadrži razmatrani RF MEMS prekidač. Predloženi hibridni pristup za inverzno modelovanje RF MEMS prekidača nije moguće koristiti za istovremeno određivanje obe lateralne dimenzije zbog činjenice da različite kombinacije lateralnih dimenzija mosta prekidača mogu da daju istu vrednost rezonantne frekvencije. Iz tog razloga, biće razvijene dve varijante hibridnog pristupa kako bi se sagledale mogućnosti zasebnog modelovanja za obe lateralne dimenzije mosta prekidača [105, 106]. Pored toga biće predložen i hibridni pristup u kojem se veštačkom neuronskom mrežom određuju lateralne dimenzije u zavisnosti od induktivnosti RF MEMS kapacitivnog prekidača [107]. Validacija predloženih hibridnih inverznih modela biće izvršena na način da se vrednosti određene pomoću neuronskih modela pridruže odgovarajućim elementima ekvivalentnog kola i iskoriste za simulaciju S-parametara. Tako dobijene vrednosti S-

parametara biće upoređene sa S-parametrima koji su određeni u ADS momentum simulacijama za iste dimenzije prekidača.

U osmoj glavi doktorske disertacije biće izvedeni zaključci o primeni veštačkih neuronskih mreža u modelovanju RF MEMS prekidača i istaknuti najvažniji doprinosi doktorske disertacije. U devetoj, poslednjoj glavi, biće dat spisak korišćene literature i spisak publikacija u kojima su objavljeni rezultati istraživačkog rada prikazanog u okviru ove disertacije.

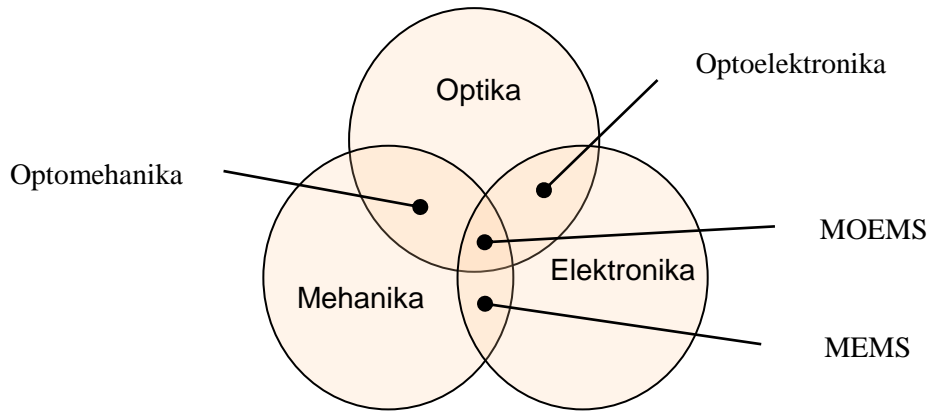
## 2 RF MEMS PREKIDAČI

### 2.1 OSNOVE MIKROELEKTROMEHANIČKIH SISTEMA

Mikroelektromehanički sistemi (*Micro-Electro-Mechanical Systems* - MEMS) su mehanički ili elektromehanički sistemi (sklopovi i strukture) koje pokreće električna energija [1, 2]. Sledeća definicija, MEMS opisuje kao uređaje mikro dimenzija koji kombinuju električne i mehaničke komponente, a koji su proizvedeni primenom tehnologije mikrofabrikacije [3]. Ovi sistemi mogu da registruju, kontrolišu i aktiviraju mehaničke procese na mikronivou, koje dalje pojedinačno ili u nizu generišu u efekte vidljive na makro nivou. Takođe, MEMS se može definisati kao uređaji koji vrše funkciju prenosa signala između dva (ili više) odvojena fizička dela posredstvom mehaničkog pokreta [11, 12].

MEMS su razvijeni kao logičan nastavak razvoja mikroelektronike i integrisanih kola. Pri tome, pravac razvoja MEMS je kanalisala potreba za minijaturizacijom komponenti i sklopova, čime se sa jedne strane umanjuju troškovi i potrebni materijali, a sa druge značajno se uvećava primenljivost i mogućnost implementacije u različitim uređajima i komponentama. Drugim rečima, smanjenjem mase i dimenzija stvaraju se uslovi za ugradnju u uređaje u koje nije moguće instalirati tradicionalne komponente. Za električna kola je karakteristično da su čvrste i kompaktne strukture, dok MEMS strukture imaju šupljine, kanale, konzole i mostove [4].

Dakle, svaki deo u nazivu za MEMS ima poseban smisao: mikro (strukture malih dimenzija koje se dobijaju mikrofabrikacijom), elektro (električni signal/kontrola), mehanički (mehanička funkcionalnost), sistemi (komponente, strukture, uređaji, sistemi). Na Slici 2.1 dat je ilustrativni prikaz međusobnog prožimanja optike, mehanike i elektronike koje su osnova za razvoj MEMS-a, mikro-opto-elektro-mehaničkih sistema (MOEMS), optoelektronike i optomehanike [4].



Slika 2.1 Osnovne tehnike (optika, mehanika i elektronika) za razvoj MEMS, MOEMS, optoelektronike i optomehanike

MEMS čine mehanički elementi, senzori, aktuatori, električni i elektronski uređaji koji su smešteni na supstratu silicijuma (čip), te se mogu direktno implementirati na elektronske komponente. Senzori realizovani u MEMS tehnologiji sakupljaju informacije iz okoline merenjem mehaničkih, toplotnih, bioloških, hemijskih, optičkih i magnetnih efekata [3]. Elektronskim kolima procesiraju se informacije i uz mogućnost donošenja odluka usmeravaju aktuatora da svrsishodno željenom odzivu reaguju prema okolini (na primer pomeranjem, pozicioniranjem, regulisanjem, pumpanjem i/ili filtriranjem). Veličina MEMS komponente iznosi od 1  $\mu\text{m}$  do 100  $\mu\text{m}$ , dok je sam MEMS uređaj veličine od 20  $\mu\text{m}$  do 1 mm. Tipovi MEMS uređaja mogu da variraju od relativno jednostavnih - bez pokretnih delova, do izuzetno kompleksnih elektromehaničkih sistema sa mnogo pokretnih elemenata koje kontroliše integrisana mikroelektronika.

## 2.2 ISTORIJAT I PRAVCI DALJEG RAZVOJA MEMS-A

MEMS komponente se razvijaju od 1970. godine za primene poput senzora pritiska i temperature, akcelometara, gasnih hromatografa i drugih senzorskih uređaja. Prva demonstracija rada MEMS prekidača za niskofrekvencijsku primenu izvršena je 1980. godine, ali je duži vremenski period ostala u domenima laboratorijskog istraživanja. Tek 1990. i 1991. godine, uz podršku DARPA (*Defense Advanced Research Projects Agency*), razvijen je prvi MEMS prekidač za primenu u oblasti mikrotalasa. Tada su po prvi put demonstrirane odlične karakteristike MEMS prekidača na frekvencijama do 50 GHz, čime je ostvaren napredak u odnosu na postojeće elektronske komponente slične namene. Kompanije *Rockwell Science* i

*Center and Texas Instruments* razvile su 1995. godine MEMS prekidače sa odličnim karakteristikama. *Rockwell* prekidač bio je kontaktnog tipa metal na metal pogodan za primenu do 60 GHz, dok je *Texas Instruments* prekidač bio tipa kapacitivnog kontakta za primenu u frekventijskom opsegu od 10 do 120 GHz. Nakon toga, više od 30 kompanija bavi se istraživanjima u oblasti MEMS tehnologije, uključujući i gigante kako što su: *Broadcom*, *Robert Bosch*, *Texas Instruments*, *STMicroelectronics*, *Qorvo*, *Hewlett Packard*, *Knowles Electronics*, *NXP Semiconductors N.V*, *Murata Manufacturing* i *Samsung*. U poslednjoj deceniji, razvoj MEMS prekidača ostvario je ogroman rast usled potrebe za elektronskim komponentama koje mogu da obezbede rad do visokih graničnih frekvencija (do 40 THz) uz veoma mala unutrašnja slabljenja komponente [1].

Tržište MEMS uređaja predstavlja deo velikog tržišta poluprovodničkih čipova, a to je trenutno tržište koje pokazuje najbrži rast. U početku je automobilska industrija bila glavni pokretač tržišta za MEMS uređaje, da bi se perspektiva njihovog razvoja preusmerila na novije oblasti primene (oblast medicine, telekomunikacija i proizvoda široke potrošnje) a koje imaju izuzetno značajan uticaj na tržište MEMS-a. Veliki zahtevi tržišta za elektronskim uređajima najnovije generacije, kao što su inteligentni telefoni (*smart phones*) i tablet uređaji utiču na porast proizvodnje i razvoj MEMS-a.

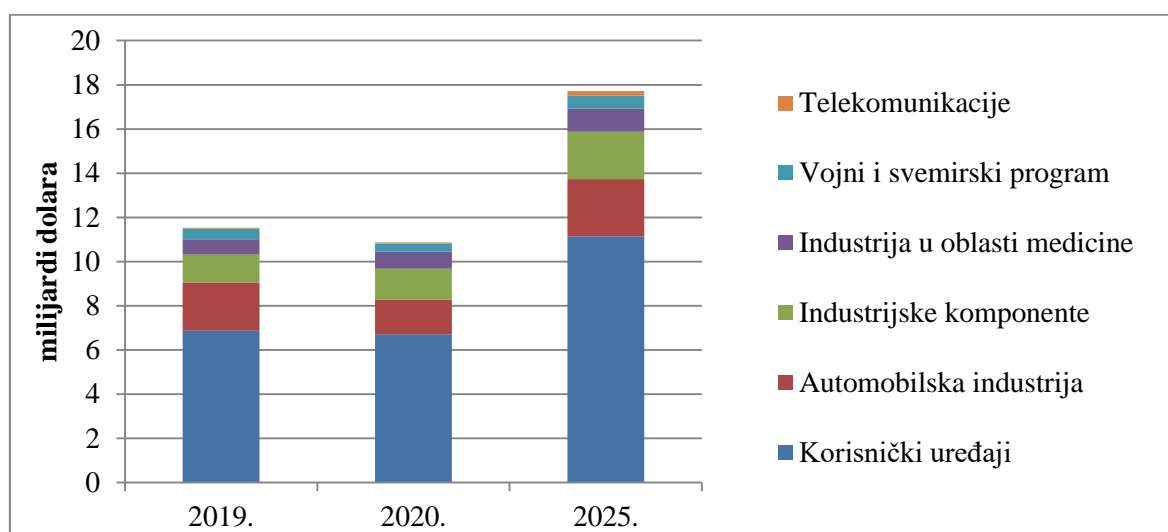
Primena MEMS uređaja može se grupisati u sledeće industrijske grane i oblasti tehnološkog razvoja [1]:

- automobilska industrija (u sistemima vazdušnih jastuka, bezbednosnim sistemima u vozilu, svetlima za kočnice, uređajima za pozicioniranje prednjih farova, detektovanje proklizavanja, automatsko zaključavanje, MEMS ogledala u LIDAR tehnologijama),
- proizvodi široke potrošnje (u aparatima i spravama za sportske treninge, perifernim uređajima za računar, navigacionim uređajima za automobile i ličnu upotrebu, glavama štampača sa MEMS komponentom u štampačima sa visokom rezolucijom, mobilni telefoni, iPhone, iPad, iPod),
- industrija (u uređajima za detektovanje zemljotresa, za regulaciju/isključivanje gasa, za testiranje ispravnosti aparata i mašina, registrovanje udara i potresa),
- vojna industrija (u uređajima u tenkovima, avionima, radarima, opremi za vojnike, inteligentnoj municiji, merači ubrzanja, žiroskopi i elektronski kompas),
- medicina, biomedicina, biotehnologija i uređaji za praćenje promena u životnoj okolini (u koje spadaju i biočipovi za detektovanje opasnih hemijskih i bioloških supstanci, mikrosistemi za DNK identifikaciju, mikrofabrikovani STM uređaji, mikrosistemi za sortiranje i selekciju lekova i bio-MEMS uređaji u medicini i

tehnologijama bliskim medicini (od tzv. „laboratorije na čipu” do biosenzora i hemosenzora, uređaji za praćenje bioloških parametara),

- vazduhoplovstvo i istraživanje svemira (to su merači ubrzanja i žiroskopi za unutrašnju navigaciju, senzori za pritisak, radiofrekvencijski prekidači i filtri za komunikaciju, harmonijska ogledalca za optiku, mikro-energetski izvori i turbine, uređaji za kontrolu pokreta i položaja, bio-reaktori i bio-senzori, uređaji sa mikrofluidima, uređaji sa toplotnom kontrolom, atomski satovi).

U 2019. godini tržište MEMS uređajima je dostiglo vrednost od 11.5 milijardi dolara [13]. Procena je da će u 2020. godini tržište MEMS komponentama i uređajima zbog negativnog uticaja ekonomske krize doživeti manji pad i iznosiće 10.9 milijardi dolara. Međutim, procene su da će MEMS tržište do 2025. godine ostvarivati godišnji rast od 7.4%, kada će iznositi 17.7 milijardi dolara. Iskazano u broju proizvedenih jedinica MEMS komponenti, godišnji rast će iznositi uvećanje od 11.9% novoprodučenih jedinica. Najznačajniji uticaj na rast proizvodnje MEMS komponenti ispoljiće njihova primena u oblasti korisničkih uređaja. Očekuje se da će tržište MEMS komponenti u oblasti korisničkih uređaja do 2025. godine ostvariti ukupnu stopu godišnjeg rasta od 8.4% i iznosiće 11.14 milijardi dolara. Konstantan godišnji rast MEMS komponenti se ostvaruje i u oblasti telekomunikacija. Procena je da će se do 2025. godine u oblasti telekomunikacija, MEMS tržište ostvariti ukupnu stopu godišnjeg rasta od 33%. Na Slici 2.2 prikazana je projekcija razvoja MEMS tržišta u glavnim oblastima industrije i tehnološkog razvoja u kojima se ugrađuju MEMS komponente i uređaji [13].



Slika 2.2 MEMS tržište sa projekcijom razvoja do 2025. godine

Svakako jedan od najvećih podsticaja na inovativni razvoj i upotrebu RF MEMS komponenti i sklopova ispoljiće tehnološki napredak mobilnih telekomunikacija, kroz razvoj 5G mobilnih komunikacionih sistema. Sledeća oblast tehnološkog razvoja koja će neminovno i u značajnoj meri usloviti razvoj RF MEMS komponenti i sklopova je razvoj i implementacija tehnologije Internet inteligentnih uređaja (*Internet of Things-IoT* i *Internet of Everything-IoE*).

RF-MEMS komponente su prepoznate kao ključna tehnologija u budućoj tehnologiji mobilnih komunikacija. Protokoli budućih 5G mobilnih komunikacionih sistema postavili su zahteve u vidu visoke operativne frekvencije (u opsegu od 6 GHz do 70 GHz) i velike mogućnosti rekonfiguracije komponenti kako bi se pokrili različiti servisi koje će pružati 5G mreža. Sa druge strane, zahteva se povećanje hardverske kompaktnosti i smanjenje potrošnje električne energije. Kako bi se odgovorilo navedenim izazovima, neophodno je unaprediti karakteristike pasivnih komponenti, u čemu je RF MEMS tehnologija prepoznata kao ključna opcija koja može odgovoriti postavljenim zahtevima za razvoj 5G mobilnih telefona i baznih stanica [14, 15].

Perspektiva primene RF MEMS tehnologije u budućim konfiguracijama Internet inteligentnih uređaja (*IoT, IoE, Tactile Internet*) i 5G mobilnih komunikacionih sistema ogleda se u unapređenju sledećih RF-MEMS komponenti i sklopova [16]:

- Širokopolasni prekidači i prekidačke jedinice sa malim slabljenjem, velikom otpornošću, veoma malim međukanalnim uticajem i sa mogućnostima rada u frekvencijskom opsegu od 23 GHz do 70 GHz;
- Podesivi filteri sa visokim slabljenjem signala van propusnog opsega;
- Širokopolasni tjuneri sa promenljivom impedansom;
- Podesivi prigušivači sa ravnom karakteristikom u intervalima u okviru frekvencijskog opsega 60-70 GHz;
- Širokopolasni pomerači faze;
- Minijaturne antene i antenski nizovi.

## 2.3 UPOREDNE KARAKTERISTIKE MEMS PREKIDAČA SA POLUPROVODNIČKIM PREKIDAČIMA

U RF i mikrotalasnim kolima u najvećoj meri koriste se standardni GaAs (galijum-arsenidni) FET tranzistori (*Field Effect Transistor*) i PIN diode kao prekidači. Nova generacija prekidača, kao što su RF MEMS prekidači, pretenduje da potisne dosadašnje standardne komponente [9]. Preporuke za njihovu upotrebu su njihove karakteristike, koje ih kvalifikuju kao komponente koje imaju male gubitke, malu potrošnju energije, dobru izolaciju i linearne karakteristike. Usporedne karakteristike RF MEMS prekidača, GaAs PIN diodnih prekidača i tranzistorskog prekidača date su u Tabeli 2.1.

Tabela 2.1 Usporedni pregled karakteristika MEMS, PIN i FET prekidača [1]

Parametar	MEMS	PIN Dioda	FET
Napon (V)	20-80	$\pm 3-5$	3-5
Struja (mA)	0	3-20	0
Potrošnja (mW)	0.05-0.1	5-100	0.05-0.1
Vreme odziva	1-300 $\mu$ s	1-100 ns	1-100 ns
$C_{up}$ (serijski) (fF)	1-6	40-80	70-140
$R_s$ (serijski) ( $\Omega$ )	0.5-2	2-4	4-6
Odnos kapacitivnosti ( $C_{up} / C_{down}$ )	40-500	10	-
Granična frekvencija (THz)	20-80	1-4	0.5-2
Izolacija (1-10 GHz)	Veoma velika	Velika	Srednja
Izolacija (10-40 GHz)	Veoma velika	Srednja	Mala
Izolacija (60-100 GHz)	Velika	Srednja	0
Slabljenje (1-100 GHz) (dB)	0.05-0.2	0.3-1.2	0.4-2.5
Snaga (W)	<1	<10	<10

Preciznu komparaciju karakteristika prekidača otežava široki opseg snaga koje se koriste u RF komponentama. U novije vreme, diode i tranzistori lako mogu da odgovore primeni u uređajima koji rade sa velikim snagama. Sa druge strane, snaga značajno utiče na otpornost prekidača, unutrašnje slabljenje, brzinu prekidanja i potrošnju energije. MEMS prekidači sa svojom izuzetno malom kapacitivnošću u *up-state* položaju  $C_{up}$  (serijski prekidači) i veoma velikim odnosom kapacitivnosti (prekidači sa kapacitivnim kontaktom), nude daleko bolje karakteristike u odnosu na diodne i tranzistorske prekidače za ugradnju u uređaje male i srednje snage.

Prednosti MEMS prekidača u odnosu na PIN diodne i FET prekidače su [1, 5]:

- Veoma mala potrošnja struje. Elektrostatička aktucija prekidača zahteva 30-80 V, a da pri tome ne troši električnu energiju, što utiče na veoma malo rasipanje snage



(10-100 nJ po prekidačkom ciklusu). Sa druge strane, termičko-magnetni prekidači su veći potrošači električne energije sve dok se prekidač akcijom ne dovede u spuštenu položaj. Navedena karakteristika naročito je značajna kod izbora RF MEMS prekidača za ugradnju u satelitske sisteme, antene promenljive konfiguracije ili fazne nizove koji se sastoje od više hiljada elemenata.

- Visoka izolacija: RF MEMS prekidači sa metalnim kontaktima proizvode se sa vazдушnim međuprostorima, usled čega imaju veoma malu kapacitivnost u stanju isključenosti - *off state* (2-4 fF), a što ih čini veoma dobrim izolatorom na frekvencijama od 0.1 GHz do 60 GHz. Takođe i kapacitivni prekidači sa odnosom kapacitivnosti od 60 do 160, obezbeđuju odličnu izolaciju za frekvencije od 8 GHz do 100 GHz.
- Veoma malo slabljenje: RF MEMS prekidači sa metalnim kontaktima i kapacitivni prekidači imaju unutrašnje slabljenje od 0.1 dB na frekvencijama do 100 GHz.
- Linearnost i intermodulacioni produkti: MEMS prekidači su izuzetno linearni uređaji što je od presudnog značaja na nivo intermodulacionih produkata u prekidačkim operacijama. Njihova karakteristika je za 30-50 dB bolja od PIN ili FET prekidača.
- Niska cena: RF MEMS prekidači se proizvode mikromašinskim procesima na podlogama od kvarca, pireksa, LTCC (*Low Temperature Co-fired Ceramic*), silicijuma ili GaAs.

Pored niza prednosti, RF MEMS prekidači imaju i određene nedostatke [7] :


- Relativno mala brzina: Brzina prekidanja kod većine elektrostatičkih MEMS prekidača iznosi od 2  $\mu$ s do 40  $\mu$ s, a kod termičkih/magnetskih prekidača od 200  $\mu$ s do 3 ms. Savremeni komunikacioni i radarski sistemi zahtevaju prekidače sa mnogo bržim prekidačkim procesom.
- Rad pri visokom naponu ili velikoj struji: Elektrostatički MEMS prekidači zahtevaju 30-80 V za pouzdan operativni rad, što zahteva ugradnju čipa za konverziju napona. Termički/magnetski prekidači za akciju koriste napone od 2 V do 5 V, ali zahtevaju struju akcije od 10 mA do 100 mA.
- Maksimalna snaga: Većina MEMS prekidača ne može da podnese snage veće od 200 mW. Izuzeci su *Terravicta* i *Raytheon* prekidači sa karakteristikom pouzdanog rada sa snagom do 500 mW. U praksi nisu razvijeni MEMS prekidači koji obezbeđuju visoku pouzdanost za snage od 1 W do 10 W.

- Pouzdanost: Pouzdanost MEMS prekidača starije konstrukcije je u granicama od 0.1 do 40 milijardi ciklusa. Međutim, mnogi sistemi zahtevaju pouzdanost prekidača za 20-200 milijardi ciklusa. Takođe, vremenski period (u godinama) pouzdanosti prekidača još nije definisan. Danas je poznato da su kapacitivni prekidači ograničeni dielektričnim promenama koje nastaju u akucionim elektrodama. Prekidači sa metalnim kontaktima limitirani su problemima interfejsa između metalnih kontakata koji mogu biti ozbiljniji kod malih sila kontakta (kod elektrostatičkih dizajna, sila kontakta je u granicama 40-100  $\mu\text{N}$  po kontaktu). Pored pouzdanosti i pakovanje je ograničavajući problem u bržem razvoju RF MEMS prekidača, te su upravo oni predmet intenzivnog naučnog istraživanja.
- Ugradnja (pakovanje): MEMS prekidači zahtevaju uslove ugradnje u inertnoj atmosferi (Azot, Argon, itd.), uz veoma malu vlažnost, i na kraju hermetičko ili skoro hermetičko pakovanje. Hermetičko pakovanje trenutno uzrokuje veće troškove izrade, a sama tehnika pakovanja može negativno uticati na pouzdanost MEMS prekidača.
- Cena: Iako MEMS prekidači imaju potencijalno veoma malu cenu izrade, u razmatranju cene potrebno je uzeti u obzir cene pakovanja i ugradnje visokonaponskog čipa. Sa druge strane, teško je dostići aktuelnu cenu PIN ili FET prekidača od 0.3 - 0.6 USD. Iz tog razloga, prvobitna upotreba MEMS prekidača bila je usmerena na komercijalne uređaje visokih performansi i satelitske sisteme.

## **2.4 KONFIGURACIJA RF MEMS PREKIDAČA**

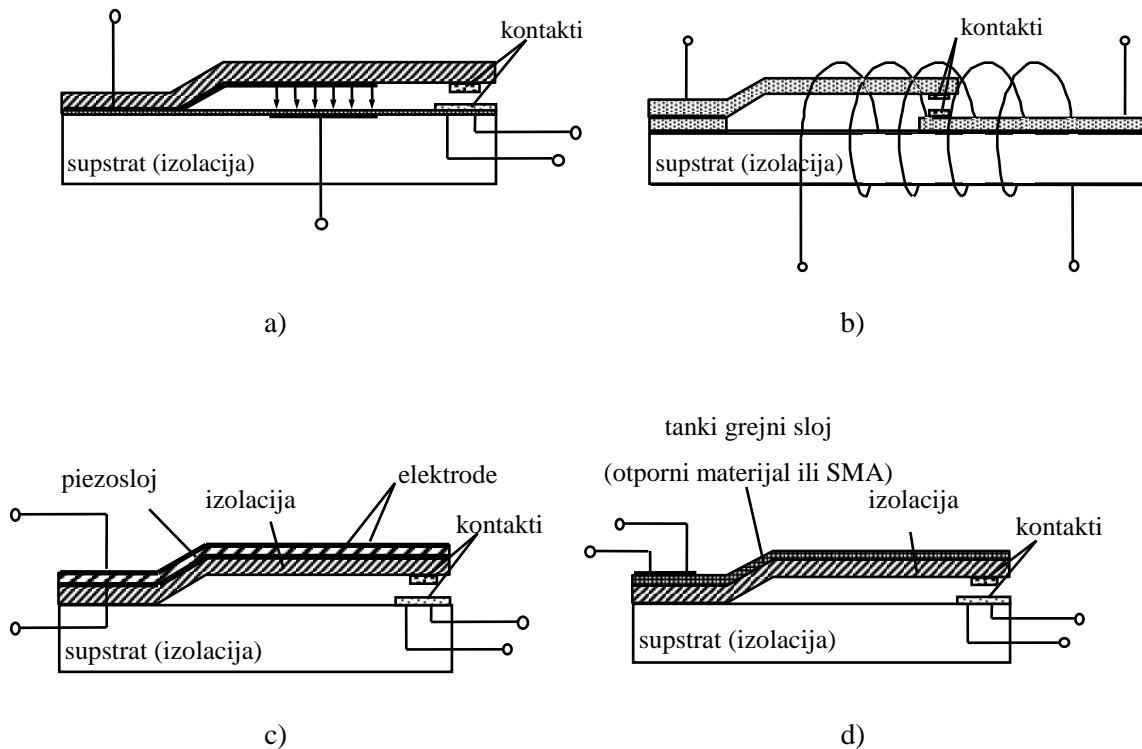
MEMS prekidači su komponente i/ili sklopovi mikro veličine koji mehaničkim pokretima otvaraju, odnosno kratko spajaju električna kola na RF prenosnim (signalnim) linijama. RF MEMS prekidači su specifični mikro-mehanički prekidači projektovani za operativni rad u frekvencijskom opsegu od 0.1 GHz do 100 GHz. RF MEMS prekidači mogu biti izrađeni u nekoliko različitih konfiguracija. Osnovna podela je izvršena u zavisnosti od topologije signalne linije (serijski ili paralelni prekidač), mehanizma akcije, vrste kontakta (kapacitivni ili omski) i strukture mosta prekidača (most sa osloncem na oba kraja, *fixed-fixed beam* ili most u obliku jednostrane konzole, *cantilever beam*) [1, 5, 12].

U elektronskim sklopovima koji koriste jednosmernu struju i naizmeničnu struju nižih frekvencija (do 60 GHz) koriste se omski RF MEMS prekidači, dok su kapacitivni RF MEMS prekidači pokazali bolje karakteristike na višim frekvencijskim opsezima (do 120 GHz). Uprošćeni poprečni preseki omskog i kapacitivnog RF MEMS prekidača dati su u Slici 2.3.



Slika 2.3 RF MEMS prekidači u odnosu na vrstu kontakta: a) omski i b) kapacitivni

RF MEMS prekidač ima dva osnovna dela: akciju (mehaničku) sekciju i električnu sekciju. Sila potrebna za mehanički pokret prekidača može se ostvariti elektrostatičkim, magnetostatičkim, piezoelektričnim ili termičkim efektom (Slika 2.4).



Slika 2.4 RF MEMS prekidači sa različitim tipovima mehaničkih kontakata: a) elektrostatički, b) elektromagnetni, c) piezoelektrični, d) elektrotermički

Fizički hod prekidača zavisi od konstrukcije prekidača i može biti vertikalni ili bočni. Dostignuti razvoj elektrostatičkih, termičkih i elektromagnetnih RF MEMS prekidača (proizvedeni u *wafer-scale* tehnici) obezbeđuju visoku pouzdanost (od 100 miliona do 60 milijardi ciklusa) za rad u frekvencijskom opsegu od 0.1 GHz do 100 GHz [1]. Uzimajući u obzir sve moguće konfiguracije MEMS prekidača, proističe da se jedan prekidač može izraditi u najmanje 32 različite varijante, odnosno kombinovanjem različitih aktacionih mehanizama, kontakata i implementacija u strujnom kolu. U Tabeli 2.2 dat je prikaz osnovnih karakteristika različitih konfiguracija RF MEMS prekidača [1].

Tabela 2.2 Karakteristike različitih konfiguracije MEMS komponenti

Mehanizam aktucije						
	Napon (V)	Struja (mA)	Snaga (mW)	Veličina	Vreme prekidanja ( $\mu$ s)	Sila kontakta ( $\mu$ N)
Elektrostatički	20-80	0	0	mala	1-200	50-1.000
Termalni	3-5	5-100	0-200	velika	300-10.000	500-4.000
Magnetnostatički	3-5	20-150	0-100	srednja	300-1.000	50-200
Piezoelektrični	3-20	0	0	srednja	50-500	50-200

Fizički hod	
Vertikalni	Utiče na smanjenje veličine komponente
Bočni	Utiče na povećanje veličine komponente

Vrsta kontakta	
Metal na metal (omski)	Za jednosmernu i naizmjeničnu struju do 60 GHz
Kapacitivni	Za naizmjenične struje od 6 do 120 GHz

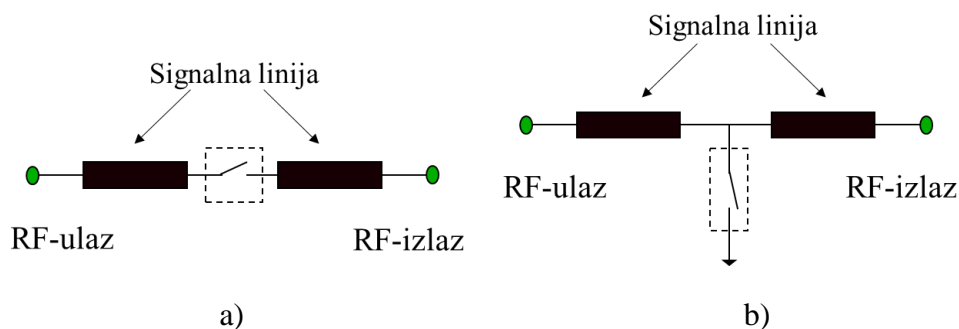
Konfiguracije	
Serijska	<ul style="list-style-type: none"> <li>- Jednosmerna i naizmjenična struja do 50 GHz, sa metal na metal kontaktom; malom kapacitivnošću u podignutom položaju (mala kapacitivnost u podignutom položaju mosta)</li> <li>- Naizmjenična struja od 10 do 50 GHz, sa kapacitivnim kontaktom i malom kapacitivnošću u podignutom položaju (mala kapacitivnost u podignutom položaju mosta)</li> </ul>
Paralelna	<ul style="list-style-type: none"> <li>- Jednosmerna i naizmjenična struja do 60 GHz, sa metal na metal kontakt i malom induktivnošću sa uzemljenjem,</li> <li>- Naizmjenična struja od 10 do 200 GHz sa kapacitivnim kontaktom i malom induktivnošću sa uzemljenjem.</li> </ul>

Elektrostatička aktucija je najčešća tehnika koja se koristi u izradi MEMS prekidača zahvaljujući maloj veličini elektrode, upotrebi tankog sloja, relativno malom vremenu prekidanja, veoma maloj potrošnji električne struje (približna nuli), odgovarajućoj sili ostvarivanja kontakta (50-200 mN) i mogućnosti napajanja prekidača korišćenjem visoko rezistivne linije za napajanje. Međutim, ovakvi prekidači u mnogim slučajevima zahtevaju

napon aktivacije od 30 do 80 V, usled čega je neophodna upotreba CMOS pojačavača za pojačanje kontrolnog napona na ulazu od 3 V do 5 V na potrebni iznos napona aktivacije. Kod mnogih rešenja, termička aktivacija je povezana sa elektrostatičkim (naponskim) stanjem, dok je magnetnostatička aktivacija (struja u kalemu) povezana sa konstantnim magnetnim poljem. Oba slučaja odlikuje veoma mala potrošnja električne energije u aktivnom režimu rada prekidača. U procesu fabrikacije MEMS prekidača ugrađuju se signalne linije koje se odlikuju malom otpornošću (zlato ili aluminijum), pa se na taj način smanjuje potrebna struja za prekidačke cikluse. Signalne linije male otpornosti se povezuju sa mikrotalasnim signalnim linijama, usled čega se posebna pažnja posvećuje projektovanju kompleksnih prekidačkih mreža koje sadrže veliki broj prekidača i prednaponskih linija.

## 2.5 RF MEMS PREKIDAČI ZA PRIMENU U TELEKOMUNIKACIJAMA

U telekomunikacijama se najčešće koriste paralelni i serijski RF MEMS prekidači (Slika 2.5).




Slika 2.5 Konfiguracije RF MEMS prekidača u odnosu na signalnu liniju:

a) serijska konfiguracija, b) paralelna konfiguracija

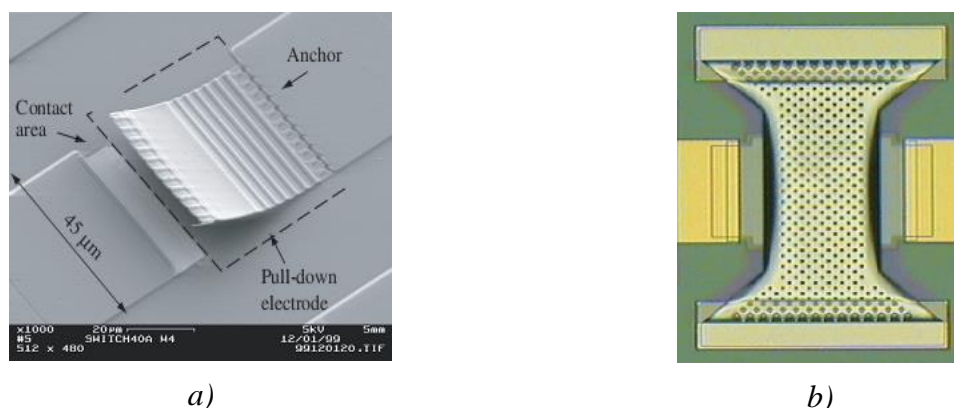
Idealni serijski prekidač dovodi do otvorenog strujnog kola na signalnoj liniji kada nije prisutan napon aktivacije (podignuti položaj mosta - *up state*). U suprotnom, dovodi do kratkog spoja kada je prisutan napon aktivacije (spušteni položaj mosta - *down state*). Takođe, idealni serijski prekidač ima beskonačnu otpornost u podignutom položaju mosta i nulto unutrašnje slabljenje u spuštenom položaju mosta. MEMS serijski prekidači imaju široku primenu u frekvencijskom opsegu od 0.1 GHz do 40 GHz. Pri tom obezbeđuju visoku izolaciju u RF frekvencijskom opsegu, od -50 dB do -60 dB na frekvenciji od 1 GHz i od -20

dB do -30 dB na frekvenciji od 20 GHz. U položaju spuštenog mosta, odlikuju se veoma malim unutrašnjim slabljenjem, od 0.1 dB do 0.2 dB na frekvencijama 0.1-40 GHz [1].

Paralelni prekidači vezuju se paralelno između signalne linije i uzemljenja. U zavisnosti od prisustva napona aktivacije, prekidač spaja signalnu liniju sa uzemljenjem ili u suprotnom ne ostvaruje kontakt sa njom. Stoga, idealni paralelni prekidač ima nultu unutrašnje slabljenje u odsustvu napona aktivacije (most u podignutom položaju) i beskonačnu otpornost kada je doveden napon aktivacije (most u spušenom položaju). Karakteristike kvalitetnog paralelnog kapacitivnog prekidača su: veoma malo unutrašnje slabljenje od 0.04 dB do 0.1 dB na frekvencijama od 5 do 50 GHz (podignut most) i prihvatljivom otpornošću od preko -20 dB takođe za frekvencije od 10 GHz do 50 GHz (most u spušenom položaju). Primeri različite realizacije RF MEMS serijskih i paralelnih prekidača dati su u Slikama 2.6. i 2.7 [7].




Slika 2.6 Serijski prekidači: a) analogni prekidač sa metalnim kontaktima, b) Rockwell Scientific prekidač



Slika 2.7 Paralelni MEMS prekidači: a) Lincoln Labs, b) Raytheon prekidač

### 2.5.1 Opis fizičkih karakteristika MEMS kapacitivnog prekidača u paralelnoj konfiguraciji

Tipičan MEMS kapacitivni prekidač u paralelnoj vezi prikazan je na Slici 2.8 [1]. Most prekidača se nalazi na rastojanju  $g$  iznad izolatorskog sloja na signalnoj liniji. Dimenzije mosta su: dužina  $L$ , širina  $w$  i debljina  $t$ . Širina signalne linije je  $W$ . Supstrat se izrađuje od silicijuma, GaAs, aluminijum trioksida, kvarca ili u LTCC tehnologiji.



Slika 2.8 MEMS paralelni prekidač u poprečnoj i vertikalnoj ravni sa odgovarajućim strujnim kolom

MEMS kapacitivni prekidač može biti realizovan u tehnologiji koplanarnog talasovoda (*coplanar-waveguide*, CPW) ili u mikrostrip tehnologiji. U CPW konfiguraciji kotva (*anchor*) most MEMS prekidača je povezana sa CPW ravni. Kod mikrostrip konfiguracije jedna kotva je povezana sa  $\lambda/4$  otvorenim stabom što rezultira kratkim spojem. Druga kotva mosta je slobodna ili je povezana sa otpornikom prednapona. Dovođenjem jednosmernog napona aktucije između mosta i mikrotalasne linije, stvara se elektrostatička sila koja dovodi do savijanja mosta MEMS prekidača sve do izolatorskog sloja. Na taj način značajno se povećava kapacitivnost mosta (faktor povećanja od 30 do 100). Uvećana kapacitivnost povezuje signalnu liniju sa uzemljenjem i stvara kratak spoj na mikrotalasnim frekvencijama. Nakon isključenja napona aktucije, MEMS prekidač se vraća u prvobitno stanje usled dejstva povratne sile opruge na most prekidača. Tipične vrednosti geometrije parametara prekidača su: debljina izolatorskog sloja 1000-1500 Å, relativna dielektrična konstanta 5.0-7.6, visina

mosta 1.5-5  $\mu\text{m}$ , dužina mosta 250-400  $\mu\text{m}$ , širina mosta 25-1800  $\mu\text{m}$  (zavisi od zahtevane kapacitivnosti prekidača). Dužina mosta je retko kraća od 200  $\mu\text{m}$  jer smanjenje dužine mosta zahteva veće napone aktuacije. Širina mosta je u praksi ograničena do 200  $\mu\text{m}$  kako bi se postigao ravan kontakt između mosta i signalne linije.

MEMS kapacitivni prekidač u paralelnoj vezi modelovan je sa dve kratke sekcije signalne linije i RCL modela mosta sa kapacitivnošću koju ima u podignutom i spuštenom položaju. Sekcija signalne linije je dužine  $(w/2) + \ell$ , gde  $\ell = 20 \mu\text{m}$  je rastojanje od referentne ravni do kraja mosta [1]. Tipične vrednosti za prekidače milimetarskog talasnog područja su: kapacitivnost  $C_u/C_d$ : 35 fF/2.8 pF, induktansa  $L$  od 6 pH do 12 pH i serijska otpornost  $R_s$  od 0.2  $\Omega$  do 0.3  $\Omega$ .

Impedansa kapacitivnog prekidača u paralelnoj vezi data je sa:

$$Z_s = R_s + j\omega L + \frac{1}{j\omega C} \quad (2.1)$$

U ovom slučaju  $C=C_u$  ili  $C=C_d$  što zavisi od pozicije prekidača.

Kapacitivnosti prekidača za stanja mosta u spuštenom položaju ( $C_d$ ), odnosno u sa mostom u podignutom položaju ( $C_u$ ), moguće je izračunati primenom sledećih jednačina [1]:

$$C_d = \frac{\varepsilon_0 \varepsilon_r A}{t_d} \quad (2.2)$$

$$C_u = \frac{\varepsilon_0 A}{g + \frac{t_d}{\varepsilon_r}} \quad (2.3)$$

gde  $\varepsilon_0$  predstavlja dielektričnu konstantu,  $\varepsilon_r$  je relativna dielektrična konstanta,  $t_d$  je rastojanje između dve podloge koje formiraju kapacitivnost,  $A$  je površina kapacitivnog sloja RF MEMS prekidača i  $g$  je visina mosta prekidača u odnosu na elektrodu.

Rezonantna frekvencija prekidača data je izrazom

$$f_0 = \frac{1}{2\pi\sqrt{LC}} \quad (2.4)$$

Impedansa paralelnog prekidača je

$$f(x) = \begin{cases} \frac{1}{j\omega C}, & f \ll f_0 \\ R_s, & f = f_0 \\ j\omega C, & f \gg f_0 \end{cases} \quad (2.5)$$



RCL model se ponaša kao kondenzator na frekvencijama manjim od rezonantne frekvencije i kao kalem na frekvencijama većim od rezonantne frekvencije. Na rezonantnoj frekvenciji, impedansa postaje otpornog karaktera što dovodi do serijskog otpora mosta MEMS prekidača. Ilustracije radi, za vrednosti  $C_u=35$  fF,  $C_d=2.8$  pF i  $L=7$  pH do rezonanse dolazi na  $f_0=322$  GHz kada je most prekidača u podignutom položaju i na  $f_0=36$  GHz kada je most u spuštenom položaju. Ovo proističe iz činjenice da induktivnost mosta nema uticaja kada je most u podignutom položaju za frekvencije manje od 100 GHz. Stoga se u podignutom položaju mosta MEMS prekidač može modelovati kao paralelna kapacitivnost vezana na uzemljenje. Za razliku od navedenog, induktansa vrši značajniji uticaj kada je most u spuštenom položaju.

Granična frekvencija (*cutoff frequency*) je definisana kao frekvencija kada odnos impedansi podignutog i spuštenog mosta padne na jedinicu i iznosi

$$f_c = \frac{1}{2\pi C_u R_s} \quad (2.6)$$

Za vrednosti  $C_u=35$  fF i  $R_s=0.15$   $\Omega$ , granična frekvencija je  $f_c=30$  THz.

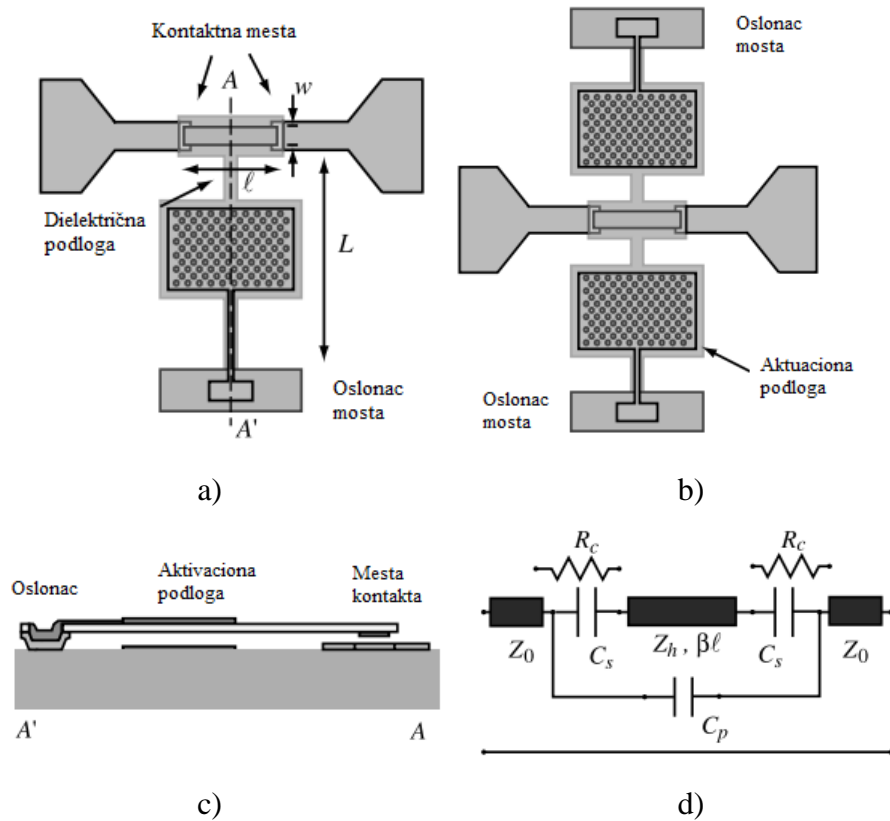
Iz jednačina 2.2 i 2.3 može se zaključiti da kapacitivnost ne zavisi od lateralnih dimenzija mosta prekidača, odnosno ona je konstantna sa promenama dimenzija mosta. Ostala dva elementa ekvivalentnog kola  $R$  i  $L$  direktno zavise od lateralnih dimenzija mosta prekidača. Navedene vrednosti određuju se procesom optimizacije u simulatoru kola u cilju dostizanja željenih vrednosti S-parametara u odgovoru ekvivalentnog kola. Alternativno, induktivnost MEMS prekidača se može odrediti sledećom jednačinom preko simulirane ili merene vrednosti rezonantne frekvencije:

$$L = \frac{1}{4\pi^2 f_{res}^2 C} \quad (2.7)$$

## 2.5.2 Opis fizičkih karakteristika MEMS omskog prekidača u serijskoj konfiguraciji

MEMS prekidači u serijskoj konfiguraciji dele istu geometrijsku strukturu kao i prekidači u paralelnoj konfiguraciji. Prorez na signalnoj liniji od 40 do 100  $\mu\text{m}$  stvara otvoreno strujno kolo, dok je prekidač u otvorenom položaju (most prekidača je u podignutom položaju). Aktivacijom MEMS prekidača, most prelazi u spušteni položaj i stvara kratak spoj sa otvorenim krajevima signalne linije. Za većinu dizajna serijskih MEMS prekidača koristi se omski kontakti (*DC-contact*), usled čega su podesni za prekidačku funkciju kod signala niskih

frekvencija (manjih od 100 MHz). Princip aktivacije omskih prekidača zasniva se na neposrednom ostvarivanju kontakta kraja mosta sa signalnom linijom, te je iz tog razloga potrebna zasebna elektroda koja će usloviti mehaničku aktivaciju prekidača. Primer MEMS omskog prekidača u serijskoj vezi dat je na Slici 2.9 [1].



Slika 2.9 MEMS omski prekidač: a) u serijskoj vezi, b) u vertikalnoj ravni, c) u poprečnoj ravni i d) sa odgovarajućim strujnim kolom

Tipične geometrijske vrednosti omskih MEMS prekidača su: visina od 1.5  $\mu\text{m}$  do 3  $\mu\text{m}$ , ukupna dužina  $L=300-400$   $\mu\text{m}$  i širina  $l=80-160$   $\mu\text{m}$  (zavisno od dužine preseka na signalnoj liniji). Širina signalne linije je 20-60  $\mu\text{m}$  i metal na metal kontaktno polje se generalno projektuje mnogo manjih dimenzija u odnosu na širinu signalne linije. Aktivaciona podloga se postavlja na udaljenosti od 100  $\mu\text{m}$  do 200  $\mu\text{m}$  od mesta oslanjanja mosta (kotve mosta). Naponi aktivacije su u opsegu od 15 V do 60 V, što u najvećoj meri zavisi od dizajna prekidača. Rupičasta struktura mosta prekidača značajno uvećava brzinu prekidača.

Kapacitivnost omskog MEMS prekidača sa mostom u podignutom (*up-state*) položaju čine serijska kapacitivnost ( $C_s$ , kapacitivnost između signalne linije i mosta prekidača) i parazitska kapacitivnost ( $C_p$ , kapacitivnost između otvorenih krajeva signalne linije). Ukupna

kapacitivnost serijskog MEMS omskog prekidača sa mostom koji se oslanja na oba kraja (*fixed-fixed beam*) može se izraziti sledećom jednačinom:

$$C_u = \frac{C_s}{2} + C_p \quad (2.8)$$

dok je ukupna kapacitivnost serijskog MEMS omskog prekidača sa mostom u obliku jednostrane konzole (*cantilever beam*):

$$C_u = C_s + C_p \quad (2.9)$$

Provodnost struje kod serijskog MEMS prekidača sa mostom u spušenom položaju (*down-state*) je identična provodnosti struje u signalnoj liniji, jer sam prekidač u serijskoj topologiji predstavlja nastavak signalne linije. Procesom simulacije dokazano je da se struja koncentriše na ivici metalnog mosta (čak i za mostove koji su široki samo 40  $\mu\text{m}$ ) i da na nju ne utiče rupičasta struktura središnjeg dela mosta (čime se povećava prekidačka brzina).

Otpornost serijskog MEMS prekidača zavisi od veličine kontaktne površine, primenjene mehaničke sile na most prekidača i kvaliteta metala koji ostvaruju kontakte [6]. Najčešće se kreće u granicama 1-2  $\Omega$ . Serijska otpornost MEMS serijskog prekidača sa mostom u obliku jednostrane konzole i dva kontaktna polja izražava se jednačinom:

$$R_s = 2R_c + 2R_{s1} + R_l \quad (2.10)$$

dok kod linijskog prekidača sa jednim kontaktnim poljem:

$$R_s = R_c + 2R_{s1} + R_l \quad (2.11)$$

U jednačini,  $R_c$  predstavlja otpornost kontaktnih polja,  $R_{s1}$  otpornost signalne linije i  $R_l$  otpornost mosta prekidača. U praksi, na serijsku otpornost prekidača najveći uticaj ispoljava otpornost kontaktnih polja ( $R_c$ ).

Slabljenje koje unosi serijski MEMS prekidač može se izračunati merenjem vrednosti ili upotrebom simulatora električnog kola, kao  $L_{oss} = 1 - |S_{11}|^2 - |S_{21}|^2$ . Na osnovu RLC kola slabljenje MEMS prekidača se može izračunati jednačinom:

$$L_{oss} = \frac{4R_s Z_0}{|Z_s + 2Z_0|^2} \quad (2.12)$$

gde je  $Z_s$  impedansa prekidača, a  $Z_0$  je karakteristična impedansa signalne linije.

Kada je most prekidača u spušenom položaju, onda je  $Z_s = R_s + j\omega L$ , pa je slabljenje


$$L_{oss} = \frac{R_s}{Z_0} \quad \text{za} \quad \omega L \ll Z_0 \quad (2.13)$$

Induktivnost serijskog MEMS prekidača predstavlja se jednačinom:

$$L = \frac{Z_h \beta \ell}{\omega} = \frac{Z_h \ell}{v_p} \quad \text{za } \ell < \frac{\lambda_g}{12} \quad (2.14)$$

## 2.6 MODELOVANI RF MEMS KAPACITIVNI I OMSKI PREKIDAČI


Rezultati modelovanja prezentovani u ovoj disertaciji odnose se na RF MEMS kapacitivni prekidač u paralelnoj topologiji (Slika 2.10) i na RF MEMS omski prekidač u serijskoj topologiji (Slika 2.11). Oba prekidača proizvedena su u *Fondazione Bruno Kessler* (FBK) u Trentu Italija, u koplanarnoj tehnologiji (CPW-Coplanar Waveguide) procesom mikrofabrikacije na osmoslojnom silicijumu [8, 12].



Slika 2.10 Modelovani prekidač sa šemom poprečnog preseka u FBK tehnologiji

Ispod mosta paralelnog RF MEMS kapacitivnog prekidača postavljena je signalna linija koja je izrađena od aluminijuma i premazana je slojem od 100 nm SiO<sub>2</sub>. Uporedno od signalnom linijom nalazi se aktuaciona podloga (*actuation pad*) izrađena od polisilicijuma. Most predstavlja tanka membrana koja povezuje obe strane uzemljenja. Induktansa mosta i fiksna kapacitivnost između signalne linije i mosta prekidača formiraju rezonantno kolo sa

uzemljenjem. Rezonantna frekvencija navedenog kola zavisi od dimenzija mosta, odnosno dužine osnove mosta,  $L_s$ , i dužine prstiju mosta,  $L_f$ . Na rezonantnoj frekvenciji, kolo se ponaša kao kratak spoj sa uzemljenjem. Kod struja u opsegu frekvencija oko rezonantne frekvencije, prenos signala je onemogućen. Povlačenje mosta nadole ostvaruje se dovođenjem napona aktucije od oko 45 V. Napon aktucije definisan je kao trenutni jednosmerni napon koji se dovodi na aktuacionu podlogu usled čega se most povlači nadole i ostvaruje kontakt sa signalnom linijom. Za obeležavanje napona aktucije ustaljena je oznaka  $V_{PI}$  (*pull-in voltage*). Navedeni parametri su usko povezani sa karakteristikama prekidača, mehaničkim parametrima, karakteristikama materijala, kao što su položaj i veličina aktuacione podloge, konstante opruge i rezidualnog stresa mosta, oblika mosta, itd. Dužinom prstiju mosta direktno se podešava napon aktucije. Ukoliko je dužina prstiju mosta duža u odnosu na ostale delove mosta, onda će most biti isuviše fleksibilan a samim tim aktucija prekidača je moguća sa malim vrednostima  $V_{PI}$ . U tom slučaju, povećan je i rizik od samoaktucije ili aktucije kada prekidač sprovodi signal velike RF snage. Sa druge strane, kada je dužina prstiju mosta isuviše mala, prekidaču je potreban veliki napon aktucije za povlačenje mosta u spuštenu položaj i ostvarenja kontakta. Osim toga, promene širine i dužine mosta utiču na menjanje induktanse prekidača a samim tim i rezonantne frekvencije. Osnova mosta je izrađena u perforaciji, čime je umanjen otpor vazduha prilikom povlačenja mosta iz spuštenog u podignuti položaj i obrnuto. Perforacije na mostu imaju ulogu povećanja fleksibilnosti mosta i ne utiču na električne karakteristike.



Slika 2.11 Omski RF MEMS prekidač: a) u serijskoj topologiji, b) uprošćena konfiguracija

Iste karakteristike se odnose i na RF MEMS omski prekidač u serijskoj topologiji. Prekidač je fabrikovan na SiO<sub>2</sub> podlozi debljine 525 μm u procesu mikrofabrikacije i CMOS tehnologije [8]. Za postizanje željenih karakteristika RF MEMS omskog prekidača u serijskoj topologiji potrebno je kroz proces optimizacije odrediti optimalne dimenzije dužine mosta ( $L_b$ ), širine mosta ( $W_b$ ), kao i lateralnog ( $L_g$ ) i longitudinalnog procepa ( $W_g$ ) između kotve mosta i koplanarnog uzemljenja.

Lateralne dimenzije mosta RF MEMS prekidača treba da budu pažljivo odabrane tako da se podesi rezonantna frekvencija za izabrani frekventni opseg primene prekidača, pri čemu treba voditi računa o snagama RF signala i izvodljivosti jednosmernog napona aktivacije [1]. Modeli RF MEMS prekidača bazirani na veštačkim neuronskim mrežama predloženi u ovoj disertaciji mogu biti iskorišćeni za poboljšanje efikasnosti postupka određivanja lateralnih dimenzija prekidača, što će biti detaljno izloženo u glavama koje slede.

### **3 VEŠTAČKE NEURONSKE MREŽE**

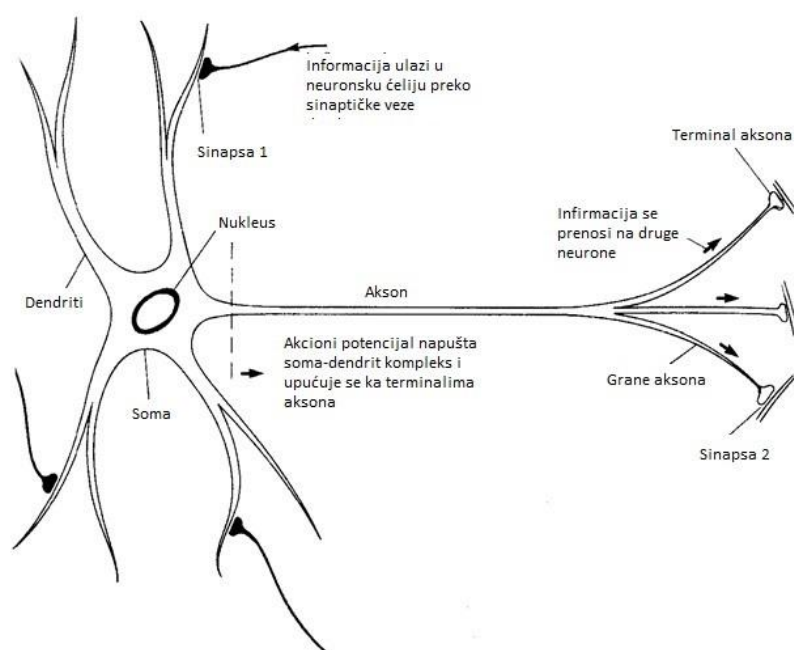
Veštačke neuronske mreže su matematičke strukture napravljene po ugledu na neuronsku strukturu mozga. Odnosno, neuronske mreže simuliraju način rada ljudskog mozga pri obavljanju datog zadatka ili neke funkcije. Ovakav princip primene biološki inspirisanih modela, omogućava niz prednosti kod primene u različitim oblastima modelovanja elektronskih komponenti.

U današnje vreme, problem obrade složenih matematičkih operacija prevaziđen je primenom računara. Međutim, osnovni nedostatak je prepoznavanje čak i najjednostavnijih obrazaca, tj. nemogućnost generalizacije izvršenih obrazaca i predikcije budućih akcija. Sa druge strane, mozak informacije skladišti u vidu složenih obrazaca koji omogućavaju sagledavanje pojava i problema iz više uglova. Takav proces skladištenja informacija u formi obrazaca i njihovog korišćenja radi rešavanja problema, formira novi pristup u rešavanju složenih zadataka. Iz tog razloga ljudski mozak je još uvek superioran u odnosu na savremene računare u mnogim aspektima, jer složene, nelinearne i paralelne procese izvršava sa sledećim svojstvenim karakteristikama:

- paralelno distributivno procesiranje informacija,
- adaptivnost i mogućnost učenja novog znanja,
- univerzalna struktura za obradu informacija (ista struktura izvršava mnogo različitih funkcija).

Dosadašnji razvoj bioloških istraživanja omogućava osnovno razumevanje prirodnih principa rada mozga, što je iskorišćeno za simuliranje principa u strukturi veštačkih neuronskih mreža. Iz tog razloga, u nastavku će ukratko biti opisana analogija veštačkih neuronskih mreža sa prirodnim nervnim sistemom. Poznato je da osnovu mozga čini poseban tip nervne ćelije koja se zove neuron. U proseku ljudski mozak broji oko 100 milijardi neurona. Neuron najčešće ostvaruje od 1.000 do 10.000 veza sa drugim neuronima. Moć ljudskog uma upravo proističe iz velikog broja neurona i višestrukih veza između njih sa

moogućnostima genetskog programiranja i učenja. Pojedinačno gledano, neuroni su vrlo složene građe, jer imaju veliki broj delova, podsistema i kontrolnih mehanizama. Uprošćeni izgled prirodnog neurona prikazan je na Slici 3.1 [81]. Neuron se sastoji od dendrita, tela ćelije i aksona. Dendriti su produžeci na telu ćelije koji prihvataju oko 90% signala iz okolnih neurona. Ovi signali se dalje sprovode do tela ćelije, koje prihvata ostalih 10% signala. Akson (neurit ili nervno vlakno) je cilindrični nastavak koji prima signale iz tela ćelije koji se dalje prenose sinapsama do dendrita susednih neurona.



Slika 3.1 *Prirodni neuron*

Jedan deo aksona je obavijen mijelinskim omotačem, dok je njegov kraj razgranat kako bi se signali prosleđivali ka većem broju drugih neurona. Na kraju razgranatih delova aksona nalaze se nervni završeci. Sinapsa igra ključnu ulogu u funkcionisanju celog nervnog sistema i predstavlja vezu između neurona. Naime, u nepobuđenom stanju ne postoji nikakva izlazna aktivnost prirodnog neurona i njegov potencijal je oko  $-70$  mV. Kada se na neku sinapsu dovede signal dolazi do fizičko-hemijskog procesa kojim se menja potencijal neurona. Sve dok se ne prekorači aktivacioni prag na izlazu neurona nema signala. Međutim, dovođenje signala na samo jednu sinapsu obično ne dovodi do izlazne aktivnosti neurona. Prekoračenje praga se može ostvariti uzastopnim aktiviranjem jedne sinapse ili simultanim aktiviranjem više sinapsi. Tek kada se prekorači aktivacioni prag dolazi do polarizacije početnog dela aksona, tj. do izlazne aktivnosti neurona. Učenje se odvija menjanjem jačine sinaptičkih veza,



odnosno težina u mreži. Sami prirodni neuroni su dosta sporiji od savremenih elektronskih elemenata (silicijumski čipovi) [24]. Međutim, prirodna neuronska mreža relativno malu brzinu rada neurona nadomeštava velikim brojem neurona i još većim brojem sinapsi između njih. Krajnji rezultat jeste enormno efikasna struktura prirodne neuronske mreže.

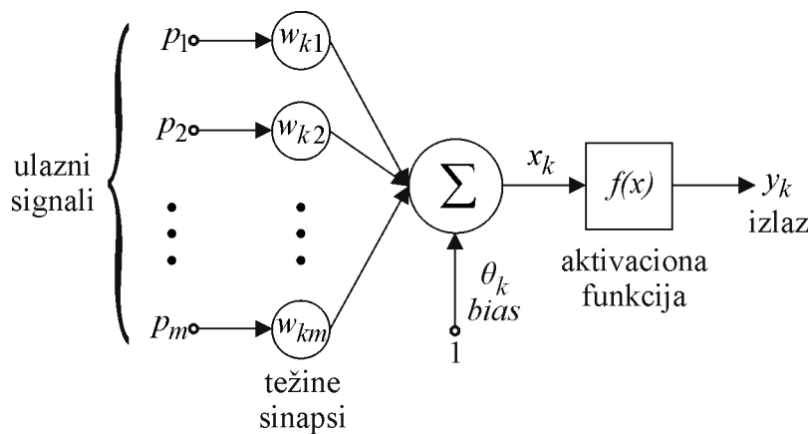
Veštačke neuronske mreže repliciraju samo najosnovnije elemente komplikovanog, svestranog i moćnog prirodnog nervnog sistema. Analogija u odnosu na ljudski mozak ogleda se kroz dva procesa:

- neuronska mreža zahvata znanje kroz proces obučavanja,
- težine medjuneuronskih veza (jačina sinaptičkih veza) služe za memorisanje znanja.

Navedene procese veštačke neuronske mreže vrše na najjednostavniji način stvarajući novi pristup u načinu rešavanja problema.

### **3.1 MODEL NEURONA VEŠTAČKE NEURONSKE MREŽE**

Osnovna jedinica svake veštačke neuronske mreže koja vrši obradu informacija je neuron. Blok šema modela veštačkog neurona prikazana je na Slici 3.2 [24]. Veštački neuron, kao i prirodni neuron, ima jedan ili više ulaza sa kojih prima informacije (analogno dendritima kod prirodnih neurona). Neuron najpre vrši sabiranje ulaznih signala pomnoženih odgovarajućim težinama (težine sinapsi) i tako stvara svoju internu aktivaciju. Izlazni signal neurona predstavlja odziv aktivacione funkcije za prethodno određenu internu aktivaciju.



Slika 3.2 *Nelinearni model neurona*

Model neurona čine sledeća tri bazična elementa:

- Skup sinaptičkih težina (veze). Signal  $p_j$  na ulazu sinapse  $j$  povezane za neuron  $k$  množi se težinom sinapse  $w_{kj}$ . Indeksi težine sinapse napisani su tako što prvi indeks u  $w_{kj}$  se odnosi na neuron, dok se drugi indeks odnosi na sinapsu čija je ovo težina;
- Sabirač formira težinsku sumu ulaza tako što sabira ulazne signale koji su pomnoženi odgovarajućim težinama sinapsi neurona;
- Aktivaciona funkcija limitira amplitudu izlaznog signala neurona. Načelno se uzima normalizacija izlaza neurona u intervalima  $[0,1]$  ili  $[-1,1]$ .

Neuroni veštačke neuronske mreže uključuju spoljašnje primenjeni prag (*bias*),  $\theta_k$ , koji predstavlja težinski koeficijent jediničnog ulaza u neuron. Pozitivne vrednosti praga ( $\theta_k$ ) vrše povećanje vrednosti aktivacionog signala neurona, odnosno, argumenta prenosne funkcije neurona ( $x_k$ ), što odgovara eksitatornoj sinapsi kod prirodnog neurona. Sa druge strane negativne vrednosti praga smanjuju vrednost argumenta prenosne funkcije, što odgovara inhibitornoj sinapsi kod prirodnog neurona. Svaki neuron se može opisati i matematičkim izrazima:

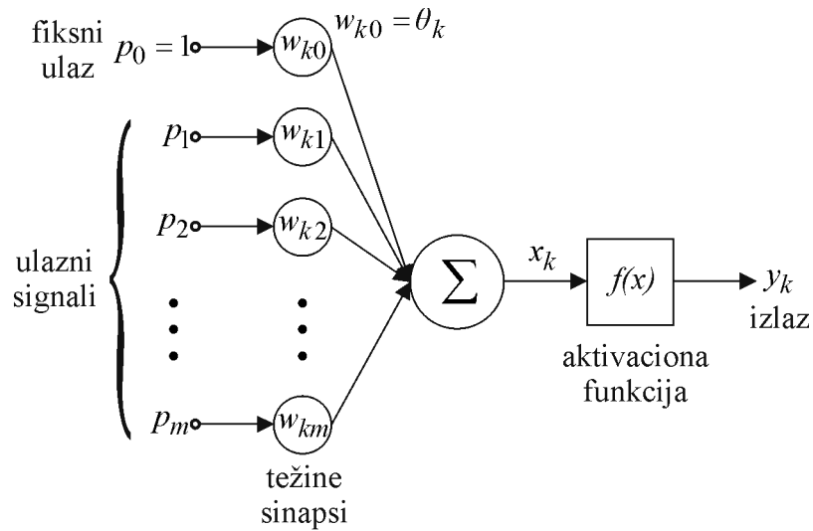
$$x_k = \sum_{j=0}^m w_{kj} p_j + \theta_k \quad (3.1)$$

$$y_k = f(x_k) \quad (3.2)$$

gde su  $p_1, p_2, \dots, p_m$  ulazni signali,  $w_{k1}, w_{k2}, \dots, w_{km}$  težine sinapsi neurona  $k$ , a  $y_k$  izlazni signal neurona.

Za razliku od navedenog statičkog modela neurona, postoji i nelinearni model neurona sa proširenim ulazom i pragom uobliku sinaptičke težine. U tom slučaju se parametar praga  $\theta_k$  uključuje u model neurona na samom ulazu preko težinskog parametra  $w_{k0}$  ( $w_{k0} = \theta_k$ ) ulaza  $p_0$  sa fiksnom vrednošću jednakom jedinici. Ovakav model neurona prikazan je na Slici 3.3, a odgovarajući matematički izraz je:

$$x_k = \sum_{j=0}^m w_{kj} p_j \quad (3.3)$$




Slika 3.3 Nelinearan model neurona sa proširenim ulazom

Aktivaciona (prenosna, transfer) funkcija, prikazana kao  $f(x)$ , definiše izlaz neurona  $y$  u zavisnosti od parametra  $x$ . Odnosno, aktivaciona funkcija određuje da li rezultat funkcije sumiranja (interna aktivacija neurona) može da proizvede izlaz neurona. U primeni je veći broj aktivacionih funkcija, koje se dele u dve grupe: linearne aktivacione funkcije kao jednostavniji oblik i nelinearne aktivacione funkcije kao druga grupa mnogo zastupljenijih funkcija.

Linearna aktivaciona funkcija prikazana je na Slici 3.4 i definisana je izrazom:

$$f(x) = x \quad (3.4)$$

S obzirom da prenosna funkcija prirodnog neurona nije linearna, ovaj tip funkcije nije zadovoljavajuće rešenje. Zbog toga se u veštačkim neuronskim mrežama kombinuju neuroni sa linearnom i nelinearnom aktivacionom funkcijom.




Slika 3.4 Linearna prenosna funkcija neurona

Nelinearna aktivaciona funkcija je daleko zastupljenija jer se veštačke neuronske mreže najčešće koriste za modelovanje nelinearnih zavisnosti. Najzastupljenija je primena odskočne i sigmoidne nelinearne aktivacione funkcije [24, 42]. Odskočne funkcije mogu se naći u dva oblika koja su prikazana na Slikama 3.5(a) i 3.5(b), i definisane su sledećim jednačinama, respektivno:

$$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.5)$$

$$f(x) = \begin{cases} 1, & x \geq 0 \\ -1, & x < 0 \end{cases} \quad (3.6)$$



Slika 3.5 Odskočne prenosne funkcije neurona: a) u opsegu  $[0,1]$  i b) u opsegu  $[-1,1]$

Odskočne funkcije obezbeđuju neuronu dva stabilna stanja, odnosno aktivno i neaktivno stanje, pa se zbog te karakteristike nazivaju još i aktivacionim funkcijama praga. Neuron sa ovakvom aktivacionom funkcijom je poznat kao *Mek Kulok-Pitsov* model neurona (*McCulloch i Pitts* su 1943. godine postavili temelje za razvoj neuronskih mreža tako što su prvi dokazali da neuroni mogu imati dva stanja i da njihova aktivnost zavisi od vrednosti pobude) [24].


Ako se na ulaz neurona dovede aktivacija veća od nule, onda se neuron aktivira i generiše aktivni izlaz, dok je u svim drugim slučajevima izlaz inhibitoran, odnosno stimulacija na ulazu neurona nije bila dovoljna za prelazak aktivacionog praga.

Druga grupa nelinearnih aktivacionih funkcija su sigmoidne, koje su za razliku od odskočnih funkcija matematički kontinualne i diferencijabilne. Takođe, ove funkcije su i neopadajuće. Dve najčešće korišćene sigmoidne funkcije su log-sigmoidna i tan-sigmoidna,

koje su prikazane na Slikama 3.6(a) i 3.6(b). One su definisane uz pomoć sledeće dve jednačine, respektivno:

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.7)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.8)$$



Slika 3.6 Sigmoidne prenosne funkcije neurona: a) log-sigmoidna i b) tan-sigmoidna

Prag aktivacije kod svih nelinearnih aktivacionih funkcija je nula. Promena, odnosno podešavanje praga aktivacije se vrši izmenama praga ( $\theta_k$ ) i težinskog parametra  $w_{k0}$  u aktivacionom signalu, što je prikazano na Slikama 3.2 i 3.3.

## 3.2 NEURONSKA MREŽA

Jedan neuron ima vrlo ograničene mogućnosti, pa se njihovim umrežavanjem i uređenjem međusobnih konekcija formira neuronska mreža koja ima daleko veći učinak. Svaka neuronska mreža se u osnovi sastoji od elemenata za procesiranje (neuroni) i njihovih međusobnih konekcija.

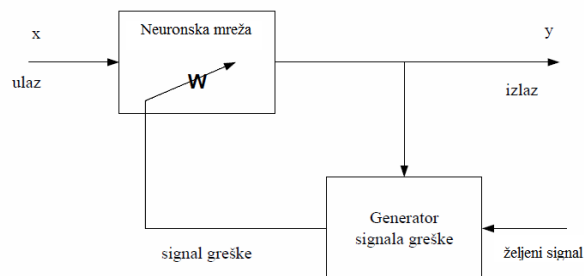
Jedna od najznačajnijih karakteristika neuronskih mreža je sposobnost učenja. Učenje veštačkih neuronskih mreža je procedura podešavanja parametara i/ili strukture mreže tako da ona dobije željeno ponašanje/funkcionalnost, tj. da za određene vrednosti ulaznih parametara na ulazu mreže bude željeni izlaz. Određeni broj rešenih primera problema koji se modeluje mrežom predstavlja trening skup koji se koristi u postupku učenja VNM. Najpre se određuju odzivi VNM za ulazne parametre iz trening skupa. Dobljene vrednosti na izlazu mreže se

upoređuju sa očekivanim. Ukoliko postoji razlika između dobijenih i očekivanih podataka, vrše se modifikacije parametara mreže u cilju smanjivanja razlike trenutnog i željenog izlaza. Ovaj postupak se ponavlja sve dok mreža ne nauči da reaguje na željeni način. Krajnji cilj je razvoj mreže koja je sposobna da tačno rešava zadatke za koje je obučavana. Procedure za promenu parametara i/ili strukture VNM nazivaju se procedurama za učenje. Procedure za učenje se mogu podeliti na:

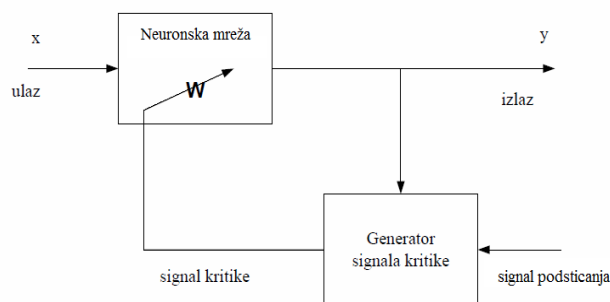
- Statičke procedure - baziraju na promeni težine veza (promena sinapsi) i pragova aktivacionih funkcija za već definisanu arhitekturu i
- Dinamičke procedure - vrši se promena težina, pragova aktivacionih funkcija i arhitekture mreže.

Postoje tri klase učenja neuronskih mreža [81]:


- Nadgledano (supervised) učenje, Slika 3.7 (a). U ovoj klasi učenja mreži se prezentuju pobuda i korektan odziv na tu pobudu, pa se na osnovu razlike, tj. greške između stvarnog i željenog odziva mreže, procedura vrši promenu parametara mreže, sa ciljem minimizacije ove razlike.
- Učenje sa podsticanjem (reinforcement), Slika 3.7 (b). Neuronska mreža dobija osnovne informacije kakav izlaz generiše, najčešće samo u formi jednog bita informacije tipa (dobar, loš).
- Nenadgledano (unsupervised) učenje, Slika 3.7 (c). U ovoj klasi ne postoje primeri funkcija koje mreža treba da nauči. Odnosno, mreži se prezentuje samo pobuda, a od mreže i od procedure za učenje se očekuje da same "uoče" zavisnost u ulaznim podacima i da definišu korektan odziv. Procedure za učenje vrši promenu težina samo na osnovu trenutnog ulaza i izlaza mreže.



a)



b)



c)

Slika 3.7 Klase učenja neuronskih mreža:

a) Nadgledano učenje, b) Učenje sa podsticanjem i c) Nenadgledano učenje

U zavisnosti od odnosa učenja mreže i njene kasnije eksploatacije učenje može biti:

- *Off-line* (laboratorijsko) učenje, i
- *On-line* učenje.

*Off-line* učenje najčešće se koristi u nadgledanim klasama učenja mreža i podrazumeva obučavanje mreže van sredine u kojoj će ona kasnije raditi. Sredina se simulira skupom podataka za učenje, tj. trening skupom, koji treba što vernije da simulira datu sredinu. Podaci za učenje se sekvencijalno dovode na ulaze mreže. Na osnovu njih procedura za učenje vrši promenu parametara mreže. Formiranje mreže je završeno kada se uspostavi zadovoljavajući odziv mreže.

*On-line* učenje predstavlja obučavanje mreže u toku njene eksploatacije. Mreža se tada uči direktno na podacima koje dobija od radne sredine. Karakteristična je primena kod metode nenadgledanog učenja. U ovom slučaju mreža, nalik prirodnom nervnom sistemu, uči u toku celog svog radnog veka, tj. na beskonačnom skupu uzoraka. *Off-line* učenje se često vrši sa nepotpunim trening skupom. Naime, dešava se da je broj mogućih uzoraka preveliki tako da nije moguće obuhvatiti ih sve trening skupom, ili da trening skup nije potpun jer se ne

poznaje odziv mreže za sve ulaze. Od naučene mreže se, međutim, očekuje da da korektan odziv i za one ulaze koji nisu obuhvaćeni trening skupom, tj. da ima mogućnost generalizacije problema. Upravo ova karakteristika predstavlja najveći argument primene veštačkih neuronskih mreža u rešavanju složenih problema.

Podela veštačkih neuronskih mreža se može izvršiti po sledećim kriterijumima:

- Prema broju slojeva (jednoslojne i višeslojne).
- Prema načinu povezivanja:
  - o slojevite (neuroni su raspoređeni u slojeve),
  - o potpuno povezane (izlaz iz jednog neurona vodi se na ulaz svih neurona u mreži),
  - o ćelijske (samo susedni neuroni su međusobno povezani ali se signali prostiru indirektno).
- U odnosu na pravac prenosa i obradu podataka:
  - o Feedforward - direktne mreže (tj. prenos signala se odvija samo u jednom pravcu), takođe nazivaju se i nerekurentne ili nerekurzivne,
  - o Feedback, rekurentne mreže (indirektne ili povratne), gde postoje povratne veze između pojedinih neurona.
- U zavisnosti od načina učenja mogu biti:
  - o sa nadgledanim učenjem,
  - o sa nenadgledanim učenjem.
- Feedforward mreže sa nadgledanim učenjem se dalje mogu podeliti na:
  - o perceptron,
  - o višeslojni perceptron (MLP),
  - o neuronska mreža sa radijalnom funkcijom (RBF),
  - o Hamingova mreža,
  - o probalističke mreže,
  - o Košijeva mašina,
  - o kvantizacija vektora učenja i druge.
- Feedforward mreže sa nenadgledanim učenjem mogu biti:
  - o counterpropagation mreža,
  - o clustering mreža,
  - o linearna asocijativna mreža i druge.
- Feedback mreže sa nadgledanim učenjem mogu biti:
  - o Flopfildova mreža,
  - o fuzzy kognitivne mape,

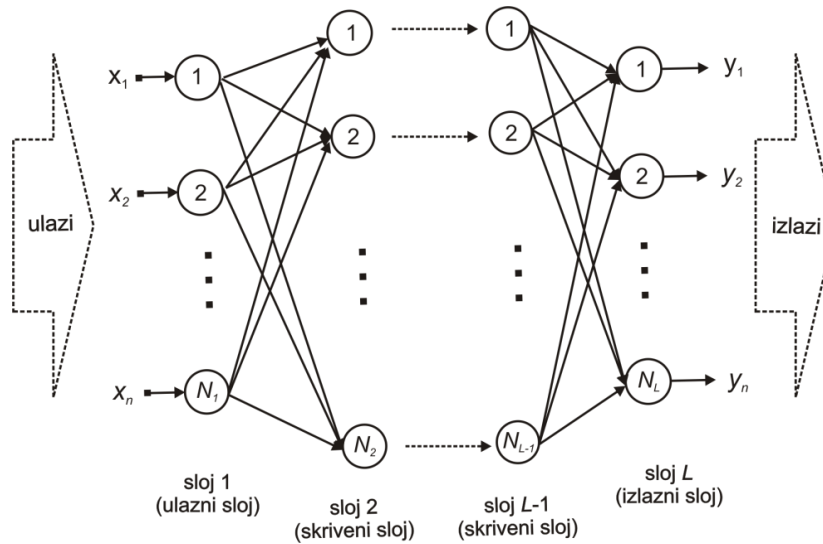


- asocijativne memorije,
  - Bolcmanova mašina i druge.
- Feedback sa nenadgledanim učenjem:
- Grosbergove mreže,
  - Kohonenove mape,
  - teorija adaptivne rezonancije, i
  - mreže sa kompetitivnim učenjem.

### **3.3 SLOJEVITA NEURONSKA MREŽA-MLP**

Najjednostavnija i vrlo često korišćena struktura neuronske mreže je slojevita (višeslojna) neuronska mreža (*Multilayer Perceptron Network*), ili skraćeno MLP mreža. Spada u grupu feedforward mreža (mreža sa prostiranjem podataka unapred) sa nadgledanim učenjem. Osnovna karakteristika ovog tipa mreže jeste sposobnost aproksimacije generičkih klasa funkcija, uključujući kontinualne i integrabilne funkcije. U oblasti mikrotalasa, MLP mreža je do sada primenjivana kako za modelovanje, tako i za optimizaciju komponenata i sistema [26-80].

Načelno, jedna MLP mreža se sastoji od neurona grupisanih u ulaznom sloju, jednom ili više skrivenih slojeva i izlaznom sloju, što je prikazano na Slici 3.8. Neuron koji primaju informacije spolja formiraju ulazni sloj, dok su neuroni koji generišu izlazne informacije grupisani u izlaznom sloju. Između ulaznog i izlaznog sloja, formira se skriveni sloj (ili slojevi). Kod ovog tipa mreže, svaki neuron iz jednog sloja povezan je sa svim neuronima iz prethodnog i narednog sloja, pri čemu ne postoje veze između neurona koji se nalaze u istom sloju. Broj slojeva u mreži, broj neurona u svakom sloju, aktivaciona funkcija za svaki sloj i međuslojne konekcije čine arhitekturu neuronske mreže. Koja je najbolja arhitektura neuronske mreže zavisi od tipa problema koji treba da se predstavi mrežom.



Slika 3.8 Slojevita MLP neuronska mreža

Informacije iz okruženja, tj. vrednosti ulaznih podataka, dovode se na ulaze neurona u ulaznom sloju, a zatim se šalju neuronima u prvom skrivenom sloju. Pošto se ulazni podaci procesiraju od strane neurona iz svih skrivenih slojeva, prosleđuju se neuronima iz poslednjeg izlaznog sloja, koji na kraju generišu izlazne signale (podatke).

Ako se pretpostavi da je ukupan broj slojeva neuronske mreže  $L$ , u tom slučaju prvi sloj je ulazni sloj,  $L$ -ti sloj izlazni sloj, a drugi sloj i svi naredni slojevi zaključno sa slojem  $L-1$  su skriveni slojevi. Broj neurona u  $l$ -tom sloju je  $N_l$  i označeni su  $l = 1, 2, \dots, L$ .


Neka  $w_{ij}^l$  predstavlja težinsku vezu između  $j$ -tog neurona u  $l-1$  sloja  $i$ -tog neurona u  $l$ -tom sloju, pa je  $1 \leq j \leq N_{l-1}$  i  $1 \leq i \leq N_l$ . Takođe,  $x_i$  predstavlja  $i$ -ti ulaz u MLP mrežu a  $z_i^l$  izlaz  $i$ -tog neurona u  $l$ -tom sloju. Ako na svaki neuron dovedemo dodatni težinski parametar  $w_{i0}^l$ , tada će on predstavljati prag  $i$ -tog neurona u  $l$ -tom sloju. Težinska veza parametara  $w_{ij}^l$  u MLP mreži predstavlja se matricom [26]:

$$w = [w_{10}^2 \ w_{11}^2 \ w_{12}^2 \ \dots \ w_{N_L N_{L-1}}^L]^T \quad (3.9)$$

gde je  $j = 0, 1, \dots, N_{l-1}$ ,  $i = 1, 2, \dots, N_l$  i  $l = 2, 3, \dots, L$ .

Svaki neuron prima stimulanse od neurona iz prethodnog sloja. Navedeno se ne odnosi samo na neurone u ulaznom sloju. Dobijene stimulanse neuron obrađuje i prosleđuje ka svom izlazu. Odnosno, neuron sloja  $l$  prima stimulanse koji potiču od izlaza neurona sloja  $l-1$ , a koji se mogu označiti sa:  $y_1^{l-1}, y_2^{l-1}, \dots, y_{N_{l-1}}^{l-1}$ .

Svaki ulaz se prvo množi odgovarajućim težinskim parametrom, a zatim se dobijene vrednosti sabiraju kako bi se dobila suma koja predstavlja argument  $x$ , aktivacione funkcije odgovarajućeg neurona  $f(x)$ , kako bi se generisao konačni izlaz neurona (Slika 3.9). Izlaz neurona  $y_i^l$  proslediće se u naredni sloj kao stimulans neurona u njemu. U praksi se najčešće koristi linearna aktivaciona funkcija u neuronima ulaznog i izlaznog sloja, a u neuronima skrivenog sloja (ili slojeva) koristi se nelinearna sigmoidna aktivaciona funkcija. Pri tome u ulaznom sloju neuroni imaju samo po jedan ulaz.



Slika 3.9 Procesiranje informacije u  $i$  – tom neuronu  $l$  – tog sloja MLP mreže

### 3.1.1 Backpropagation algoritam

Jedna od prvih i najčešće korišćenih metoda za nadgledano učenje neuronskih mreža je backpropagation algoritam, tj. algoritam za prostiranje greške unazad. Promena parametara neuronske mreže vrši se na osnovu signala greške izlaznih neurona. Uspostavljanje optimalnog skupa težinskih parametara  $w$  postiže se treningom neuronske mreže, tako da mreža  $y = y(\mathbf{x}, \mathbf{w})$  verno aproksimira originalni problem. Neka trening podatke kojima se vrši treniranje neuronske mreže predstavljaju uzorci, tj. parovi oblika  $(x_k, d_k)$ , gde je  $k = 1, 2, \dots, P$ ,  $d_k$  predstavlja željene izlaze neuronskog modela za odgovarajuće ulaze  $x_k$ , a  $P$  predstavlja ukupan broj trening uzoraka.

Tokom treninga, karakteristike neuronske mreže se izražavaju proračunom razlike između stvarnih i željenih izlaza neuronske mreže za sve trening uzorke. Ova razlika (greška) se može izraziti na sledeći način [26]:

$$E = \frac{1}{2} \sum_{k \in T_r} \sum_{j=1}^m (y_j(x_k, w) - d_{jk})^2 \quad (3.10)$$

gde  $d_{jk}$  predstavlja  $j$ -ti element u vektoru  $d_k$ ,  $y_j(x_k, w)$  je  $j$ -ti izlaz neuronske mreže za odgovarajući ulaz  $x_k$ , a  $T_r$  je skup indeksa trening podataka. Težinski parametri  $w$  se tokom treninga podešavaju tako da ova greška bude što je moguće manja.

Prvi korak u sprovođenju backpropagation algoritma je početna inicijalizacija težinskih parametara  $w$ . Najčešće se za vrednosti težinskih parametara određuju male nasumične vrednosti. Tokom treninga, vrednosti  $w$  menja u pravcu negativne vrednosti gradijenta parametra  $E$ , sve dok  $E$  ne postane dovoljno malo [26].

Ako se vrednosti težinskih parametara  $w$ , menjaju samo na osnovu jednog trening uzorka, onda se funkcija greške  $E_k$  :

$$E_k = \frac{1}{2} \sum_{j=1}^m (y_j(x_k, w) - d_{jk})^2 \quad (3.11)$$

koristi za promenu vrednosti parametara  $w$  u skladu sa,

$$w = w - \eta \frac{\partial E_k}{\partial w} \quad (3.12)$$

gde se parametar  $\eta$  naziva stopa učenja. U nastavku je sagledano kako se proces prostiranja greške u nazad koristi za proračun gradijenta informacije  $\frac{\partial E_k}{\partial w}$ . Proširivanjem jednačine (3.11) dobijene su jednostavne realcije koje određuju parametre  $E_k$  u odnosu na težinske parametre  $l$ -tog sloja [26]:

$$\frac{\partial E_k}{\partial w_{ij}^l} = \frac{\partial E_k}{\partial z_i^l} \cdot \frac{\partial z_i^l}{\partial w_{ij}^l} \quad (3.13)$$

i

$$\frac{\partial z_i^l}{\partial w_{ij}^l} = \frac{\partial \sigma}{\partial \gamma_i^l} \cdot z_j^{l-1} \quad (3.14)$$

Gradijent  $\frac{\partial E_k}{\partial z_i^l}$  se u izlaznom sloju  $L$  određuje po jednačini:

$$\frac{\partial E_k}{\partial z_i^L} = (y_i(x_k, w) - d_{ik}) \quad (3.15)$$

gde se koristi greška, odnosno razlika vrednosti koje generiše veštačka neuronska mreža sa vrednostima željenih izlaza mreže.

Na isti način se izračunava greška od sloja  $l+1$  do sloja  $l$ , tada se gradijent  $\frac{\partial E_k}{\partial z_i^l}$  određuje po sledećem:

$$\frac{\partial E_k}{\partial z_{ij}^l} = \sum_{j=1}^{N_{l+1}} \frac{\partial E_k}{\partial z_j^{l+1}} \cdot \frac{\partial z_j^{l+1}}{\partial z_i^l} \quad (3.16)$$

U sledećem koraku, uz pretpostavku da MLP mreža koristi sigmoidnu aktivacionu funkciju u neuronima skrivenog sloja, pa je

$$\frac{\partial \sigma}{\partial \gamma} = \sigma(\gamma)(1 - \sigma(\gamma)) \quad (3.17)$$

$$\frac{\partial z_i^l}{\partial w_{ij}^l} = z_i^l(1 - z_i^l)z_j^{l-1} \quad (3.18)$$

i

$$\frac{\partial z_i^l}{\partial w_j^{l-1}} = z_i^l(1 - z_i^l)w_{ij}^l \quad (3.19)$$

Za istu MLP mrežu može da se parametar  $\delta_i^l$  definiše kao  $\delta_i^l = \frac{\partial E_k}{\partial \gamma_i^l}$ , koji predstavlja lokalni gradijent na  $i$ -tom neuronu  $l$ -tog sloja. Onda se proces prostiranja unazad predstavlja sa jednačinama [26],

$$\delta_i^L = (y_i(x_k, w) - d_{ik}) \quad (3.20)$$

$$\delta_i^l = \left( \sum_{j=1}^{N_{l+1}} \delta_j^{l+1} w_{ij}^{l+1} \right) z_i^l(1 - z_i^l) \quad (3.21)$$

gde je  $l=L-1, L-2, \dots, 2$

Na kraju, jednačina gradijenta u odnosu na težinske parametre bi bila:

$$\frac{\partial E_k}{\partial w_i^l} = \delta_i^l z_j^{l-1} \quad (3.22)$$


takođe za vrednosti  $l=L-1, L-2, \dots, 2$ .

Efikasnost navedenog algoritma prostiranja greške unazad u izvesnoj meri zavisi od početnih vrednosti težina i pragova, pa je dalji pravac razvoja za učenje neuronskih mreža bio usmeren na razvoj optimizacionih tehnika sa višim stepenom konvergencije. Tu se ističu *Quasi-Newton*-ova metoda i *Levenberg-Marquardt*-ova optimizaciona tehnika [26]. *Quasi-Newton*-ova metoda je optimizaciona tehnika koja značajno ubrzava proces učenja neuronske mreže. Reč je o gradijentnoj metodi koja minimizira grešku odziva mreže za ceo trening skup. Ovakva optimizaciona tehnika nije pogodna za realizaciju u paralelnoj distribuiranoj strukturi, s obzirom da su bazirane na manipulacijama matrica parcijalnih izvoda drugog reda (npr. *Hesse*-ova matrica). Sa druge strane, *Levenberg-Marquardt*-ova optimizaciona tehnika ima

bolje osobine po pitanju konvergencije od backpropagation algoritma, a i lakše se implementira u paralelnoj arhitekturi od *Quasi-Newton*-ovog metoda.

### 3.4 NEURONSKA MREŽA SA RADIJALNOM FUNKCIJOM (RBF MREŽA)


Neuronska mreža sa radijalnom funkcijom (*Radial Basis Function-RBF*) je feedforward neuronska mreža sa ulaznim, jednim skrivenim i izlaznim slojem. Neuroni u skrivenom sloju koriste radijalnu aktivacionu funkciju, po čemu su RBF neuronske mreže i dobile ime [26, 32]. RBF neuronske mreže uspešno se primenjuju u širokom spektru modelovanja karakteristika mikrotalasnih uređaja i elemenata [82-85]. Tipična RBF neuronska mreža prikazana je na Slici (3.10). Radijalnu aktivacionu funkciju određuju sledeći parametri:  $c_{ij}$  – centri vektora i  $\lambda_{ij}$  – standardne devijacije (spread), što će biti objašnjeno u daljem delu teksta.



Slika 3.10 Struktura RBF neuronske mreže

Najčešće korišćena radijalna aktivaciona funkcija je Gausova aktivaciona funkcija. Gausova funkcija je prikazana na Slici (3.11) i opisuje se jednačinom:

$$f(x) = \exp(-x^2) \quad (3.23)$$



Slika 3.11 Gausova funkcija

Za date ulaze  $x$ , ukupan ulaz  $i$ -tog neurona u skrivenom sloju je dat jednačinom:

$$x_i = \sqrt{\sum_{j=1}^n \left( \frac{x_j - c_{ij}}{\lambda_{ij}} \right)^2} \quad (3.24)$$

za vrednosti  $i = 1, 2, \dots, N$ , gde  $N$  predstavlja broj skrivenih neurona.

Izlazna vrednost  $i$ -tog neurona u skrivenom sloju je  $z_i = f(x_i)$ , gde  $f(x)$  predstavlja radijalnu aktivacionu funkciju. Na kraju, izlazne vrednosti RBF mreže mogu se opisati sledećom jednačinom:

$$y_k = \sum_{i=0}^N w_{ki} z_i, \quad k = 1, 2, \dots, m \quad (3.25)$$

gde  $w_{ki}$  predstavlja težinski parametar veze između  $i$ -tog neurona u skrivenom sloju i  $k$ -tog neurona u izlaznom sloju. U RBF mreži trening parametri  $w$  uključuju vrednosti:  $w_{k0}$ ,  $w_{ki}$ ,  $c_{ij}$ ,  $\lambda_{ij}$ , dok su vrednosti  $k=1, 2, \dots, m$ ;  $i=1, 2, \dots, N$ ;  $j=1, 2, \dots, n$ .

Obuka RBF neuronski mreža vrši se u dva koraka:

1. Prvi korak obuke RBF neuronske mreže podrazumeva primenu klaster algoritma, sa kojim se vrši početna inicijalizacija centara  $c_{ij}$  aktivacionih funkcija neurona u skrivenom sloju. Ovaj korak je faza nenadgledanog treninga mreže, sa ciljem postavljanja centara klastera u distribuciji trening kombinacija. Na ovaj način se obezbeđuju bolje inicijalne vrednosti za vrednosti centara u skrivenim neuronima, nego što se to postiže primenom metoda početne inicijalizacije sa slučajnim vrednostima.
2. Drugi korak se odnosi na usklađivanje vrednosti centara aktivacionih funkcija skrivenih neurona primenom tehnike optimizacije gradijenta, kao što je  $w = w -$

$\eta \frac{\partial E}{\partial w}$ , gde  $w$  uključuje sve parametre RBF mreže ( $\lambda_{ij}$ ,  $c_{ij}$  i  $w_{ki}$ ). Proces se nastavlja sve dok neuronska mreža ne nauči trening podatke na zahtevanom nivou. U tom smislu, ovaj korak je sličan procesu treninga MLP neuronskih mreža.

### 3.5 SPOSOBNOST GENERALIZACIJE

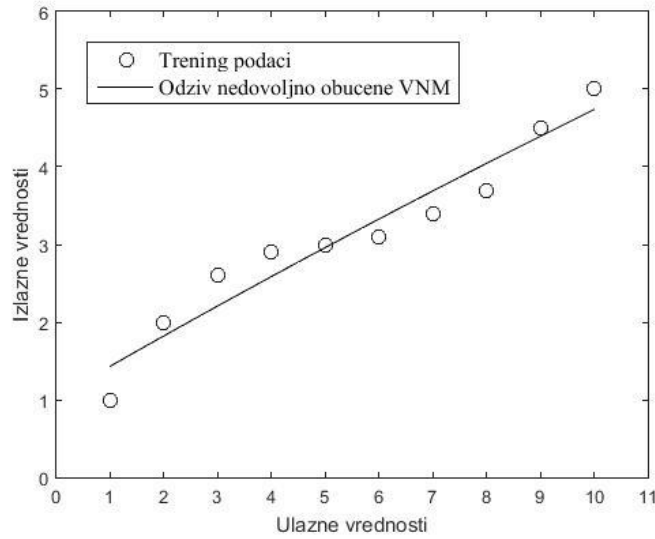
Kao što je već pominjano, osnovnu računarsku snagu neuronskih mreža čini masivni paralelizam, sposobnost obučavanja i generalizacija.

Generalizacija predstavlja sposobnost generisanja korektnog izlaza neuronske mreže i za kombinacije ulaznih vrednosti koje nisu korišćene u toku obučavanja mreže, ali koje pripadaju istom prostoru ulaznih veličina.

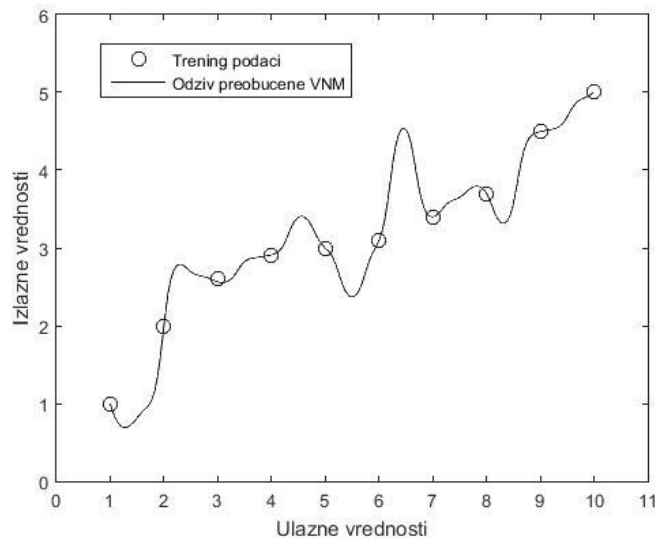
Efikasnost generalizacije neuronske mreže zavisi od veličine trening skupa. Mali broj uzoraka ulaznih vrednosti usloviće lošu generalizaciju, jer oni reprezentuju smanjen prostor uzoraka, odnosno daje samo delimičnu "sliku" problema za koji se specijalizuje. Sa druge strane, veći trening skup upotpunjuje celi prostor uzoraka, mreža raspolaže sa više informacija i uvećava se sposobnost neuronske mreže da generalizacije zadati problem. Mreža sa većim brojem neurona raspolaže sa većim brojem parametara (težine veza i pragovi aktivacionih funkcija), pa samim tim ima veću sposobnost aproksimacije trening skupa [24]. Suprotno tome, mreža sa nedovoljnim brojem neurona nije u mogućnosti da korektno nauči ni trening uzorke. Rešenje je u kompromisu ova dva zahteva, tj. između korektnog učenja podataka iz trening skupa i dobre generalizacije. Pored toga, generalizaciju neuronske mreže u velikoj meri određuju sledeća dva fenomena:

1. Trajanje procesa obučavanja izražava se kroz broj epoha. Nedovoljan broj epoha uslovljava nedovoljnu obučenost mreže, tj. dovodi do fenomena zvanog *under-learning* (Slika 3.12). Na navedeni fenomen utiče i nedovoljan broj skrivenih neurona, nedovoljan broj kombinacija u trening skupu ili se trening procedura završila u lokalnom minimumu, umesto u globalnom minimumu.
2. Pojava preučenosti neuronske mreže ili *over-learning* javlja se u slučajevima prevelikog broja epoha, kada se mreža isforsira u tačnosti učenja trening uzoraka (Slika 3.13). Drugi razlozi pojave preučenosti mreže su prevelik broj skrivenih neurona ili nedovoljan broj kombinacija u trening skupu. Kao posledica javlja se nekontrolisano ponašanje mreže za ulazne uzorke van trening skupa.





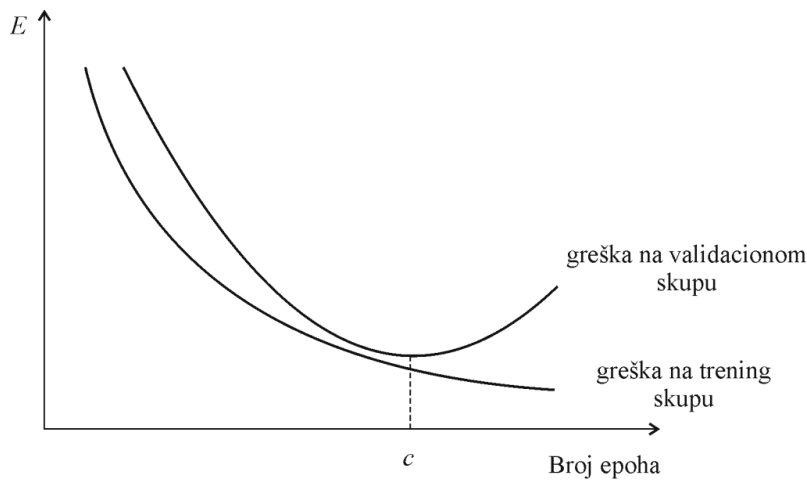
Slika 3.12 *Primer odziva nedovoljno obučene neuronske mreže*



Slika 3.13 *Primer odziva preobučene neuronske mreže*

Ako se uzme u obzir da visokodimenzionalni problemi dodatno usložnjavaju pronalaženje kompromisnog rešenja, onda se broj potrebnih epoha lakše određuje ukoliko se u toku učenja pored trening skupa koristi još jedan skup, tzv. validacioni skup. Pri tome se, sem greške na trening skupu, računa i prati greška na validacionom skupu. Na Slici 3.14 je prikazana zavisnost ovih grešaka od broja epoha učenja. Greška na trening skupu opada sa brojem izvršenih epoha. Međutim, greška na test skupu, koja predstavlja meru kvaliteta generalizacije, opada do nekog broja epoha  $c$ , a onda počinje da raste. Objašnjenje ove pojave leži u činjenici da se posle  $c$  epoha mreža primorava da što vernije aproksimira trening skup,

dok van granica trening skupa ona počinje da se ponaša nekontrolisano i narušava generalizaciju mreže.



Slika 3.14 Zavisnost greške od broja epoha [31]

### 3.6 TESTIRANJE VEŠTAČKIH NEURONSKIH MREŽA

Nakon formiranja i obuke neuronskog modela potrebno je izvršiti njegovo testiranje. Testiranjem neuronske mreže sagledava se tačnost odziv mreže za datu pobudu iz trening skupa, kao njena generalizacija. Iz tog razloga, neuronska mreža se testira sa trening vrednostima i vrednostima koje nisu obuhvaćene trening skupom.

U postupku testiranja neuronske mreže, kao mera kvaliteta predikcije neuronske mreže najčešće se koriste [42]:

- *ATE* - srednja greška testiranja (*Average Test Error*),
- *WCE* - maksimalna greška (*Worst Case Error*) i
- *Pearson-Product Moment* korelacioni koeficijent  $r$ .

Neka neuronska mreža ima  $m$  ulaza. Ukoliko je na ulazu  $k$ -ti uzorak test skupa  $T_e$ , onda se relativna greška odziva na  $j$ -tom izlazu mreže može definisati kao:

$$\delta_{kj} = \frac{o_{ki} - d_{kj}}{d_{max,j} - d_{min,j}}, \quad j = 1, \dots, m, \quad k \in T_e \quad (3.26)$$

Pri tome,  $y_{ki}$  je odziv  $j$ -tog izlaza neuronske mreže na  $k$ -ti test uzorak,  $d_{kj}$  je željena vrednost a  $d_{max,j}$  i  $d_{min,j}$  su maksimalna i minimalna vrednost na  $j$ -tom izlazu mreže, respektivno.

Neka je moment reda  $p$  definisan sa:

$$M_p = \left[ \sum_{k \in T_e} \sum_{j=1}^m |\delta_{kj}|^p \right]^{1/p} \quad (3.27)$$

Ako je  $p=1$ , onda se srednja greška testiranja ( $ATE$ ) može direktno odrediti na osnovu  $M_1$ :

$$ATE = |\bar{\delta}| = mean(\delta) = \frac{M_1}{Size(T_e)m} = \frac{1}{Size(T_e)m} \sum_{k \in T_e} \sum_{j=1}^m |\delta_{kj}| \quad (3.28)$$

$Size(T_e)$  predstavlja ukupan broj elemenata u test skupu.

Analogno tome, standardna devijacija  $\sigma^2$  je:

$$\sigma^2 = \frac{1}{Size(T_e)m} \sum_{k \in T_e} \sum_{j=1}^m (|\delta_{kj}| - |\bar{\delta}|)^2 \quad (3.29)$$

Maksimalna greška ( $WCE$ ) definiše se kao:

$$WCE = M_\infty = \max_{k \in T_e} \max_{j=1}^m |\delta_{kj}| \quad (3.30)$$

Najčešće se prilikom testiranja neuronske mreže koriste  $ATE$  i  $WCE$ , dok se alternativno mogu koristiti  $ATE$  i  $\sigma^2$ .

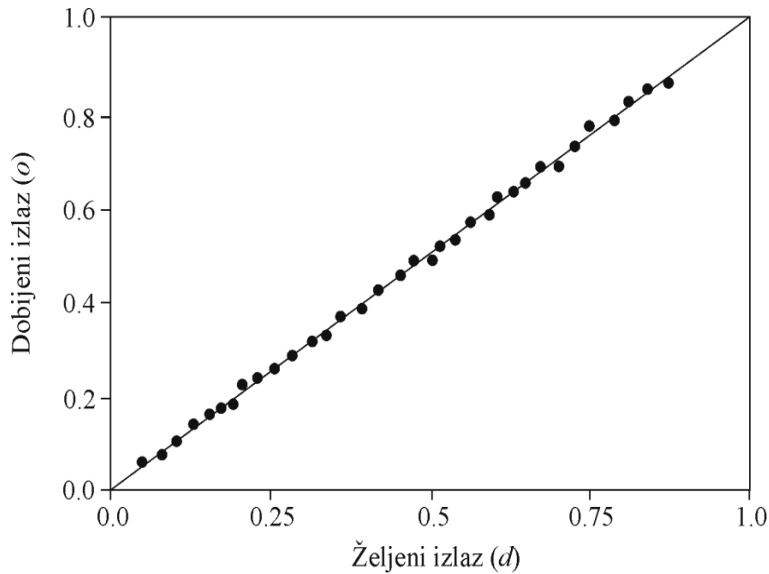
Sledeći parametar koji se često koristi kao kriterijum prilikom testiranja neuronskih mreža jeste korelacioni koeficijent  $r$ . Ovaj parametar predstavlja stepen slaganja vrednosti koje generiše neuronska mreža sa odgovarajućim referentnim podacima. Treba težiti da korelacioni koeficijent ima vrednost što je moguće bliže jedinici jer je to pokazatelj boljeg slaganja izlaznih sa željenim vrednostima. Korelacioni koeficijent se definiše preko:

$$r = \frac{\sum_{j=1}^m \sum_{k \in T_e} (y_{kj} - \bar{y})(d_{kj} - \bar{d})}{\sqrt{\left[ \sum_{j=1}^m \sum_{k \in T_e} (y_{kj} - \bar{y})^2 \right] \left[ \sum_{j=1}^m \sum_{k \in T_e} (d_{kj} - \bar{d})^2 \right]}} \quad (3.31)$$

$$\bar{y} = \frac{1}{Size(T_e)m} \sum_{j=1}^m \sum_{k \in T_e} y_{kj} \quad (3.32)$$

$$\bar{d} = \frac{1}{Size(T_e)m} \sum_{j=1}^m \sum_{k \in T_e} d_{kj} \quad (3.33)$$

Poslednji u nizu postupaka procene kvaliteta predikcije neuronske mreže je iscrtavanje korelacionog dijagrama (*scattering plot*). Predstavlja brz i krajnje jednostavan postupak sagledavanja tačnosti formiranog neuronskog modela. Primer korelacionog dijagrama prikazan je na Slici 3.15, gde se na x osu nanose željene vrednosti, a na y osu vrednosti generisane neuronskom mrežom. Idealno slaganje je postignuto kada se sve tačke nalaze na pravoj liniji duž dijagonalne ose.




Slika 3.15 Primer korelacionog dijagrama

Navedeni parametri se najčešće koriste tokom obučavanja i validacije mreža u cilju upoređivanja njihovih performansi, u cilju izbora mreže sa najboljim performansama. Međutim, za samu ilustraciju tačnosti mreža često se koriste i klasično definisane apsolutna greške i relativna greška izražena u procentima. Sve greške različite od ATE i WCE korišćene u ovom radu biće definisane pri njihovom navođenju u delu sa rezultatima.


### **3.7 STRUKTURE NEURONSKIH MODELA PREDLOŽENIH ZA MODELOVANJE RF MEMS PREKIDAČA**

Najjednostavniji neuronski model čini jedna višeslojna neuronska mreža obučena da modeluje zavisnost dva skupa veličina (Slika 3.16). Svako ulaznoj veličini problema pridružuje se jedan ulaz u neuronsku mrežu, tj. jedan neuron ulaznog sloja, a svakoj izlaznoj jedan izlaz iz mreže tj. jedan neuron izlaznog sloja. Ovakav model pripada grupi modela zasnovanih na principu „crne kutije“ (*black-box models*), a koji karakteriše direktno modelovanje zavisnosti izlaznih od ulaznih veličina. Za razvoj modela nisu potrebne dodatne informacije o prirodi problema, osim kombinacija ulaz-odgovarajući izlaz [42].



Slika 3.16 Osnovni neuronski model („black-box“)


Kod modelovanja mikrotalasnih komponenti moguća je pojava da se pojedine izlazne veličine različito ponašaju sa promenom ulaznih veličina od ostalih izlaznih veličina. U takvim slučajevima često, i pored povećanja broja uzoraka za obučavanje, jednom višeslojnom neuronskom mrežom nije moguće izvršiti dovoljno dobro modelovanje ulazno-izlaznih zavisnosti. Za prevazilaženje ovog problema efikasno rešenje je grupisanje izlaznih veličina na osnovu karaktera (tj. sličnosti) ponašanja njihovih zavisnosti od ulaznih veličina, tj. vrši se dekompozicija skupa izlaznih veličina. Dekompozicija podrazumeva zasebno obučavanje posebnih višeslojnih neuronskih mreža za svaku grupu izlaznih veličina sličnih karaktera. Na taj način formira se posebna grupa *black box* modela. Na Slici 3.17 je prikazana blok šema neuronskog modela zasnovanog na dekompoziciji, u slučaju da postoje dve grupe srodnih izlaznih veličina. Pri tome svaka od neuronskih mreža ima onoliko izlaza koliko ima veličina u odgovarajućoj grupi, dok su ulazi u obe neuronske mreže isti kao i u slučaju modelovanja jedinstvenom neuronskom mrežom [28].



Slika 3.17 Neuronski model zasnovan na dekompoziciji

Sledeća vrsta modela baziranih na veštačkim neuronskim mrežama zasnovana je na konceptu kod kojeg se neuronska mreža koristi za preslikavanje prostora ulaznih veličina (*SM - Space Mapping*) [86]. Navedeni koncept kombinuje prednosti efikasnosti jednog modela sa tačnošću drugog modela. Kod *SM* modela prostor originalnih ulaznih veličina preslikava se u

prostor ulaznih veličina drugog, eksternog, modela, koji kao izlaze ima veličine koje treba modelovati. Blok šema ovakvog modela prikazana je na Slici 3.18. Veštačka neuronska kojom vrši preslikavanje prostora ulaznih veličina ima onoliko ulaznih neurona koliko ima originalnih ulaznih veličina, dok je broj izlaznih neurona jednak broju ulaznih veličina eksternog modela.



Slika 3.18 *Neuronski model baziran na preslikavanju prostora ulaznih veličina*

Koji će od navedenih neuronskih modela biti primenjen zavisi od konkretnog problema koji se rešava (modeluje), pri čemu je moguće primeniti i kombinacije modela.

Radi lakšeg obeležavanja razvijenih neuronskih mreža, korišćen je princip notacije VNM oblika  $N - H_1 - H_2 - M$ . Na ovaj način predstavljena je VNM koja ima  $N$  neurona u ulaznom sloju,  $M$  neurona u izlaznom sloju,  $H_1$  i  $H_2$  neurona u prvom i drugom skrivenom sloju, respektivno.

### **3.7.1 Priprema podataka za neuronske modele**

Priprema podataka za neuronski model obuhvata prikupljanje, podelu i pretprocesiranje podataka za obuku, testiranje neuronskog modela, kao i postprocesiranje dobijenih rezultata. Priroda problema koji se modeluje određuje način na koji će podaci biti prikupljeni. Generalno, za razvoj neuronskih modela u oblasti mikrotalasa, podaci se mogu dobiti na dva načina: merenjem ili simulacijom. Generisanje podataka merenjem primenjuje se u slučajevima kada ne postoji matematički model koji bi omogućio dovoljno tačnu i dovoljno brzu simulaciju zavisnosti izlaza od ulaznih promenljivih i kada se u merenje uključuju i razni sekundarni efekti koje je teško matematički modelovati. Glavni nedostaci pribavljanja podataka putem merenja su relativna ograničenost u promeni nekih ulaznih parametara (npr. fizički parametri komponente) i nepreciznost merenja pojedinih izlaznih parametara. Prednost generisanja podataka putem simulacije (npr. pomoću elektromagnetskog simulatora, simulatora kola ili matematičkog/fizičkog modela) je u mogućnosti lakog menjanja vrednosti ulaznih veličina (uz proizvoljni korak promene). Na efikasnost ovog načina pribavljanja podataka negativno utiče kompleksnost procesa simulacije (naročito kod simulacija sa

kompleksnim matematičkim izračunavanjima), pa je samim tim često hardverski i vremenski zahtevan proces.

Kako se modeli koji su prikazani u ovoj disertaciji razvijaju sa ciljem da se koriste kao vremenski efikasnija alternativa kompleksnim EM/mehaničkim simulatorima ili pomoću ranije razvijenih neuronskih modela, zadržavajući pri tome tačnost simulacije, podaci koji se koriste za razvoj i validaciju modela dobijeni su u simulatorima, što će biti detaljnije objašnjeno u narednim glavama.

Podaci koji su na raspolaganju dele se na:

- trening skup, koji se koristi za obučavanje neuronske mreže,
- test skup, koji služi za testiranje obučene neuronske mreže i
- validacioni skup koji služi za *on-line* testiranje tokom obučavanja (opciono).

Nužno je da svi skupovi pravilno reprezentuju prostor ulazno-izlaznih podataka [26, 32], odnosno da što je moguće bolje pokriju prostor ulaznih promenljivih. Podaci u ulaznom prostoru mogu biti: uniformno izabrani, neuniformno raspoređeni (češća primena) i sa slučajnim uzorkovanjem u ulaznom prostoru.

Osetljivost neurona sa sigmoidnom prenosnom funkcijom (koja se najčešće koristi) najveća je u uskom opsegu [0,1] ili [-1,1], pa vrednosti van tog opsega mogu da dovedu neuron u oblast smanjene osetljivosti, tj. zasićenja. Ovaj problem je naročito prisutan u oblasti mikrotalasa, gde ulazne i izlazne veličine neuronskih mreža mogu imati vrednosti u velikom rasponu. Iz tog razloga vrši se pretprocesiranje podataka, čime se omogućava da neuronska mreža radi u oblasti maksimalne dinamičke osetljivosti. Pretprocesiranjem se podaci iz originalnog opsega prebacuju u normalizovani opseg [0,1] ili [-1,1], pa se sa takvim trening skupom vrši obučavanje mreže. Time se dobija na tačnosti modelovanja, a da se ne gube neophodne informacije. U kasnijoj primeni obučene neuronske mreže, takođe se koriste ulazni podaci koji su prethodno iz originalnog opsega prebačeni u normalizovani opseg. Na kraju, vrši se postupak postprocesiranja (denormalizacija odziva), kojim se izlazni podaci neuronske mreže iz normalizovanog opsega vraćaju u originalni opseg [26, 43].

Na primer, normalizacija veličine  $p$  u opseg [-1,1] može se izvršiti pomoću:

$$p_n = 2 \cdot \frac{p - \min p}{\max p - \min p} - 1 \quad (3.34)$$

gde je  $p_n$  normalizovana vrednost, a  $\min p$  i  $\max p$ , minimalna i maksimalna vrednost veličine  $p$  u trening skupu, respektivno.

Denormalizacijom odziva  $t_n$  iz opsega  $[-1,1]$  dobija se odziv  $t$  u originalnom opsegu pomoću:

$$t = \frac{1}{2} \frac{t_n - 1}{\max t - \min t} + \min t \quad (3.35)$$

gde su  $\min t$  i  $\max t$ , minimalna i maksimalna vrednost odziva  $t$  u trening skupu, respektivno.



## **4 BLACK-BOX MODELI KARAKTERISTIKA RF MEMS PREKIDAČA**

Projektovanje elektronskih kola koja sadrže RF MEMS prekidače zahteva veliki broj simulacija i/ili optimizacija za koje je potrebno poznavati karakteristike prekidača. U slučaju realizovane komponente, prekidač se može predstaviti mernim karakteristikama. Međutim često je potrebno vršiti simulacije i optimizaciju karakteristika kola pre nego što se prekidač realizuje. Odnosno, postoji potreba za poznavanjem direktnih relacija između geometrijskih parametara i njegovih kako električnih tako i mehaničkih karakteristika. Iz tog razloga, neophodno je razviti pouzdan model RF MEMS prekidača koji bi se koristio u proceduri projektnih proračuna. Standardno modelovanje EM karakteristika RF MEMS prekidača vrši se u *full-wave* simulatorima [17-19], dok se određivanje mehaničkih karakteristika prekidača vrši u mehaničkim simulatorima baziranim na metodu konačnih elemenata (*FEM-Finite Element Method*) [19, 20]. Ovakvi procesi zahtevaju poznavanje detaljnih fizičkih karakteristika prekidača, značajne računarske resurse i vremenski su dugotrajni procesi uzimajući u obzir ukupno vreme potrebno za simulaciju i optimizaciju elektronskog kola u koje se ugrađuje RF MEMS prekidač. Moguća alternativa su analitički postupci koji mogu biti upotrebljeni samo za jednostavnije konfiguracije prekidača, npr. za određivanje napona aktucije kod prekidača sa mostom jednostavnog oblika. Druga opcija je primena skalabilnih modela baziranih na ekvivalentnom kolu, koji često ne daju potrebnu tačnost, te se stoga koriste u preliminarnoj analizi.

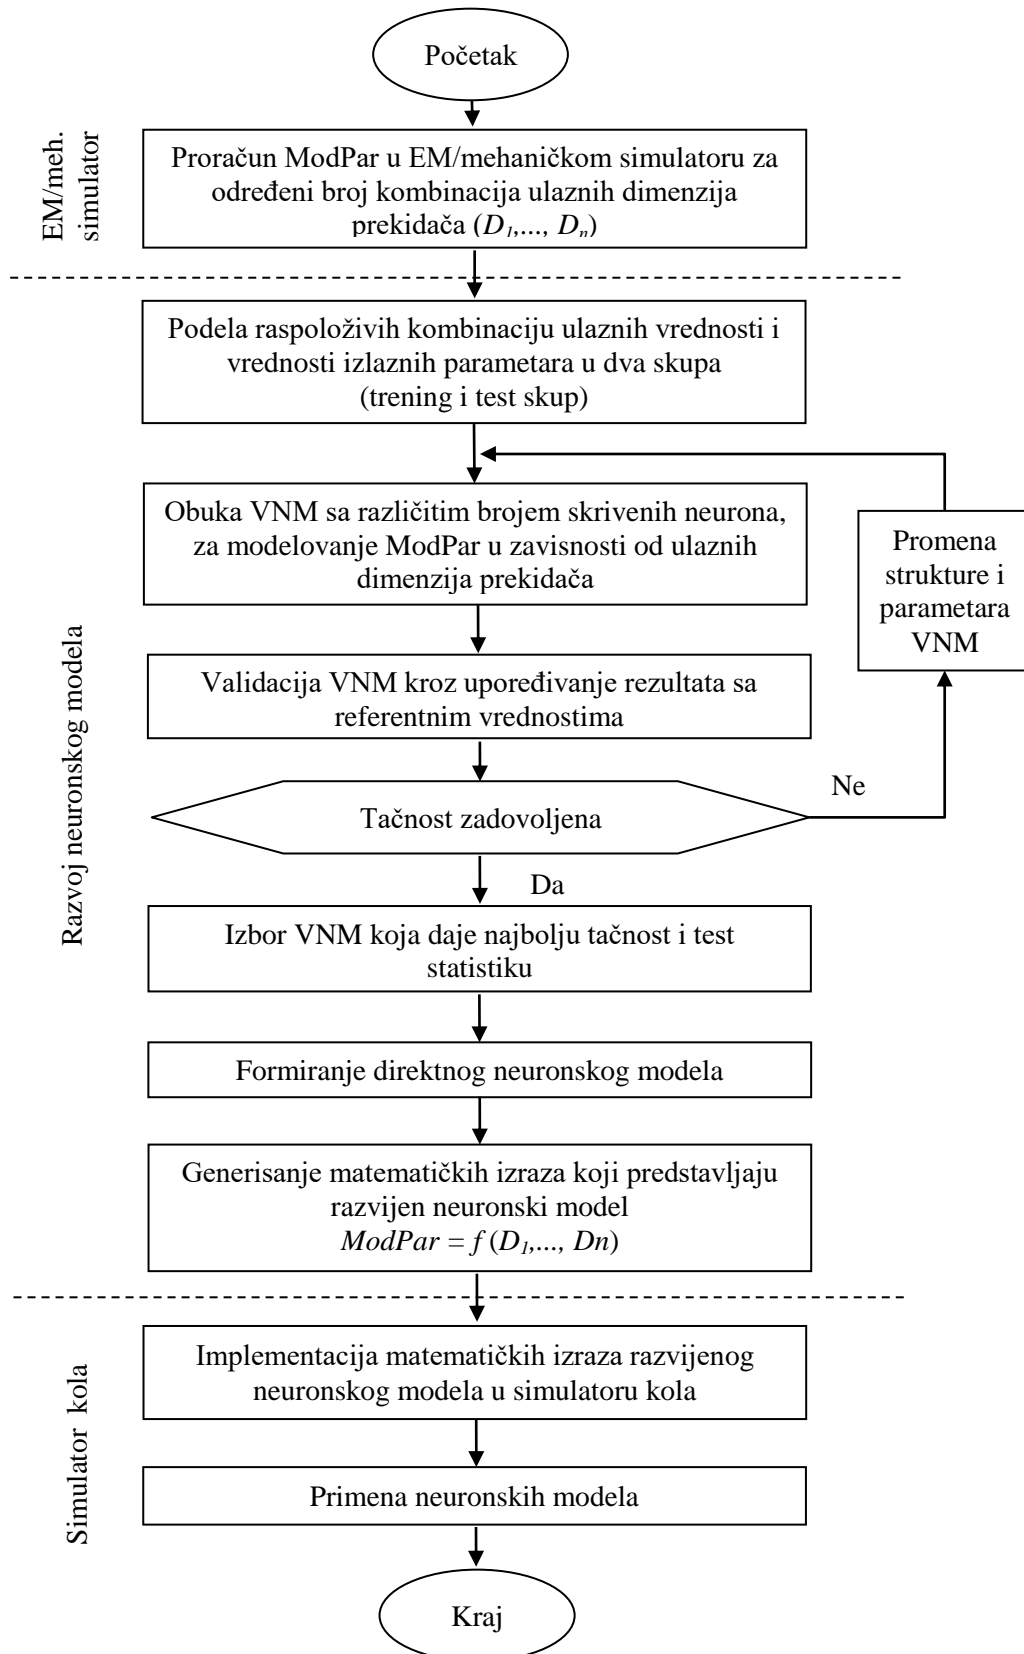
Imajući u vidu sposobnost učenja veštačkih neuronskih mreža, u ovoj disertaciji biće predložen alternativni način modelovanja baziran na primeni neuronskih modela za određivanje EM i mehaničkih karakteristika RF MEMS prekidača (opisanih u Poglavlju 2.6) u zavisnosti od geometrijskih dimenzija prekidača. Na Slici 4.1 prikazan je osnovni neuronski model (*black-box* model) razvijen za modelovanje parametara prekidača (ModPar) u zavisnosti od lateralnih dimenzija prekidača ( $D_1, D_2, \dots, D_n$ ). Modelovani parametri se odnose

na EM karakteristike prekidača (S-parametri i rezonantna frekvencija) i mehaničke karakteristike prekidača (napon aktivacije).



Slika 4.1 *Predloženi black-box neuronski model*

Osnova za formiranje neuronskih modela je postojanje dovoljnog broja kombinacija ulaznih vrednosti sa odgovarajućim izlaznim vrednostima modelovanih parametara. Na Slici 4.2 u formi blok dijagrama predstavljen je postupak formiranja i upotrebe predloženih neuronskih modela  $ModPar = f(D1, \dots, Dn)$ .




Slika 4.2 Blok dijagram razvoja i validacije predloženog neuronskog modela

#### 4.1 MODELOVANJE EM KARAKTERISTIKA - PARAMETRI RASEJANJA

Parametri rasejanja, odnosno S-parametri (*Scattering Parameters*), predstavljaju skup parametara koji se najčešće koriste za karakterizaciju mikrotalasnih sklopova [87]. Parametri rasejanja povezuju direktne i reflektovane komponente talasa na prilazima sklopa.

Pošto se RF MEMS prekidači mogu smatrati dvoprilaznim sklopovima, ovde će biti dat opis S-parametara za dvoprilazni sklop (Slika 4.3) [88]. Neka su  $V_1^+$  i  $V_1^-$  intenziteti incidentnog i reflektovanog talasa na ulazu (prilaz 1), a  $V_2^+$  i  $V_2^-$  intenziteti incidentnog i reflektovanog talasa na izlazu (prilaz 2).



Slika 4.3 Dvoprilazna mreža

Parametri rasejanja definišu se na sledeći način:

$$V_1^- = S_{11}V_1^+ + S_{12}V_2^+ \quad (4.1)$$

$$V_2^- = S_{21}V_1^+ + S_{22}V_2^+ \quad (4.2)$$

Parametar  $S_{11}$  predstavlja koeficijent refleksije na ulazu kada je izlaz prilagođen (nema refleksije na izlazu):

$$S_{11} = \left. \frac{V_1^-}{V_1^+} \right|_{V_2^+ = 0} \quad (4.3)$$

dok parametar  $S_{12}$  predstavlja koeficijent refleksije u inverznom smeru, kada je ulaz prilagođen:


$$S_{12} = \left. \frac{V_1^-}{V_2^+} \right|_{V_1^+ = 0} \quad (4.4)$$

Na sličan način se definišu parametri  $S_{21}$  i  $S_{22}$ :

$$S_{21} = \frac{V_2^-}{V_1^+} \Big|_{V_2^+ = 0} \quad (4.5)$$

$$S_{22} = \frac{V_2^-}{V_2^+} \Big|_{V_1^+ = 0} \quad (4.6)$$

Predložen je neuronski model za određivanje S-parametara razmatranog kapacitivnog prekidača za date vrednosti frekvencije i geometrijskih parametara prekidača, kao što je prikazano na Slici 4.4 [21, 23, 89]. RF MEMS je simetrična i recipročna komponenta gde je  $S_{22} = S_{11}$  i  $S_{12} = S_{21}$ , pa je dovoljno razviti model za parametre  $S_{11}$  i  $S_{21}$ .

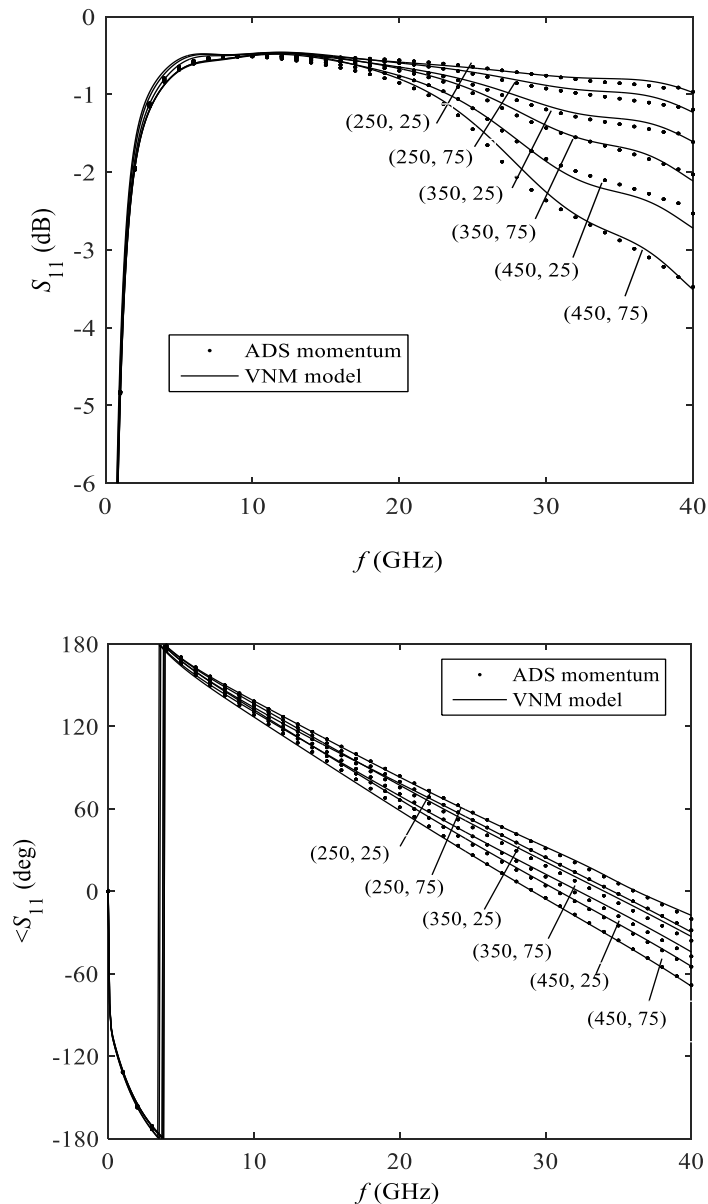


Slika 4.4 Neuronski model za S-parametre u zavisnosti od dimenzija mosta i frekvencije

U cilju postizanja što bolje tačnosti, primenjen je pristup dekompozicije, tj. posebni neuronski modeli su razvijeni za modelovanje parametara  $S_{11}$  i  $S_{21}$ , pri čemu se i moduli  $|S_{ij}|$  i faze  $\angle S_{ij}$  razmatranih parametara modeluju posebnim mrežama, VNM 1 i VNM 2, respektivno. Svaka od mreža ima po tri ulazna neurona koji odgovaraju frekvenciji,  $f$ , i geometrijskim dimenzijama prekidača:  $L_s$  - dužina osnove mosta i  $L_f$  - dužina prstiju mosta prekidača. Svaka veštačka neuronska mreža ima po jedan izlazni neuron za modelovani parametar. Optimalan broj neurona skrivenom sloju mreže ne može biti unapred određen, pa se određuje tokom postupka obučavanja mreže.

Mreže se obučavaju na osnovu vrednosti parametara  $S_{11}$  i  $S_{21}$  dobijenih pomoću numeričke *full-wave* simulacije. U konkretnom slučaju simulacije su vršene u softverskom paketu *Advanced Design System - ADS (ADS Momentum)* za frekvencije do 40GHz. S-parametri su simulirani za 23 kombinacije geometrijskih parametara  $L_s$  i  $L_f$ . Opsezi geometrijskih parametara su:  $L_s$  od 50  $\mu\text{m}$  do 500  $\mu\text{m}$  i  $L_f$  od 0  $\mu\text{m}$  do 100  $\mu\text{m}$ . Podaci koji se odnose na 17 kombinacija ovih parametara su korišćeni za obučavanje modela, a preostalih 6 kombinacija korišćeno je za testiranje modela.


Za svaku mrežu, u cilju određivanja broja skrivenih neurona, vrši se obučavanje više mreža sa različitim brojem skrivenih neurona. Najbolja mreža je određena analizom rezultata testiranja mreže na skupu podataka koji je korišćen za obučavanje i test skupu koji sadrži podatke koji nisu korišćeni za obučavanje mreža. Kao VNM koje su generisale najveću tačnost modelovanih parametara izabrane su sledeće mreže: za  $S_{11}$  – mreža od 8 neurona u prvom i 6 neurona u drugom sloju (2-8-6-1), za  $S_{21}$  – mreža sa po 8 neurona u oba skrivena sloja (2-8-8-1). Za faze parametara najbolje rezultate su dale mreže koje imaju po dva skrivena sloja sa po 10 neurona u svakom skrivenom sloju (2-10-10-1) [89].



Slika 4.5 Parametar  $S_{11}$  za test skup

Pošto su najbolje mreže izabrane, S-parametri za bilo koju kombinaciju razmatranih dimenzija mogu biti određeni praktično trenutno, jer se njihovo određivanje svodi na računanje odziva neuronske mreže.


Kao ilustracija tačnosti predloženih neuronskih modela, na Slikama 4.5 i 4.6 dato je poređenje simuliranih parametara rasejanja dobijenih pomoću razvijenih neuronskih modela (linije) i odgovarajućih referentnih vrednosti dobijenih elektromagnetskom analizom u ADS simulatoru (simboli) [23, 89].



Slika 4.6 Parametar  $S_{21}$  za test skup

Svi rezultati se odnose na kombinacije geometrijskih parametara koje nisu predstavljene odgovarajućim neuronskim mrežama tokom obučavanja. Može se uočiti da postoji veoma dobra podudarnost između simuliranih i referentnih vrednosti, što potvrđuje tačnost razvijenih neuronskih modela.

Na Slici 4.7 prikazana je karakteristika izolacije ( $S_{21}(dB)$ ) realizovanog RF MEMS kapacitivnog prekidača čije su vrednosti lateralnih dimenzija  $L_s=174 \mu m$  i  $L_f=40 \mu m$ .



Slika 4.7 Izolacija realizovanog RF MEMS kapacitivnog prekidača

Prikazano je poređenje merenih vrednosti (isprekidana linija), vrednosti dobijenih EM simulacijom u ADS simulatoru (simboli) i vrednosti dobijenih pomoću predloženog neuronskog modela (puna linija). Može se uočiti da se vrednosti dobijene pomoću neuronskog modela i EM simulatora skoro u potpunosti poklapaju, što je još jedna potvrda da se ovaj model može uspešno koristiti kao efikasna zamena za vremenski zahtevne EM simulacije. Odstupanja koja postoje između simuliranih i merenih vrednosti nastaju zbog tolerancija u realizaciji komponente i njihove vrednosti su uobičajene.

U cilju korišćenja razvijenog VNM modela za optimizaciju dimenzija prekidača, izvršena je njegova implementacija u mikrotalasni simulator kola u okviru programskog paketa ADS. Naime, svaka neuronska mreža se može opisati pomoću odgovarajućih matematičkih izraza, koji omogućavaju da se zavisnost između ulaznih i izlaznih parametara mreže može predstaviti u zatvorenom obliku. Izrazi kojima su definisane neuronske mreže implementirani su u ADS tako što je prekidač predstavljen kao dvoprilazni element opisan svojim S-parametrima. Pri tome su matematički izrazi za S-parametre definisani u funkciji



lateralnih dimenzija prekidača i frekvencije. Pomoću ovako implementiranog modela, vrednosti S parametara za proizvoljne dimenzije prekidača određuju se za manje od sekunde, dok je u elektromagnetskom simulatoru za to potrebno nekoliko minuta.

Nakon implementacije VNM modela u simulator kola, optimizacija dimenzija prekidača za zadate uslove se obavlja na način standardan za mikrotalasne simulatore kola. Optimizovanje dimenzija za zadate željene vrednosti karakteristika prekidača u mikrotalasnom simulatoru kola traje oko jedne sekunde. Na ovaj način ostvaruje se izuzetno velika ušteda u vremenu optimizacije u poređenju sa elektromagnetnom optimizacijom koja traje oko 2 sata.

## 4.2 MODELOVANJE EM KARAKTERISTIKA - REZONANTNA FREKVENCIJA

Proces modelovanja RF MEMS prekidača često ne zahteva određivanje zavisnosti parametara rasejanja za celi frekvencijski opseg, već samo tačne vrednosti rezonantne frekvencije. Iz tog razloga, predloženo je modelovanje rezonantne frekvencije u zavisnosti od lateralnih dimenzija mosta RF MEMS prekidača. Razvoj predloženih neuronskih modela predstavlja nastavak istraživanja prikazanih u [90]. Naime, veštačka neuronska mreža je obučavana za predikciju rezonantne frekvencije u zavisnosti od dva geometrijska parametra prekidača  $L_s$  i  $L_f$ , kao što je prikazano na Slici 4.8. [23, 89].



Slika 4.8 Veštačka neuronska mreža za modelovanje RF MEMS prekidača

Razvoj i validacija predloženog neuronskog modela vršena je u skladu sa koracima koji su prikazani na Slici 4.2.


Kao što su obučavane mreže za modelovanje parametara rasejanja, tako su i veštačke neuronske mreže za modelovanje rezonantne frekvencije obučavane i testirane su skupom podataka dobijenim standardnim *full-wave* simulacijama u elektromagnetnom simulatoru (*Advanced Design System*). Naime, za iste 23 kombinacije dimenzija mosta prekidača

korišćenih u prethodnom slučaju modelovanja S-parametara, određena je rezonantna frekvencija kao frekvencija koja odgovara minimumu modula parametara  $S_{21}$ . Od ukupnog broja kombinacija, 17 je korišćeno za obučavanje, a preostalih 6 za validaciju razvijenog modela. Validacija modela vršena je upoređivanjem rezultata odziva mreže sa rezultatima dobijenim iz *full-wave* simulatora za kombinacije geometrijskih dimenzija RF MEMS prekidača koje nisu korišćene u postupku obučavanja veštačke neuronske mreže. Jednom obučena mreža može se koristiti za brzo izračunavanje rezonantne frekvencije za proizvoljne vrednosti geometrijskih parametara ili za optimizaciju dimenzija prekidača kako bi se postigla željena rezonantna frekvencija.

Nakon obučavanja većeg broja veštačkih neuronskih mreža različitih struktura i upoređivanja rezultata, zaključeno je da su najbolji rezultati postignuti veštačkom neuronskom mrežom sa jednim skrivenim slojem od pet neurona (2-5-1) [89]. Tabela 4.1 predstavlja vrednosti odziva izabrane VNM, tj. rezonantne frekvencije za nekoliko kombinacija geometrijskih parametara  $L_s$  i  $L_f$  koji nisu korišćeni u procesu obučavanja mreža [89]. Vrednosti rezonantne frekvencije dobijeni kao odziv VNM se veoma malo razlikuju od referentnih vrednosti dobijenih *full-wave* simulacijama. Procentualna relativna greška je manja od 0.6%, a apsolutno odstupanje  $f_{res}$  od željene vrednosti nije veće od 0.08 GHz. Navedeno potvrđuje tačnost predloženog neuronskog modela. Slika 4.9 dodatno potvrđuje dobru korelaciju izlaznih vrednosti VNM i referentnih vrednosti iz test skupa.

Tabela 4.1 Rezultati testiranja modela na test skupu

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	$f_{res}$ (target) (GHz)	$f_{res}$ (VNM) (GHz)	Relativna greška (%)
250	25	13.689	13.7	0.08
250	75	12.403	12.4	0.02
350	25	11.550	11.6	0.43
350	75	10.638	10.7	0.58
450	25	10.127	10.2	0.71
450	75	9.4990	9.5	0.01



Slika 4.9 Korelacija izlaznih vrednosti test skupa

### 4.3 MODELOVANJE MEHANIČKIH KARAKTERISTIKA - NAPON AKTUACIJE

Simulacije kola sa RF MEMS prekidačima, pored EM karakteristika, zahteva i poznavanje mehaničkih karakteristika prekidača. Najčešće se mehaničke karakteristike RF MEMS prekidača simuliraju u mehaničkim simulatorima baziranim na metodu konačnih elemenata (*FEM-Finite Element Method*) [19, 20]. Takve simulacije su veoma složene matematičke procedure i zahtevaju značajne računarske resurse. Moguća alternativa su analitički postupci koji mogu biti upotrebljeni samo za jednostavnije konfiguracije prekidača, npr. za određivanje napona aktucije kod prekidača sa mostom jednostavnijeg oblika. Imajući u vidu sposobnost učenja VNM, u ovoj disertaciji razmatran je neuronski model za određivanje napona aktucije RF MEMS prekidača (opisanog u Poglavlju 2.6) koji ima kompleksniji oblik mosta prekidača i za koji ne postoje odgovarajući analitički postupci. Ovim modelom se mogu odrediti karakteristike prekidača u veoma kratkom vremenskom periodu, umanjujući ukupno vreme potrebno za simulaciju i optimizaciju elektronskih kola u koja se ugrađuje RF MEMS prekidač.

Predloženi model baziran na VNM formira se u cilju modelovanja napona aktucije  $V_{PI}$  u zavisnosti od geometrijskih parametara  $L_s$  i  $L_f$  razmatranog prekidača [23]. Na Slici 4.10 prikazana je blok šema predloženog modela. Model ima dva neurona na ulazu, što odgovara

broju ulaznih parametara i jedan neuron na izlazu koji odgovara naponu aktivacije. Veštačka neuronska mreža se obučava vrednostima napona aktivacije koji su dobijeni proračunima u standardnom mehaničkom simulatoru (u konkretnom slučaju *COMSOL Multiphysics*) za određeni broj kombinacija geometrijskih parametara razmatranog prekidača. Razvoj i validacija predloženog neuronskog modela vršeni su u skladu sa koracima koji su prikazani na Slici 4.2.



Slika 4.10 *Neuronski model za određivanje zavisnosti napona aktivacije od dimenzija prekidača [23]*


Za razliku od vremenski zahtevnih mehaničkih simulatora, ovaj neuronski model se može koristiti za praktično trenutno određivanje napona aktivacije za bilo koju kombinaciju vrednosti razmatranih geometrijskih parametara koji su u opsegu vrednosti ulaznih parametara korišćenih za obučavanje VNM.

Modeli razmatranog RF MEMS prekidača razvijani su u sledećim opsezima geometrijskih parametara:  $L_s$  od 50  $\mu\text{m}$  do 500  $\mu\text{m}$  i  $L_f$  od 0  $\mu\text{m}$  do 100  $\mu\text{m}$ . Za trening i test veštačkih neuronskih mreža korišćen je skup od 39 različitih kombinacija vrednosti parametara  $L_s$  i  $L_f$ . Vrednosti su izabrane tako da pokrivaju razmatrani opseg vrednosti  $L_s$  i  $L_f$ . Trening skup čini 30 kombinacija, dok je preostalih devet kombinacija iskorišćeno za test skup i validaciju neuronskih modela. Nakon obučavanja i testiranja većeg broja modela sa različitim brojem skrivenih slojeva i različitim brojem neurona u njima, izabran je model koji je generisao rezultate najpribližnije ciljnim vrednostima dobijenim proračunima u simulatoru. Test rezultati najboljih modela prikazani su u Tabeli 4.2, a test rezultati predstavljeni su prosečnom test greškom (*Average Test Error*), slučajem najveće greške (*Worst Case Error*) i *Pearson Product-Moment* korelacionim koeficijentom ( $r$ ). Što je vrednost korelacionog koeficijenta bliža vrednosti 1, to mreža ima bolju karakteristiku predikcije.

Najbolji rezultati postignuti su neuronskim modelom (2-8-1) koji se sastoji od jednog skrivenog sloja sa osam neurona [91, 92]. Navedena mreža je dala najbolju korelaciju sa ciljnim vrednostima, pa je uzeta kao model za direktno modelovanje napona aktivacije RF MEMS kapacitivnog prekidača. Slika 4.11 prikazuje kvalitet učenja izabrane mreže, kroz odličnu korelaciju izlaznih vrednosti VNM sa ciljnim vrednostima trening skupa.

Tabela 4.2 Rezultati testiranja neuronskih modela sa različitim brojem skrivenih neurona

VNM	Prosečna greška [%]	Najveća greška [%]	$r$
2-8-1	0.4748	2.0509	0.999699
2-7-1	1.4002	2.0809	0.999262
2-10-1	1.5681	7.2761	0.998522
2-12-10-1	3.2185	6.6676	0.997469
2-4-8-1	2.4898	9.4751	0.993483
2-6-10-1	4.7447	12.8084	0.988190
2-8-4-1	5.0989	32.4658	0.984274
2-15-1	7.6388	27.7394	0.971306
2-20-1	7.5248	15.4413	0.966336
2-20-25-1	12.3220	20.7663	0.929204
2-24-20-1	10.5290	16.7665	0.928777




Slika 4.11 Korelacija izlaza VNM i referentnih vrednosti za trening podatke [75]

U Tabeli 4.3 prikazani su rezultati validacije najboljeg modela na test skupu [91, 92]. Na osnovu prikazanih rezultata može se zaključiti da je najveća relativna greška 1.1%, a apsolutna greška za sve kombinacije manja od 0.45 V. Takođe, na Slici 4.12 evidentna je vrlo dobra korelacija izlaznih vrednosti VNM sa simuliranim vrednostima za kombinacije iz test skupa. Uzimajući u obzir da kombinacije ulaznih vrednosti iz test skupa nisu korišćene u procesu obučavanja neuronskog modela, može se konstatovati da je postignuta vrlo dobra generalizacija modela za nove kombinacije geometrijskih parametara. Rezultati test skupa prilikom validacije modela pokazuju da je model sposoban da precizno generiše napon aktuacije za date vrednosti dimenzija mosta RF MEMS prekidača. Pored toga, primenom

razvijenih neuronskih modela za određivanje napona aktivacije za različite kombinacije vrednosti razmatranih dimenzija, može se ostvariti značajna ušteda u vremenu, što je osnovna prednost u odnosu na simulacije u mehaničkim simulatorima koje traju i po nekoliko časova. Upravo zbog navedene karakteristike VNM da trenutno generiše odziv, ovi modeli se mogu efikasno koristiti za ispitivanje osetljivosti promene napona aktivacije usled promena dimenzija prekidača ili za optimizaciju dimenzija prekidača, a što će biti detaljno opisano u Poglavljima 4.4.2 i 4.4.5.

Tabela 4.3 Rezultati testiranja neuronskog modela za napon aktivacije RF MEMS prekidača

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	$V_{PI}(\text{target})$ (V)	$V_{PI}(\text{VNM})$ (V)	Apsolutna greška (V)	Relativna greška (%)
150	25	55.6	55.58	0.02	0.01
150	65	43	43.45	0.45	1.10
250	25	33.3	33.16	0.14	0.40
250	65	28.2	28.21	0.01	0.03
350	10	25.2	25.32	0.12	0.47
350	25	23.8	23.74	0.06	0.25
350	65	21.1	20.99	0.11	0.54
350	75	20.5	20.45	0.35	0.17
450	65	16.9	16.80	0.10	0.57



Slika 4.12 Korelacija izlaza VNM i referentnih vrednosti iz test skupa [91, 92]


#### **4.4 PRIMENA RAZVIJENIH BLACK-BOX MODELA ZA ANALIZU I PROJEKTOVANJE RF MEMS PREKIDAČA**

Kao što je ilustrovano u prethodnim primerima, EM karakteristike (S-parametri i rezonantna frekvencija) zavise direktno od lateralnih dimenzija prekidača. Iz tog razloga, u procesu projektovanja RF MEMS prekidača potrebni su pouzdani i tačni modeli pomoću kojih se određuju lateralne dimenzije prekidača kako bi se ostvarile željene elektromagnetne i mehaničke karakteristike prekidača. Međutim, prilikom izrade komponenata dolazi do izvesnih odstupanja dimenzija od nominalnih projektovanih vrednosti, što utiče na pojavu odstupanja karakteristika komponenata od željenih vrednosti. Zato je korisno poznavati ponašanje karakteristika usled promena dimenzija prekidača. U ovom poglavlju ilustrovano je kako su predloženi direktni neuronski modeli (*black-box* modeli) iskorišćeni kao efikasno, pouzdano i tačno sredstvo u analizi osetljivosti karakteristika RF MEMS prekidača. Predloženi neuronski modeli opisani u ovoj glavi (Slike 4.4, 4.8 i 4.10) iskorišćeni su za analizu osetljivosti EM i mehaničkih karakteristika RF MEMS kapacitivnih i omskih prekidača u zavisnosti od promena lateralnih dimenzija mosta prekidača. Takođe, analiziran je uticaj malih promena dimenzija mosta prekidača (u granicama fabričke tolerancije) nastalih tokom fabrikacije komponente na parametre rasejanja, rezonantnu frekvenciju i napon aktuacije prekidača.


##### **4.4.1 Analiza osetljivosti rezonantne frekvencije RF MEMS kapacitivnog prekidača**

Kao što je prethodno opisano u Poglavlju 4.2, veštačke neuronske mreže mogu se uspešno koristiti za modelovanje zavisnosti rezonantne frekvencije od lateralnih dimenzija prekidača. Kod razmatranog primera, VNM je obučavana za predikciju rezonantne frekvencije na osnovu dva geometrijska parametra mosta prekidača  $L_s$  i  $L_f$  u sledećim opsezima:  $L_s$  od 100  $\mu\text{m}$  do 500  $\mu\text{m}$  i  $L_f$  od 0  $\mu\text{m}$  do 100  $\mu\text{m}$ . Za analizu osetljivosti rezonantne frekvencije u odnosu na promene lateralnih dimenzija prekidača korišćena je mreža opisana u Poglavlju 4.2. Kako bi se obezbedila sveobuhvatna analiza promene rezonantne frekvencije razmatranog modela, u analizi su korišćene tri karakteristične vrednosti dimenzije prekidača (na početku, sredini i kraju razmatranog opsega lateralnih dimenzija) [23, 93]. Na Slici 4.13 predstavljene su promene rezonantne frekvencije za tri vrednosti  $L_s$  (200  $\mu\text{m}$ , 300  $\mu\text{m}$  i 450  $\mu\text{m}$ ) u celom opsegu vrednosti  $L_f$ , dok je su na Slici 4.14

prikazane vrednosti rezonantne frekvencije za tri vrednosti  $L_f$  (20  $\mu\text{m}$ , 50  $\mu\text{m}$  i 80  $\mu\text{m}$ ) u opsegu vrednosti  $L_s$ .




Slika 4.13 Rezonantna frekvencija RF MEMS prekidača u zavisnosti od  $L_f$



Slika 4.14 Rezonantna frekvencija RF MEMS prekidača u zavisnosti od  $L_s$


U daljoj analizi, za svaki navedeni slučaj određena je rezonantna frekvencija za vrednosti razmatranih parametara uz odstupanja  $\pm 5 \mu\text{m}$  (sa korakom od  $1 \mu\text{m}$ ), a takođe i za odstupanje od  $+10 \mu\text{m}$  i  $-10 \mu\text{m}$ . Odnosno, razmatran je slučaj kada je jedna od dimenzija konstantna, a druga dimenzija mosta prekidača se menja u navedenom opsegu. Dobijeni grafici prikazani su na Slikama 4.15 i 4.16, dok su vrednosti prosečnih devijacija rezonantne frekvencije za promene  $L_s$  i  $L_f$  ( $Avg|\Delta f_{res}/f_{res}|$ ) prikazane na Slikama 4.17 i 4.18 [93].






Slika 4.15 Promene rezonantne frekvencije RF MEMS prekidača u zavisnosti od  $L_f$ :


a)  $L_s = 200 \mu\text{m}$ , b)  $L_s = 300 \mu\text{m}$  i c)  $L_s = 450 \mu\text{m}$



a)



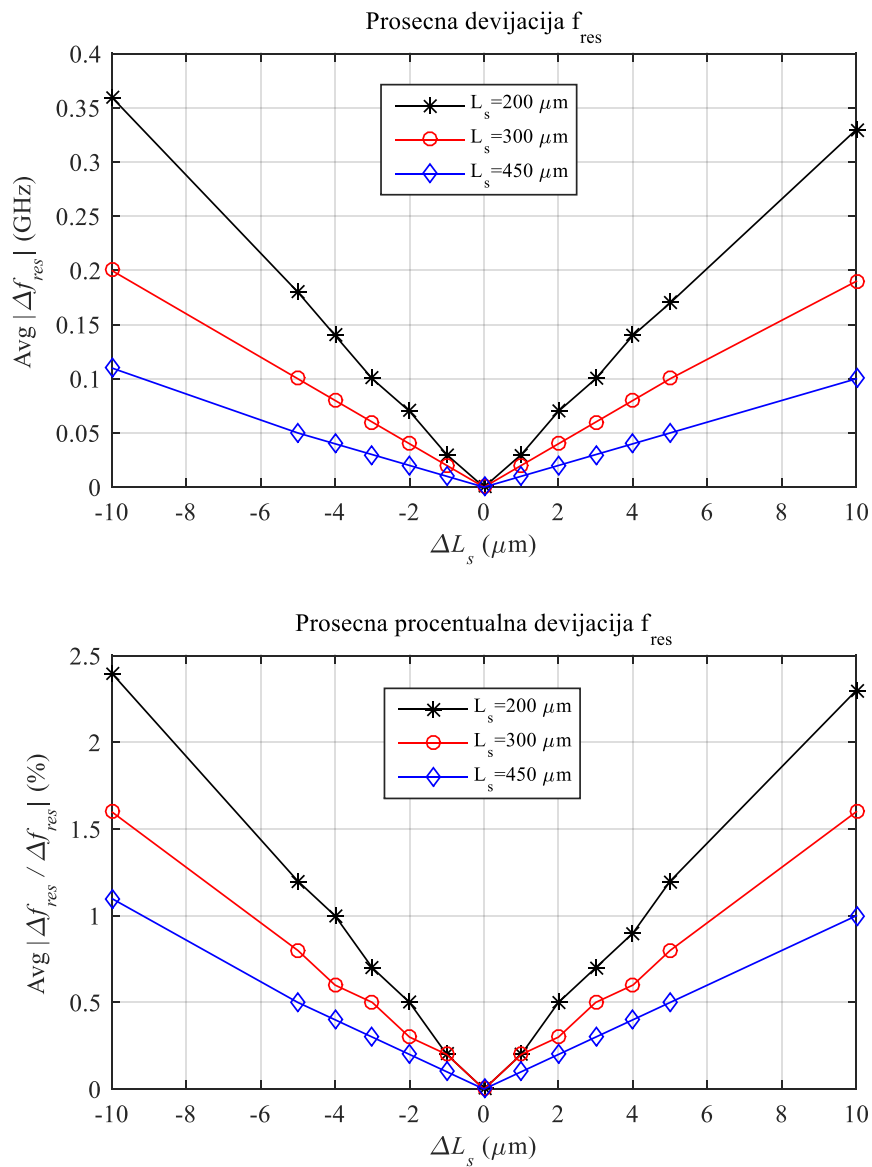
b)



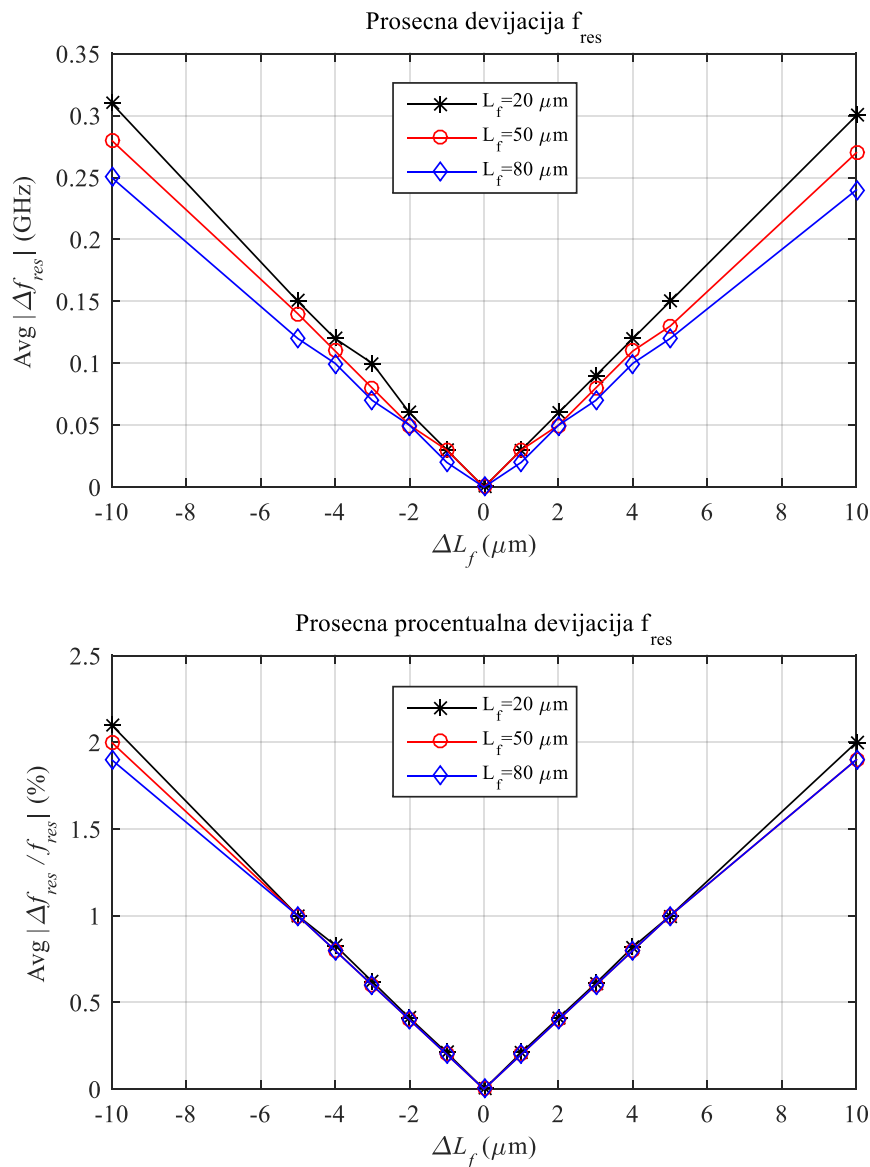
c)

Slika 4.16 Promene rezonantne frekvencije RF MEMS prekidača u zavisnosti od  $L_s$ :

a)  $L_f = 20 \mu\text{m}$ , b)  $L_f = 50 \mu\text{m}$  i c)  $L_f = 80 \mu\text{m}$



Slika 4.17 Prosečne devijacije rezonantne frekvencije za promene  $L_s$



Slika 4.18 Prosečne devijacije rezonantne frekvencije za promene  $L_f$

Može se zaključiti da je promena rezonantne frekvencije najizraženija kod odstupanja dimenzija mostova prekidača malih dimenzija, tj. kad su vremenski obe dimenzije mosta prekidača u donjem delu razmatranih opsega. Navedeno je naročito uočljivo sa promenama vrednosti  $L_s$ . Takođe, jednake promene vrednosti  $L_s$  i  $L_f$  ne uzrokuju ista odstupanja rezonantne frekvencije. Naime, promene dimenzije  $L_s$  uzrokuju veća odstupanja rezonantne frekvencije u odnosu na iste promene dimenzije  $L_f$ . Apsolutna promena rezonantne frekvencije uglavnom je ista kada je jedna od razmatranih dimenzija uvećana ili umanjena za istu vrednost. Za sve analizirane vrednosti  $L_f$  u opsegu do  $\pm 5 \mu\text{m}$ , odstupanje rezonantne

frekvencije u maloj meri zavisi od vrednosti  $L_f$ , dok u slučaju  $L_s$  promene se smanjuju sa porastom vrednosti  $L_s$ . Uzimajući u obzir sve razmatrane slučajeve, prosečan procenat greške je manji od 1% za analizirana odstupanja od +/- 5  $\mu\text{m}$ .

Zatim je izvršena analiza osetljivosti rezonantne frekvencije prilikom istovremene promene obe vrednosti lateralnih dimenzija mosta. U Tabeli 4.4 prikazani su uporedni rezultati analize kada se za određeni broj kombinacija istovremeno menjaju dimenzije  $L_s$  i  $L_f$  u opsezima +/- 5  $\mu\text{m}$  i +/- 3  $\mu\text{m}$  (sa korakom od 1  $\mu\text{m}$ ) [93]. Na osnovu prikazanih rezultata, može se zaključiti da je maksimalno odstupanje rezonantne frekvencije manje od 3% kod promena od +/-5  $\mu\text{m}$ , dok je za opseg promena dimenzija mosta od +/- 3  $\mu\text{m}$  maksimalno odstupanje manje od 1.5%. Dakle, prikazani rezultati ukazuju da je odstupanje rezonantne frekvencije prihvatljivo i u slučajevima kada se istovremeno menjaju obe dimenzije mosta u granicama fabričke tolerancije. To znači da odstupanja projektovanih vrednosti dimenzija mosta koja mogu nastati u toku fabrikacije ne dovode do značajnih promena vrednosti rezonantne frekvencije.


Tabela 4.4 Promena  $f_{res}$  za istovremenu promenu dimenzija za +/- 5  $\mu\text{m}$  i +/- 3  $\mu\text{m}$

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	promene za +/- 5 $\mu\text{m}$		promene za +/- 3 $\mu\text{m}$	
		Max $ \Delta f_{res} $ (GHz)	Max $ \Delta f_{res}/f_{res} $ (%)	Max $ \Delta f_{res} $ (GHz)	Max $ \Delta f_{res}/f_{res} $ (%)
200	20	0.40	2.6	0.24	1.5
200	50	0.34	2.4	0.20	1.4
200	80	0.29	2.2	0.17	1.3
300	20	0.22	1.8	0.13	1.1
300	50	0.21	1.7	0.12	1.0
300	80	0.19	1.7	0.11	0.1
450	20	0.13	1.3	0.08	0.8
450	50	0.12	1.2	0.07	0.7
450	80	0.10	1.1	0.06	0.6


#### 4.4.2 Analiza osetljivosti napona aktivacije RF MEMS kapacitivnog prekidača

Na osnovu rezultata postignutih neuronskim modelom predloženim u Poglavlju 4.3, zaključeno je da se veštačkim neuronskim mrežama može uspešno modelovati zavisnost napona aktivacije modelovanog prekidača u odnosu na lateralne dimenzije prekidača koje su u sledećim opsezima:  $L_s$  od 125  $\mu\text{m}$  do 500  $\mu\text{m}$  i  $L_f$  od 0  $\mu\text{m}$  do 100  $\mu\text{m}$ . Isti neuronski model iskorišćen je za analizu osetljivosti napona aktivacije u odnosu na promene lateralnih


dimenzija prekidača [23, 94]. Kao i u slučaju analize osetljivosti rezonantne frekvencije, u analizi osetljivosti napona aktivacije korišćene su tri karakteristične vrednosti lateralnih dimenzija (na početku, sredini i kraju razmatranog opsega) kako bi se obezbedila detaljna analiza promene napona aktivacije razmatranog modela. Na Slici 4.19 predstavljene su promene napona aktivacije za tri vrednosti  $L_s$  (200  $\mu\text{m}$ , 300  $\mu\text{m}$  i 450  $\mu\text{m}$ ) u celom opsegu vrednosti  $L_f$ , dok je su na Slici 4.20 prikazane vrednosti napona aktivacije za tri vrednosti  $L_f$  (20  $\mu\text{m}$ , 50  $\mu\text{m}$  i 80  $\mu\text{m}$ ) u opsegu vrednosti  $L_s$  [94].




Slika 4.19 Napon aktivacije RF MEMS prekidača u zavisnosti od  $L_f$




Slika 4.20 Napon aktivacije RF MEMS prekidača u zavisnosti od  $L_s$



a)




b)




c)

Slika 4.21 Promene napona aktivacije RF MEMS prekidača u zavisnosti od  $L_f$ :


a)  $L_S = 200 \mu\text{m}$ , b)  $L_S = 300 \mu\text{m}$  i c)  $L_S = 450 \mu\text{m}$



a)



b)



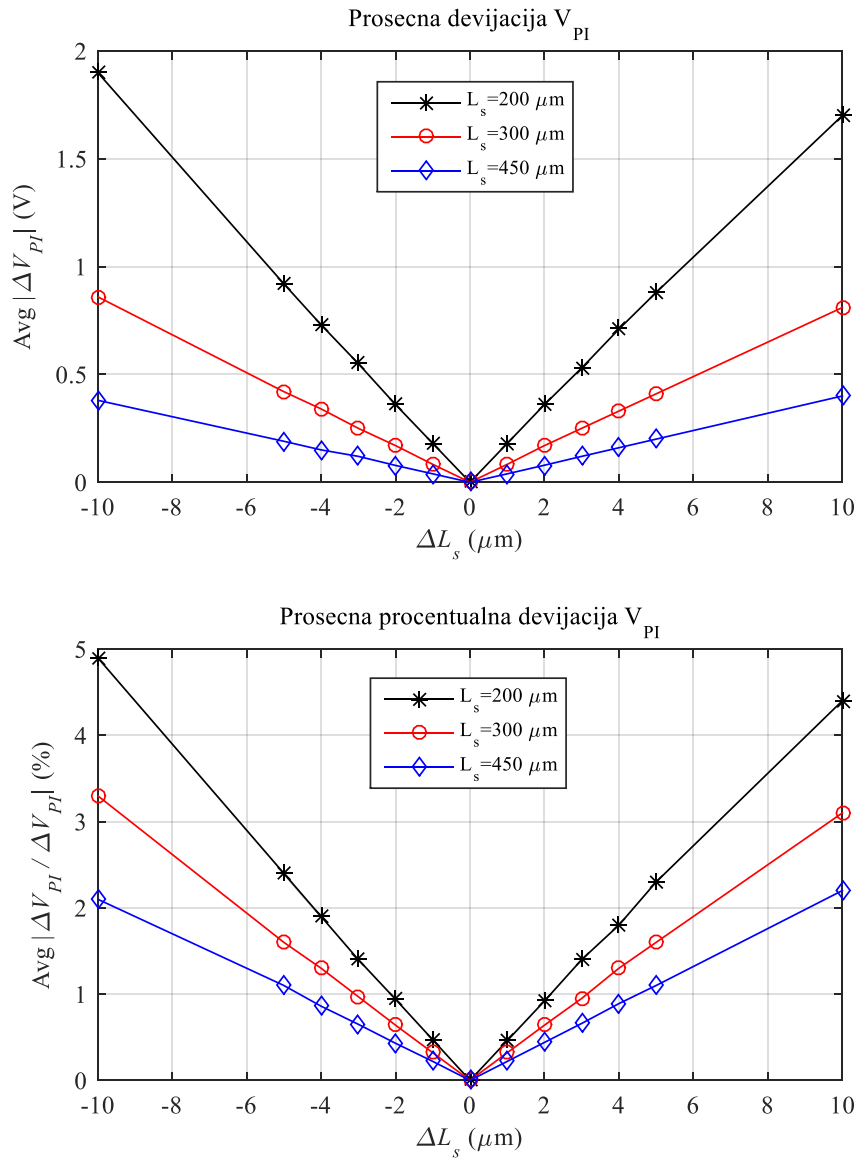
c)

Slika 4.22 Promene napona aktivacije RF MEMS prekidača u zavisnosti od  $L_s$ :

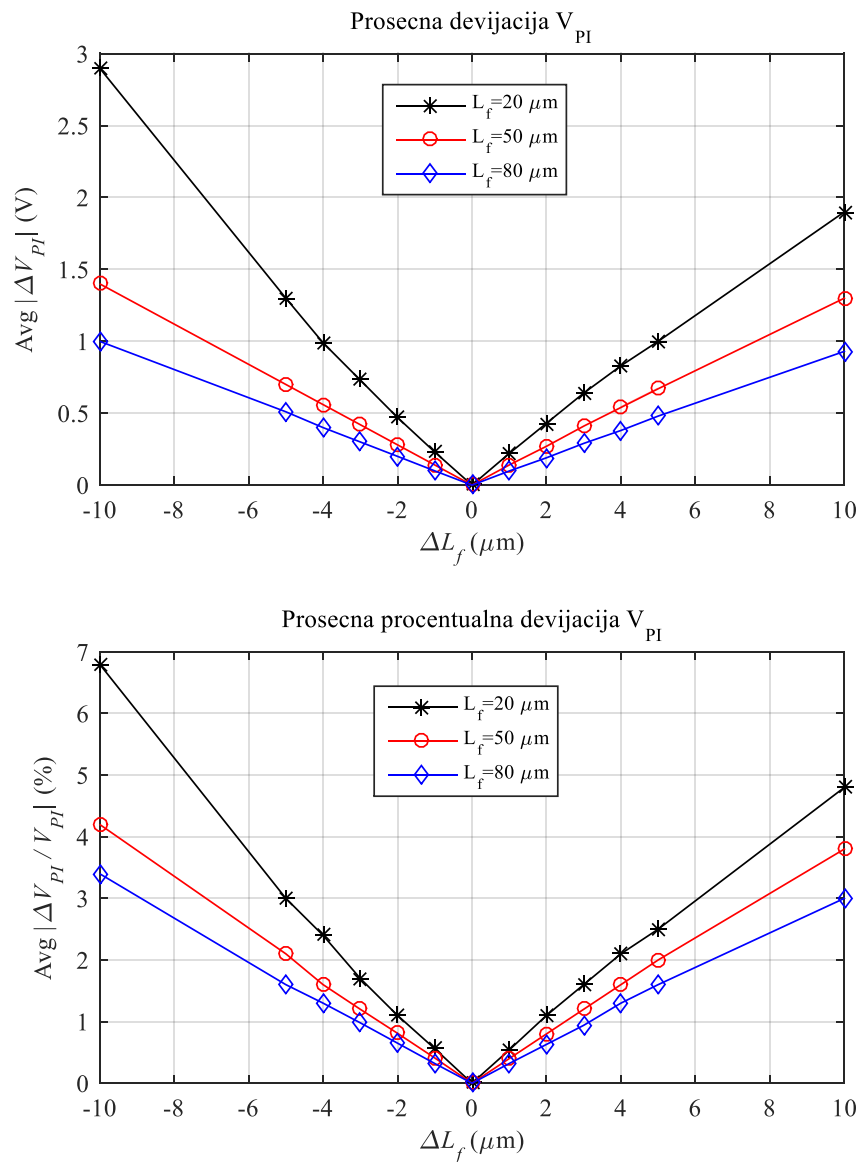
a)  $L_f = 20 \mu\text{m}$ , b)  $L_f = 50 \mu\text{m}$  i c)  $L_f = 80 \mu\text{m}$



U daljoj analizi, analiziran je slučaj kada je jedna od dimenzija konstantna, a druga dimenzija mosta prekidača se menja u datom opsegu. Odnosno, za svaki navedeni slučaj određen je napon aktivacije za vrednosti razmatranih parametara uz odstupanja  $\pm 5 \mu\text{m}$  (sa korakom od  $1 \mu\text{m}$ ), a takođe i za odstupanje od  $+10 \mu\text{m}$  i  $-10 \mu\text{m}$ . Dobijeni rezultati prikazani su na graficima na Slikama 4.21 i 4.22, a odgovarajuća odstupanja sa prosečnim vrednostima devijacije napona aktivacije usled promena  $L_s$  i  $L_f$  prikazana su na Slikama 4.23. i 4.24 [94].



Slika 4.23 Prosečne devijacije napona aktivacije za promene  $L_s$



Slika 4.24 Prosečne devijacije napona aktivacije za promene  $L_f$

Na osnovu prikazanih rezultata može se zaključiti da je apsolutna promena napona aktivacije uglavnom ista kada je jedna od razmatranih dimenzija uvećana ili umanjena za istu vrednost. Takođe, potvrđeno je da su manje promene napona aktivacije za veće dimenzije mosta prekidača. Odnosno, izraženija je osetljivost napona aktivacije za promene mosta manjih dimenzija, tj. kad su obe lateralne dimenzije mosta u donjem delu razmatranih opsega. Uzimajući u obzir sve razmatrane slučajeve, prosečan procenat greške je manji od 3% za analizirana odstupanja do  $\pm 5 \mu\text{m}$ .

Tabela 4.5 Promena  $V_{PI}$  za istovremene promene dimenzija  $\pm 5 \mu\text{m}$  i  $\pm 3 \mu\text{m}$ 

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	promene $V_{PI}$ za $\pm 5 \mu\text{m}$		promene $V_{PI}$ za $\pm 3 \mu\text{m}$	
		$Max  \Delta V_{PI} $ (V)	$Max  \Delta V_{PI} / V_{PI} $ (%)	$Max  \Delta V_{PI} $ (V)	$Max  \Delta V_{PI} / V_{PI} $ (%)
200	20	3	7	1.7	3.9
200	50	1.9	5.2	1.1	3.1
200	80	1.3	4	0.76	2.4
300	20	1	3.7	0.61	2.1
300	50	0.87	3.4	0.51	2
300	80	0.72	3.1	0.43	1.9
450	20	0.64	3.2	0.38	1.9
450	50	0.53	3	0.31	1.8
450	80	0.3	1.9	0.18	1.1

Zatim su za određeni broj kombinacija dimenzija mosta prekidača istovremeno menjane vrednosti obe dimenzije u opsegu  $\pm 5 \mu\text{m}$  i  $\pm 3 \mu\text{m}$ , a uporedni pregled maksimalnih odstupanja prikazan je u Tabeli 4.5 [94]. U prvom slučaju, maksimalno odstupanje napona aktivacije je manje od 7% za istovremene promene lateralnih dimenzija prekidača od  $\pm 5 \mu\text{m}$ . Dok je u drugom slučaju, maksimalno odstupanje napona aktivacije je manje od 4% za istovremene promene dimenzija mosta od  $\pm 3 \mu\text{m}$ . Ako se posmatraju apsolutne vrednosti ovih odstupanja, za promene u opsegu  $\pm 5 \mu\text{m}$  maksimalno odstupanje je 3 V, a u opsegu  $\pm 3 \mu\text{m}$  maksimalno odstupanje je 1 V. Ovi rezultati pokazuju da odstupanja vrednosti dimenzija u procesu fabrikacije ne menjaju u značajnoj meri vrednost napona aktivacije. Međutim, veoma je važno voditi računa o smeru promene napona aktivacije, jer ukoliko napon aktivacije padne ispod minimalne vrednosti, može doći do nepravilnog rada prekidača.


#### 4.4.3 Analiza osetljivosti S-parametara RF MEMS omskog prekidača

U ovom poglavlju predstavljena je primena modela razvijenih na bazi veštačkih neuronskih mreža u analizi S-parametara RF MEMS omskog prekidača. Odnosno, predloženi neuronski model generiše odnos između lateralnih dimenzija mosta prekidača i S-parametara, a što je kasnije iskorišćeno za brzu i efikasnu analizu promena S-parametara u uslovima malih promena dimenzija mosta prekidača.

Neuronski model modeluje S-parametre u zavisnosti od frekvencije ( $f$ ), lateralnih dimenzija mosta prekidača (dužina mosta -  $L_b$ , širina mosta -  $W_b$ ) i lateralnih dimenzija procepa u prostoru oko mosta prekidača (lateralna dužina procepa -  $L_g$ , longitudinalna dužina procepa -  $W_g$ ). Modelovana komponenta RF MEMS omskog prekidača sa naznačenim

dimenzijama mosta prekidača opisana je u Poglavlju 2.6. U postupku modelovanja omskog RF MEMS prekidača veoma važno je odrediti optimalne dimenzije procepa između mosta i tela prekidača kako bi se postigla željena ulazno-izlazna impedansa. Pored toga, dodatni zahtev u procesu optimizacije prekidača je održavanje nivoa povratnog slabljenja ispod zadate vrednosti u definisanom frekvenzijskom opsegu. Uzimajući sve u obzir, predložen je model (Slika 4.25) na bazi MLP mreža koji se sastoji od četiri mreže koje modeluju magnitude ( $|S_{ij}|$ ) i faze ( $\angle S_{ij}$ ) za  $S_{11}$  i  $S_{21}$  parametre u odnosu na frekvenciju i lateralne dimenzije mosta prekidača. Detaljan opis modela prikazan je u radu [95].

RF MEMS omski prekidači su kao RF MEMS kapacitivni prekidači simetrične i recipročne komponente, te je uzeta jednakost da su  $S_{22} = S_{11}$  i  $S_{12} = S_{21}$ , pa se predloženi neuronski model može koristiti za predikciju sva četiri S-parametra. Svaka od četiri neuronska modela ima pet ulaznih neurona koji odgovaraju ulaznim parametrima lateralnih dimenzija i frekvencije, kao i jedan neuron u izlaznom sloju za jedan od modelovanih parametara ( $|S_{11}|(\text{dB}), \angle S_{11}(\text{°}), |S_{21}|(\text{dB}), \angle S_{21}(\text{°})$ ).



Slika 4.25 Predloženi model za generisanje S-parametara RF MEMS omskog prekidača

Izabrana su četiri neuronska modela koja su generisala rezultate sa najvećom tačnošću:


- neuronski model sa po 17 neurona u dva skrivena sloja za modelovanje  $|S_{11}|(\text{dB})$ ,
- neuronski model sa 18 neurona u prvom i 16 neurona u drugom skrivenom sloju za modelovanje  $|S_{21}|(\text{dB})$ ,
- neuronski model sa 22 neurona u prvom i 18 neurona u drugom skrivenom sloju za modelovanje  $\angle |S_{11}|(\text{°})$  i
- neuronski model sa po 24 neurona u dva skrivena sloja za modelovanje  $\angle |S_{21}|(\text{°})$ .

U nastavku je izvršena analiza promena povratnog (*return loss*) i unutrašnjeg slabljenja (*insertion loss*) prekidača usled promena lateralnih dimenzija prekidača za veličine fabričke tolerancije, pri čemu su korišćeni sledeći opsezi ulaznih parametara:  $L_g$  - od 30  $\mu\text{m}$  do 110  $\mu\text{m}$ ,  $L_b$  - od 200  $\mu\text{m}$  do 1000  $\mu\text{m}$ ,  $W_g$  - od 70  $\mu\text{m}$  do 150  $\mu\text{m}$ ,  $W_b$  - od 20  $\mu\text{m}$  do 220  $\mu\text{m}$  i frekvencija od 0 do 40 GHz [96, 97]. Analiza je izvršena za osam različitih dimenzija mosta, odnosno osam različitih kombinacija lateralnih dimenzija mosta prekidača. Kao mera fabričke tolerancije u tehnologiji izrade omskog RF MEMS prekidača razmatran je opseg devijacije od  $\pm 3 \mu\text{m}$  (sa korakom od 1  $\mu\text{m}$ ). Stoga, promena u opsegu devijacije primenjena je na dimenzije  $L_g$ ,  $L_b$ ,  $W_g$  i  $W_b$ . Analiza je vršena kroz tri faze. Prvo je jedna od četiri navedene dimenzije menjana za opseg devijacije dok su sve ostale dimenzije bile konstantne. U drugoj fazi istovremeno su menjane po dve dimenzije, dok su druge dve ostajale konstantne (npr. istovremeno su menjane dimenzije mosta  $L_b$  i  $W_b$ , dok su dimenzije procepa  $L_g$  i  $W_g$  bile konstantne i obrnuto). U trećoj fazi, istovremeno su menjane sve četiri dimenzije, odnosno istovremeno su menjane lateralne dimenzije mosta i dimenzije procepa između mosta i tela prekidača.

U narednim tabelama prikazani su dobijeni rezultati u slučaju promene dimenzije  $L_b$  (Tabela 4.6), za promene dimenzije  $W_b$  (Tabela 4.7), promene dimenzije  $L_g$  (Tabela 4.8) i u slučaju promene dimenzije  $W_g$  (Tabela 4.9). Radi ilustracije, dati su i grafički prikazi modela S-parametara u razmatranom frekvencijskom opsegu za prekidače sa lateralnim dimenzijama čije promene su uzrokovale najveće devijacije (Slike 4.26 - 4.29) [96, 97]. Dimenzije prekidača prikazane su u sledećem obliku ( $L_b, W_b, L_g, W_g$ ), dok su dimenzije izražene u  $\mu\text{m}$ .

Tabela 4.6 Devijacije povratnog i unutrašnjeg slabljenja pri promenama  $L_b$  za  $\pm 3 \mu\text{m}$


$L_b$ [ $\mu\text{m}$ ]	$W_b$ [ $\mu\text{m}$ ]	$L_g$ [ $\mu\text{m}$ ]	$W_g$ [ $\mu\text{m}$ ]	$Max \Delta S_{11} $ [dB]	$Max \Delta S_{21} $ [dB]
200	20	30	70	0.5	0.0026
400	20	50	70	0.29	0.0025
300	70	90	70	0.42	0.0038
800	70	70	90	0.27	0.0054
800	20	50	110	0.54	0.0075
400	20	30	150	0.73	0.0045
1000	220	30	20	0.08	0.012
600	120	70	110	0.58	0.0063




Slika 4.26 Najizraženiji uticaj promena  $L_b$  dimenzije: a) Povratno slabljenje za prekidač (400, 20, 30, 150) i b) Unutrašnje slabljenje za prekidač (1000, 220, 30, 20)

Tabela 4.7 Devijacije povratnog i unutrašnjeg slabljenja pri promenama  $W_b$  za  $\pm 3\mu\text{m}$

$L_b$ [ $\mu\text{m}$ ]	$W_b$ [ $\mu\text{m}$ ]	$L_g$ [ $\mu\text{m}$ ]	$W_g$ [ $\mu\text{m}$ ]	$Max \Delta S_{11} $ [dB]	$Max \Delta S_{21} $ [dB]
200	20	30	70	1	0.0016
400	20	50	70	0.95	0.0092
300	70	90	70	0.83	0.0064
800	70	70	90	1.1	0.011
800	20	50	110	2.4	0.024
400	20	30	150	2.4	0.015
1000	220	30	20	0.24	0.017
600	120	70	110	1.3	0.0079



a)




b)


Slika 4.27 Najizraženiji uticaj promena  $W_b$  dimenzije: a) Povratno slabljenje za prekidač (400, 20, 30, 150) i b) Unutrašnje slabljenje za prekidač (800, 20, 50, 110)

Tabela 4.8 Devijacije povratnog i unutrašnjeg slabljenja pri promenama  $L_g$  za +/- 3  $\mu\text{m}$

$L_b$ [ $\mu\text{m}$ ]	$W_b$ [ $\mu\text{m}$ ]	$L_g$ [ $\mu\text{m}$ ]	$W_g$ [ $\mu\text{m}$ ]	$Max \Delta S_{11} $ [dB]	$Max \Delta S_{21} $ [dB]
200	20	30	70	1.7	0.0047
400	20	50	70	0.68	0.0095
300	70	90	70	0.9	0.012
800	70	70	90	0.54	0.018
800	20	50	110	1.2	0.022
400	20	30	150	2.4	0.018
1000	220	30	20	0.13	0.011
600	120	70	110	1.1	0.019



a)




b)

Slika 4.28 Najizraženiji uticaj promena  $L_g$  dimenzije: a) Povratno slabljenje za prekidač (400, 20, 30, 150) i b) Unutrašnje slabljenje za prekidač (800, 20, 50, 110)

Tabela 4.9 Devijacije povratnog i unutrašnjeg slabljenja pri promenama  $W_g$  za  $\pm 3\mu\text{m}$

$L_b$ [ $\mu\text{m}$ ]	$W_b$ [ $\mu\text{m}$ ]	$L_g$ [ $\mu\text{m}$ ]	$W_g$ [ $\mu\text{m}$ ]	$Max/\Delta S_{11}/$ [dB]	$Max/\Delta S_{21}/$ [dB]
200	20	30	70	1.4	0.0021
400	20	50	70	1.4	0.016
300	70	90	70	1.5	0.014
800	70	70	90	1.6	0.017
800	20	50	110	3.5	0.027
400	20	30	150	3.3	0.017
1000	220	30	20	0.35	0.013
600	120	70	110	2	0.013





Slika 4.29 Najizraženiji uticaj promena  $W_g$  dimenzije: a) Povratno slabljenje za prekidač (400, 20, 30, 150) i b) Unutrašnje slabljenje za prekidač (800, 20, 50, 110)


Rezultati u gore prikazanim tabelama ukazuju da su najmanje devijacije povratnog slabljenja u slučaju promena  $L_b$  dimenzije (manje su od 0.73 dB), dok su najveće u slučaju promena  $W_g$  dimenzije (manje od 3.5 dB). Devijacije unutrašnjeg slabljenja su značajno manje u odnosu na devijacije povratnog slabljenja, i one maksimalno iznose do 0.027 dB. Iz toga se može izvući zaključak da promene dimenzija mosta prekidača u okvirima fabričke tolerancije ostvaruju veći uticaj na povratno slabljenje nego na unutrašnje slabljenje prekidača. Dakle, promene dimenzije  $L_b$  ostvaruju najmanji uticaj na S-parametre prekidača, dok najveći uticaj imaju promene dimenzije  $W_g$ .

U cilju dalje analize devijacije S-parametara, istovremeno su menjane po dve dimenzije mosta prekidača u opsegu od +/- 3  $\mu\text{m}$ . Kao i u prethodnim primerima, u narednoj analizi korišćeno je istih devet kombinacija dimenzija prekidača. Prvo je analiziran slučaj u kom su dimenzije procepa konstantne, a dimenzije mosta se menjaju istovremeno. Zatim slučaj u kom su dimenzije mosta konstantne, a dimenzije procepa su istovremeno menjane. U Tabeli 4.10 predstavljeni su rezultati u slučaju istovremene promene dimenzija  $L_b$  i  $W_b$ , kao i za istovremenu promenu dimenzija  $L_g$  i  $W_g$  [96, 97].


Tabela 4.10 Devijacije povratnog i unutrašnjeg slabljenja pri istovremenim promenama dve dimenzije za +/- 3  $\mu\text{m}$

$L_b$ [ $\mu\text{m}$ ]	$W_b$ [ $\mu\text{m}$ ]	$L_g$ [ $\mu\text{m}$ ]	$W_g$ [ $\mu\text{m}$ ]	promene $L_b$ i $W_b$ za +/- 3 $\mu\text{m}$		promene $L_g$ i $W_g$ za +/- 3 $\mu\text{m}$	
				$Max/\Delta S_{11}/$ [dB]	$Max/\Delta S_{21}/$ [dB]	$Max/\Delta S_{11}/$ [dB]	$Max/\Delta S_{21}/$ [dB]
200	20	30	70	1.5	0.0036	3.2	0.0059
400	20	50	70	1.2	0.012	2.1	0.026
300	70	90	70	1.3	0.01	2.4	0.028
800	70	70	90	1.4	0.016	2.2	0.036
800	20	50	110	3	0.032	4.6	0.049
400	20	30	150	3.1	0.02	5.6	0.035
1000	220	30	20	0.31	0.029	0.48	0.022
600	120	70	110	1.9	0.014	3.1	0.033

Rezultati ukazuju da istovremene promene dimenzija mosta prekidača prouzrokuju maksimalnu devijaciju povratnog slabljenja do 3.1 dB, dok je devijacija unutrašnjeg slabljenja do 0.032 dB. U slučaju istovremenih promena dimenzija procepa, navedene devijacije su veće i one iznose do 5.6 dB za povratno slabljenje kao i do 0.49 dB za unutrašnje slabljenje. U svim analiziranim slučajevima unutrašnje slabljenje prekidača je najosetljivije u frekvencijskom opsegu od 25 GHz do 40 GHz, dok se osetljivost povratnog slabljenja ne može direktno odrediti jer varira u zavisnosti od dimenzija mosta prekidača. Takođe, devijacije S-parametara su izraženije kod prekidača malih dimenzija, što je posledica veće procentualne promene u odnosu na dimenzije prekidača. U nastavku su date Slike 4.30 i 4.31 koje se odnose na prekidače kod kojih se javljaju najveće devijacije S-parametara u razmatranom frekvencijskom opsegu.




a)



b)

Slika 4.30 Maksimalan uticaj istovremenih promena  $L_b$  i  $W_b$ : a) Povratno slabljenje (prekidač 400, 20, 30, 150) i b) Unutrašnje slabljenje (prekidač 800, 20, 50, 110)



Slika 4.31 Maksimalan uticaj istovremenih promena  $L_g$  i  $W_g$  : a) Povratno slabljenje (prekidač 400, 20, 30, 150) i b) Unutrašnje slabljenje (prekidač 800, 20, 50, 110)

Na kraju, analizom je obuhvaćen i slučaj istovremene promene svih dimenzija prekidača, tj. dimenzija mosta i procepa za  $\pm 3 \mu\text{m}$ . Pri tome, potrebno je naglasiti da promene dimenzija mosta dodatno menjaju dimenzije procepa. Dobijeni rezultati prikazani su u Tabeli 4.11 i potvrđuju očekivane zaključke [96, 97]. Devijacije unutrašnjeg i povratnog slabljenja su znatno veće nego što je to bilo slučaj kod prethodnih analiza. Maksimalna devijacija za povratno slabljenje je 7.8 dB a za unutrašnje slabljenje 0.77 dB. Međutim, u praksi se ovi ekstremni rezultati ne mogu očekivati, jer je veoma mala verovatnoća da će u postupku fabrikacije doći do istovremenih promena dimenzija mosta i procepa prekidača.

Tabela 4.11 Devijacije povratnog i unutrašnjeg slabljenja pri istovremenim promenama dimenzija mosta i procepa za +/- 3  $\mu\text{m}$

$L_b$ [ $\mu\text{m}$ ]	$W_b$ [ $\mu\text{m}$ ]	$L_g$ [ $\mu\text{m}$ ]	$W_g$ [ $\mu\text{m}$ ]	$Max \Delta S_{11} $ [dB]	$Max \Delta S_{21} $ [dB]
200	20	30	70	4.7	0.0094
400	20	50	70	3.2	0.039
300	70	90	70	3.6	0.039
800	70	70	90	3.6	0.054
800	20	50	110	6.7	0.077
400	20	30	150	7.8	0.054
1000	220	30	20	0.74	0.039
600	120	70	110	5.1	0.049

Generisanje navedenih rezultata uz upotrebu predloženih neuronskih modela trajalo je svega nekoliko sekundi, što je značajna ušteda vremena u odnosu na postupak vršenja istih analiza upotrebom full-wave simulatora za određivanje S-parametara, gde simulacija za samo jednu kombinaciju dimenzija prekidača traje nekoliko desetina minuta.


S obzirom da na unutrašnje i povratno slabljenje omskih RF MEMS prekidača u najvećoj meri utiču lateralne dimenzije prekidača, iz analize proističe opšti zaključak da male promene nastale u procesu fabrikacije imaju zanemarljiv uticaj na unutrašnje slabljenje, naročito pri nižim radnim frekvencijama. Sa druge strane, promene lateralnih dimenzija ostvaruju znatno veći uticaj na povećanje povratnog slabljenja prekidača, te se iz tog razloga preporučuje da se u toku optimizacije uzima povratno slabljenje nekoliko decibela manje od željene vrednosti. Na taj način će se izbeći prekoračenje željene vrednosti povratnog slabljenja ukoliko dođe do eventualnih devijacija lateralnih dimenziju u procesu fabrikacije prekidača.

#### 4.4.4 Primena razvijenih black-box modela za projektovanje RF MEMS kapacitivnog prekidača u električnom domenu

S obzirom da su VNM veoma efikasno sredstvo za simulaciju i optimizaciju RF MEMS prekidača, modeli bazirani na VNM mogu biti iskorišćeni za brzo i efikasno projektovanje prekidača u skladu sa definisanim zahtevima. Prethodno predloženi *black-box* neuronski modeli (direktni modeli) mogu se u jednostavnom i brzom postupku iskoristiti za određivanje dimenzija prekidača u cilju dostizanja željenih električnih karakteristika, olakšavajući na taj način postupak projektovanja prekidača. Time je predstavljena osnovna prednost primene predloženih neuronskih modela u odnosu na klasične simulacione metode, uzimajući u obzir


činjenicu da analiza karakteristika prekidača zahteva veliki broj pojedinačnih simulacija i optimizacija za svaku konkretnu dimenziju prekidača, a takve procedure su matematički složene i vremenski veoma zahtevne.

Primena neuronskih modela za projektovanje prekidača u električnom domenu biće ilustrovana na primeru modela za rezonantnu frekvenciju. Razmatrani direktni neuronski model sastoji se od VNM koja je obučena da odredi rezonantnu frekvenciju za zadate vrednosti geometrijskih parametara  $L_s$  i  $L_f$ , odnosno neuronski model koji je detaljno opisan u Poglavlju 4.2. Takvom neuronskom modelu na ulaze su dovedene vrednosti  $L_s$  (u opsegu od 50  $\mu\text{m}$  do 500  $\mu\text{m}$ ) i  $L_f$  (u opsegu od 0  $\mu\text{m}$  do 100  $\mu\text{m}$ ). Neuronskim modelom su generisane vrednosti rezonantne frekvencije koje su na trodimenzionalnom grafiku prikazane na Slici 4.32 [98].




Slika 4.32 Vrednosti rezonantne frekvencije generisane razvijenim neuronskim modelom

Dobijeni rezultati se mogu prikazati i dvodimenzionalno u odnosu na pojedinačne vrednosti lateralnih dimenzija, što je prikazano na Slikama 4.33 i 4.34.



a)




b)

Slika 4.33 Vrednosti rezonantne frekvencije za razmatrane opsege dimenzija mosta:

a) dimenzije osnove mosta, b) dimenzije prsta mosta

Iz grafika je moguće uočiti da mapiranje između dimenzija mosta i željene vrednosti rezonantne frekvencije nije jednoznačno, tj. postoje različite kombinacije dimenzija mosta prekidača kojima odgovaraju iste vrednosti rezonantne frekvencije. Uzimajući navedeno u obzir, upotrebom predloženih neuronskih modela moguće je generisati dimenzije  $L_s$  i  $L_f$  za željenu vrednost rezonantne frekvencije samo ukoliko je data ukupna vrednost lateralnih dimenzija mosta (tj. ukupna dužina mosta) prekidača  $L_t = L_s + L_f$ , ili je poznata jedna od dimenzija mosta.

U nastavku će biti ilustrovana primena predloženog neuronskog modela u postupku određivanja dimenzija mosta u cilju postizanja željene vrednosti rezonantne frekvencije za definisanu ukupnu dimenziju mosta. Ukupna dužina mosta je vrlo često ograničavajući faktor u postupku projektovanja prekidača usled uslovljenosti prostora u toku ugradnje RF MEMS prekidača u mikrotalasni sklop.




Slika 4.34 Ukupna dužina mosta u odnosu na  $f_{res}$  u razmatranom opsegu dimenzija mosta


Na Slici 4.34 moguće je uočiti da su u opsegu zadatih lateralnih dimenzija mosta vrednosti rezonantne frekvencije u opsegu od 8 do 30 GHz. Takođe, svaku vrednost rezonantne frekvencije moguće je postići sa nizom različitih kombinacija  $L_s$  i  $L_f$  dimenzija, odnosno nije moguće svakom ukupnom dužinom mosta prekidača ostvariti proizvoljnu vrednost rezonantne frekvencije. Iz zadatog opsega  $L_s$  i  $L_f$  proističe da je u tom slučaju ukupna dužina mosta prekidača u opsegu od 50  $\mu\text{m}$  do 600  $\mu\text{m}$ .

Zatim su izračunate vrednosti rezonantne frekvencije za različite procentualne vrednosti  $p = 100 \cdot L_s/L_f$  (sa korakom  $L_t$  od 50  $\mu\text{m}$ ), kao i za zasebne vrednosti  $L_s$  i  $L_f$ . Dobijeni rezultati prikazani su na graficima u Slici 4.35. Izračunate vrednosti  $L_s$  i  $L_f$  mogu biti izvan inicijalnih opsega, na primer ako je  $L_t = 500 \mu\text{m}$ , onda je za procentualnu vrednost od 20% odgovarajuća vrednost  $L_s = 100 \mu\text{m}$  a  $L_f = 400 \mu\text{m}$ . Ovakva kombinacija dimenzija izlazi izvan razmatranog opsega za  $L_f$  vrednosti. Iz tog razloga su zadebljanom linijom istaknute vrednosti koje ulaze u inicijalne opsege za vrednosti  $L_s$  i  $L_f$ . Na taj način, za svaku željenu vrednost rezonantne frekvencije, odgovarajuća kombinacija dužina  $L_s$  i  $L_f$  se jednostavno očitava sa grafika (Slika 4.35 b i c) na osnovu njihove ukupne dužine prekidača  $L_t$ .






a)




b)



Slika 4.35 Moguće vrednosti dimenzija mosta u odnosu na rezonantnu frekvenciju i različite dimenzije ukupne dužine mosta  $L_t$ :

a) procentualni odnos, b) u odnosu na dimenzije  $L_s$ , c) u odnosu na dimenzije  $L_f$

Kao primer postupka određivanja dimenzija prekidača biće navedena sledeća ilustracija, u kojoj je konkretna vrednost ukupne dužine mosta prekidača  $400 \mu\text{m}$ . Upotrebom razvijenih neuronskih modela izračunate su vrednosti  $L_s$  i  $L_f$  za različite procentualne vrednosti, a dobijeni rezultati rezonantne frekvencije su prikazani na Slici 4.36.




Slika 4.36 Moguće vrednosti dimenzija mosta u odnosu na rezonantnu frekvenciju i ukupnu dužinu mosta od  $L_t = 400 \mu\text{m}$

Kao i u prethodnim slučajevima, pojačani delovi linija odgovaraju vrednostima dimenzija mosta u zadatim opsezima. Sa grafika je moguće očitati da za ukupnu dužinu mosta od 400  $\mu\text{m}$ , moguće vrednosti rezonantne frekvencije su u opsegu od 10.8 GHz do 12.2 GHz. Ukoliko je željena rezonantna frekvencija 11 GHz, onda su dimenzije  $L_s = 310 \mu\text{m}$  a  $L_f = 90 \mu\text{m}$ .

#### **4.4.5 Primena razvijenih black-box modela za projektovanje RF MEMS kapacitivnog prekidača u mehaničkom domenu**

Razvijeni *black-box* direktni neuronski model sastoji se od VNM koja je obučavana da generiše napon aktivacije za zadate vrednosti geometrijskih parametara  $L_s$  i  $L_f$ , odnosno direktni neuronski model koji je detaljno opisan u Poglavlju 4.3. Vrednosti napona aktivacije generisane predloženim neuronskim modelom za razmatrani opseg vrednosti  $L_s$  (od 125  $\mu\text{m}$  do 500  $\mu\text{m}$ ) i  $L_f$  (od 0 do 100  $\mu\text{m}$ ) prikazane su na trodimenzionalnom grafiku na Slici 4.37 i zasebnim dvodimenzionalnim graficima na Slici 4.38 [99].




Slika 4.37 Vrednosti napona aktivacije izračunate neuronskim modelom


Bitno je naglasiti da je vreme potrebno za navedenu simulaciju svega nekoliko sekundi, što je značajno kraće u odnosu na vreme potrebno za simulacije u mehaničkom simulatoru. Primera radi, vreme potrebno za simulaciju napona aktivacije u mehaničkom simulatoru za samo jednu geometrijsku dimenziju mosta prekidača iznosi nekoliko desetina minuta. Isti slučaj se odnosi i za proces optimizacije geometrijskih parametara u cilju dostizanja željene

vrednosti napona aktivacije. Proces optimizacije baziran na neuronskim modelima traje takođe nekoliko sekundi, dok proces sproveden mehaničkim simulatorom traje nekoliko sati.

Kao i u slučaju rezonantne frekvencije, mapiranje između dimenzija mosta i željene vrednosti napona aktivacije nije jednoznačno, tj. različite kombinacije dimenzija mosta prekidača odgovaraju istoj vrednosti napona aktivacije. Iz tog razloga, nije moguće razviti model prekidača za određivanje dimenzija  $L_s$  i  $L_f$  za željenu vrednost napona aktivacije ukoliko nije data ukupna dužina mosta prekidača  $L_t = L_s + L_f$ , ili je poznata jedna od dimenzija mosta.



a)




b)

Slika 4.38 Vrednosti napona aktivacije za razmatrane opsege dimenzija mosta:

a) dimenzije osnove mosta, b) dimenzije prsta mosta


Krajnji cilj analize je razvoj neuronskog modela koji će se koristiti za određivanje lateralnih dimenzija mosta prekidača u okviru zadate ukupne dimenzije mosta i u cilju dostizanja željenog napona aktuacije. Na početku potrebno je proveriti opseg dimenzija mosta za dati napon aktuacije. Za tu svrhu koriste se dijagrami na Slikama 4.38 i 4.39. Na Slici 4.38 dvo-dimenzionalno su predstavljene iste vrednosti napona aktuacije koje su u 3D dijagramu prikazane na Slici 4.37. U stvari, na sva tri dijagrama prikazane su dimenzije mosta u odnosu na napon aktuacije. U nastavku, na Slici 4.39 predstavljena je ukupna dužina mosta  $L_t$  u odnosu na napon aktuacije u razmatranom opsegu dimenzija mosta. Kao što je prikazano, razmatranom opsegu dimenzija  $L_s$  i  $L_f$  odgovaraju naponi aktuacije u opsegu između 15 V i 85 V.




Slika 4.39 Ukupne dužine mosta u odnosu na  $V_{PI}$  u razmatranom opsegu dimenzija mosta

Svaka vrednost napona aktuacije odgovara opsegu mogućih vrednosti  $L_s$  i  $L_f$ , odnosno opsegu mogućih vrednosti ukupnih dužina. Uzimajući u obzir razmatrane opsege dimenzija  $L_s$  i  $L_f$  definisan je opseg razmatranih vrednosti ukupnih dužina od 125  $\mu\text{m}$  do 600  $\mu\text{m}$ . Za različite procentualne vrednosti  $p = 100 * L_s/L_f$  (od 0% do 100%),  $L_s$  i  $L_f$  su određene za vrednosti  $L_t$  u navedenom opsegu (sa korakom od 25  $\mu\text{m}$ ). Zatim, odgovarajući napon aktuacije je izračunat predloženim direktnim neuronskim modelom i prikazan na Slici 4.40. Delovi izračunatih dimenzija  $L_s$  i  $L_f$  označeni su zadebljanom linijom i oni predstavljaju moguće vrednosti  $L_s$  i  $L_f$  koje odgovaraju zahtevanim dimenzijama mosta prekidača. Radi ilustracije, biće analiziran primer kada je  $L_t = 500 \mu\text{m}$  a  $p = 20\%$ . Iz toga proističu vrednosti  $L_s = 100 \mu\text{m}$  i  $L_f = 400 \mu\text{m}$ , što je izvan razmatranog opsega  $L_f$ , pa stoga navedena


kombinacija dimenzija nije moguća. Na Slici 4.40 lako se uočava da za polazne zahteve u vidu vrednosti  $L_t = 500 \mu\text{m}$  i  $p = 20\%$ , odgovarajuće vrednosti  $L_s$  i  $L_f$  nisu označene zadebljanom linijom. Grafikoni na Slici 4.40 su veoma korisni za brzu analizu polaznih zahteva, tj. za proveru da li je ostvarljiva kombinacija napona aktivacije i ukupne dužine mosta prekidača, kao i da se odrede vrednosti dimenzija  $L_s$  i  $L_f$  za zadate vrednosti napona aktivacije i ukupne dimenzije prekidača.



a)




b)



Slika 4.40 Napon aktivacije za različite vrednosti ukupne dužine mosta prekidača u odnosu na: a) procenat, b)  $L_s$ , (c)  $L_f$

Na još jednom primeru će biti prikazano efikasno određivanje odgovarajuće kombinacija lateralnih dimenzija mosta za zahtevanu vrednost napona aktivacije i ukupne dužine mosta. Na Slici 4.41 prikazan je grafik koji se odnosi na ukupnu dužinu  $L_t = 400 \mu\text{m}$ . Vrednosti istaknute zadebljanim linijama su, kao što je prethodno opisano, izračunate vrednosti  $L_s$  i  $L_f$  koje odgovaraju razmatranom opsegu dimenzija mosta prekidača. Može se uočiti da moguće vrednosti napona aktivacije koje odgovaraju ukupnoj dužini mosta od  $400 \mu\text{m}$  su okvirno između  $20.6 \text{ V}$  i  $23.7 \text{ V}$ . Ako uzmemo da je željena vrednost napona aktivacije  $21.7 \text{ V}$ , onda je sa grafika moguće očitati da su odgovarajuće vrednosti dimenzija prekidača  $L_s = 300 \mu\text{m}$  i  $L_f = 100 \mu\text{m}$ .

Na ovaj način prikazan je efikasan pristup u primeni neuronskih modela u analizi modela, odnosno određivanje lateralnih dimenzija prekidača za zadate vrednosti napona aktivacije i ukupne dužine mosta prekidača. Time su izbegnute veoma vremenski zahtevne optimizacije i brojne numeričke simulacije u mehaničkim simulatorima. Dobijeni rezultati potvrđuju efikasnost i tačnost predloženog pristupa.



Slika 4.41 Moguće vrednosti dimenzija mosta u odnosu na napon aktivacije za ukupnu dužinu mosta od  $L_t=400 \mu\text{m}$

#### 4.5 UPOREDNA ANALIZA PRIMENJIVOSTI RBF I MLP NEURONSKIH MODELA ZA MODELOVANJE KARAKTERISTIKA RF MEMS PREKIDAČA

U prethodnim poglavljima prikazana je efikasnost primene MLP neuronskih modela u procesima simuliranja i optimizovanja karakteristika RF MEMS prekidača uz veoma veliku uštedu vremena. U ovom poglavlju biće predstavljene mogućnosti neuronskih modela zasnovanih na veštačkim neuronskim mrežama sa radijalnom baznom funkcijom (*Radial Base Function* - RBF) u modelovanju RF MEMS prekidača. U cilju sagledavanja tačnosti navedenog pristupa, dobijeni rezultati RBF neuronskih modela upoređeni su sa rezultatima prethodno predstavljenih MLP neuronskih modela (opisani u Poglavlju 4.3). Konkretno, razvijeni su RBF neuronski modeli za modelovanje mehaničkih karakteristika RF MEMS kapacitivnog prekidača, tj. napona aktivacije u zavisnosti od lateralnih dimenzija prekidača (Slika 4.42), a zatim su dobijeni rezultati upoređeni sa rezultatima modelovanja istih karakteristika sa predloženim MLP neuronskim modelom [100].





Slika 4.42 Predloženi neuronski model na bazi RBF mreže

RBF veštačka neuronska mreža se sastoji od tri sloja: ulazni, jedan skriveni sloj sa nelinearnom radijalnom baznom aktivacionom funkcijom (Gausova prenosna funkcija) i izlazni sloj. Broj ulaznih neurona je jednak broju nezavisnih ulaznih parametara. U konkretnom slučaju, predloženi RBF neuronski model ima dva ulazna neurona koji odgovaraju parametrima  $L_s$  i  $L_f$ . Broj izlaznih neurona jednak je broju parametara koje modeluje neuronski model, tj. u konkretnom slučaju jedan neuron koji odgovara naponu aktuacije  $V_{PI}$ . Glavni parametri koji određuju VNM sa radijalnom funkcijom su centralni vektor i standardna devijacija (*spread faktor*). Funkcija mapiranja zavisi od udaljenosti između ulaznog vektora i centralnog vektora. Obučavanje RBF VNM je vršeno sa istim skupom trening kombinacija koje su korišćene za obučavanje MLP VNM (Poglavlje 4.3), a koje su dobijene simulacijama u mehaničkom simulatoru (*COMSOL Multiphysics*) [108]. Verifikacija tačnosti predloženih modela vršena je sa test podacima koji su takođe dobijeni na isti način. Na početku obučavanja RBF MLP formirana je veštačka neuronska mreža bez neurona u skrivenom sloju. U svakoj narednoj iteraciji dodaje se po jedan neuron u skrivenom sloju sa centrom koji je jednak ulaznom vektoru. Nakon toga se vrši usklađivanje težinskih koeficijenata između neurona. Ovakav proces se ponavlja sve dok se ne postigne prethodno zadati kriterijum srednje kvadratne greške (*Mean Squared Error - MSE*) ili se dostigne maksimalan broj skrivenih neurona u skrivenom sloju. Na početku se postavlja ista vrednost standardne devijacije (*spread faktor*) radijalne funkcije za sve neurone u skrivenom sloju. Pošto se najbolja vrednost standardne devijacije ne može prethodno odrediti, ona se obično eksperimentalno određuje kroz obuku većeg broja neuronskih mreža sa različitim vrednostima standardne devijacije i upoređivanje njihovih karakteristika. Broj neurona u skrivenom sloju RBF VNM je poznat tek kada je proces obučavanja mreže završen. Trening set se sastoji od 30 različitih kombinacija vrednosti napona aktuacije sa odgovarajućim dimenzijama  $L_s$  (u opsegu od 125  $\mu\text{m}$  do 500  $\mu\text{m}$ ) i  $L_f$  (u opsegu od 0 do 100  $\mu\text{m}$ ), dok se test skup sastoji od 9 kombinacija lateralnih dimenzija.

Izvršeno je obučavanje nekoliko RBF VNM sa različitim vrednostima standardnih devijacija. Test rezultati nekoliko razvijenih RBF VNM prikazani su u Tabeli 4.12. Prikazani

rezultati se odnose na odzive RBF mreža koje su testirane sa skupom kombinacija koje nisu korišćene u procesu obučavanja mreže.

Tabela 4.12 Test rezultati razvijenih RBF neuronskih modela

Standardna devijacija	Broj neurona u skrivenom sloju	Srednja greška [%]	Najveća greška [%]	r
1	26	1.006	3.302	0.9994
0.9	27	1.257	4.026	0.9989
0.7	27	1.915	8.710	0.9963
0.5	26	5.204	17.406	0.9717
0.01	29	43.068	63.414	0.3765
0.005	29	43.876	67.699	0.3101


Na osnovu ostvarenih rezultata, RBF mreža sa standardnom devijacijom jednakom 1 generiše najbolje rezultate i ima 26 neurona u skrivenom sloju [100]. U Tabeli 4.13 prikazani su rezultati za pojedinačne lateralne dimenzije prekidača generisane pomoću predloženog RBF neuronskog modela, kao i rezultati koji su ostvareni sa MLP neuronskim modelom za iste dimenzije prekidača.

Tabela 4.13 Pregled test rezultata RBF i MLP neuronskih modela za vrednosti  $V_{PI}$

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	$V_{PI}$ (target) (V)	RBF neuronski model			MLP neuronski model		
			$V_{PI}$ (sim) (V)	Abs. greška (V)	Rel. greška (%)	$V_{PI}$ (sim) (V)	Abs. greška (V)	Rel. greška (%)
150	25	55.6	56.88	1.28	2.30	55.58	0.02	0.04
150	65	43	43.02	0.02	0.05	43.45	0.45	1.10
250	25	33.3	32.92	0.38	1.20	33.16	0.14	0.40
250	65	28.2	28.02	0.18	0.65	28.21	0.01	0.03
350	10	25.2	25.34	0.14	0.57	25.32	0.12	0.47
350	25	23.8	23.81	0.01	0.02	23.74	0.06	0.25
350	65	21.1	21.50	0.40	1.90	20.99	0.11	0.54
350	75	20.5	21.01	0.51	2.50	20.45	0.35	0.17
450	65	16.9	17.27	0.37	2.20	16.80	0.10	0.57


Predloženim RBF neuronskim modelom generisana je maksimalna relativna greška od 2.5%, dok su apsolutne razlike između ciljnih i simuliranih vrednosti napona aktuacije manje od 1.28 V. Slika 4.43 predstavlja grafik vrednosti napona aktuacije simuliranih predloženim

RBF modelom u odnosu na odgovarajuće vrednosti dobijene simulacijama u mehaničkom simulatoru [100]. Malo odstupanje vrednosti koje su generisane RBF modelom u odnosu na idealnu dijagonalnu liniju potvrđuju veoma dobru tačnost predloženog modela.



Slika 4.43 Korelacija vrednosti dobijenih pomoću RBF neuronskog modela i ciljnih vrednosti napona aktucije

Na kraju, izvršena je uporedna analiza efikasnosti postupka i tačnosti rezultata koji su ostvareni predloženim RBF neuronskim modelom u odnosu na rezultate predloženog MLP neuronskog modela (Poglavlje 4.3). Grafički prikaz test rezultata oba predložena neuronska modela dat je na Slici 4.44 [100].



Slika 4.44 Grafik generisanih vrednosti napona aktucije MLP i RBF neuronskih modela

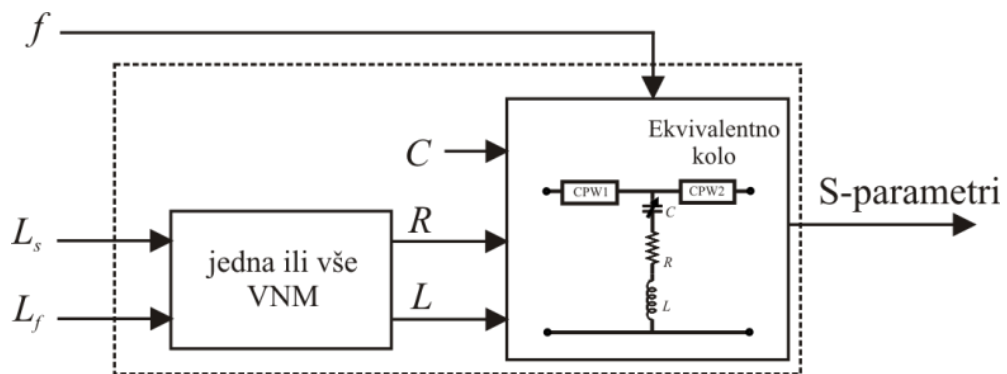
Može se zaključiti da RBF neuronski model generiše malo veće greške u odnosu na MLP neuronski model. Međutim, i takav stepen tačnosti je uporediv i ukazuje na veoma dobru tačnost predloženog RBF neuronskog modela. Oba modela daju trenutno odziva na ulazne vrednosti. Sa druge strane, procedura formiranja RBF neuronskog modela je mnogo brža usled bolje brzine konvergencije neuronske mreže.

Glavni zaključak je da oba predložena modela generišu rezultate koji su veoma blizu referentnih vrednosti dobijenih simulacijama u mehaničkom simulatoru, te da su predloženi modeli veoma podesni za buduće analize i optimizaciju karakteristika RF MEMS prekidača.

## 5 HIBRIDNI MODELI RF MEMS PREKIDAČA


Kao što je navedeno u prethodnim poglavljima, upotreba *full-wave* elektromagnetnih simulatora za određivanje električnih karakteristika RF MEMS prekidača je složen i vremenski zahtevan postupak, jer su potrebni kompleksni modeli komponenata. Iz tog razloga često se koriste modeli bazirani na ekvivalentnom kolu u simulatoru elektronskih kola, u postupku koji je vremenski manje zahtevna procedura od *full-wave* simulacija. Za primenu modela baziranih na ekvivalentnom kolu potrebno je optimizacijom odrediti vrednosti elemenata ekvivalentnog kola. U slučaju kada se razmatra veći broj komponenti čije se dimenzije razlikuju, postupak određivanja elemenata ekvivalentnog kola je potrebno ponoviti za svaku kombinaciju vrednosti dimenzija, što takođe utiče na povećanje potrebnog vremena. U cilju povećanja efikasnosti modelovanja, u ovoj glavi disertacije predložena je upotreba hibridnih modela RF MEMS prekidača. U hibridnim modelima koriste se VNM za veoma efikasno generisanje vrednosti elemenata ekvivalentnog kola RF MEMS prekidača za zadate lateralne dimenzije mosta. U literaturi je do sada korišćen sličan pristup za modelovanje RF MEMS rezonatora [66-68] i RF MEMS varaktora [75], ali ne i za RF MEMS prekidače. Štaviše, predloženim pristupom u ovom istraživanju modelovani su kompleksniji geometrijski oblici mosta prekidača, za razliku od prostih pravougaonih dimenzija mosta prekidača kod kojih je jednostavnije određivanje elemenata ekvivalentnog kola. U predloženom hibridnom modelu korišćeno je ekvivalentno kolo RF MEMS kapacitivnog prekidača koje je opisano u Poglavlju 2.5.1. Elementi ekvivalentnog kola (otpornost i induktivnost) direktno su zavisni od lateralnih dimenzija mosta prekidača i njihove vrednosti se određuju procesom optimizacije u simulatoru kola za zadate vrednosti parametara rasejanja, kao vrednosti odziva ekvivalentnog kola. Navedeno se ne odnosi na kapacitivnosti kao element ekvivalentnog kola, jer ona ne zavisi od lateralnih dimenzija prekidača, te je u ovom slučaju kapacitivnost konstantna (jednačine 2.2 i 2.3 u Poglavlju 2.5.1) i direktno primenjena u ekvivalentnom kolu. Predloženi

hibridni model RF MEMS prekidača za određivanje elemenata ekvivalentnog kola u odnosu na lateralne dimenzije mosta prekidača prikazan je na Slici 5.1 [101].



Slika 5.1 Predloženi hibridni model

U predloženom modelu analizirana su dva pristupa primene neuronskih mreža za modelovanje zavisnosti vrednosti otpornosti i induktivnosti u odnosu na lateralne dimenzije mosta prekidača. Prema prvom pristupu, kao što je prikazano na Slici 5.2 (a), zasebno se generišu vrednosti elemenata ekvivalentnog kola, dok je drugi pristup prikazan na Slici 5.2 (b) i on podrazumeva neuronski model koji istovremeno generiše oba elementa.



Slika 5.2 Neuronski modeli: a) dve zasebne VNM, b) jedna VNM

Za obučavanje VNM korišćen je set uzoraka sastavljen od kombinacija lateralnih dimenzija mosta prekidača ( $L_s$  i  $L_f$ ) i odgovarajućih vrednosti elemenata ekvivalentnog kola:

otpornosti ( $R$ ) i induktivnosti ( $L$ ). Za svaku kombinaciju lateralnih dimenzija izvršena je simulacija S-parametara u *full-wave* simulatoru i određene su vrednosti otpornosti i induktivnosti. Kada se obuči VNM koja generiše željenu tačnost, ona se implementira u ekvivalentno kolo čime se dobija kompletiran model sa skalabilnim koncentrisanim elementima. Implementacija je urađena na sledeći način. Naime, svaka VNM može biti predstavljena skupom matematičkih izraza koji opisuju prenosnu funkciju VNM. Takav skup matematičkih izraza, implementiran je u šemu ekvivalentnog kola preko bloka promenljivih i jednačina (VAR blok). Ulazne vrednosti VAR bloka su lateralne dimenzije mosta prekidača, a izlazne vrednosti su vrednosti odgovarajućih elemenata ekvivalentnog kola. Razvijeni modeli ne zahtevaju dodatne simulacije u *full-wave* simulatoru, kao ni dodatne optimizacije za određivanje elemenata ekvivalentnog kola za nove kombinacije lateralnih dimenzija. Na taj način se omogućava da se u veoma kratkom vremenskom periodu izvrše simulacije S-parametara u željenom frekvencijskom opsegu za bilo koju dimenziju mosta prekidača.

U cilju pripreme podataka za razvoj modela, određene su vrednosti elemenata ekvivalentnog kola  $R$ ,  $L$  i  $C$  za određeni broj različitih kombinacija lateralnih dimenzija mosta prekidača u opsezima: dužina osnove mosta -  $L_s$  od 50  $\mu\text{m}$  do 500  $\mu\text{m}$  i dužina prsta mosta -  $L_f$  od 0 do 100  $\mu\text{m}$ . Relativna dielektrična konstanta silicijuma je 3.9, a dimenzije koje odgovaraju kapacitivnosti prekidača u statusu kratkog spoja su  $A=13000 \mu\text{m}^2$  i  $t_d = 0,1 \mu\text{m}$ . Implementacijom navedenih vrednosti u jednačinu (2.2 u Poglavlju 2.5.1) izračunata je vrednost kapacitivnosti i ona iznosi 4.48695 pF. U ekvivalentnom kolu korišćeni su 50  $\Omega$  CPW. Za svaku korišćenu kombinaciju dimenzija  $L_s$  i  $L_f$ , izračunate su vrednosti S-parametara u *full-wave* simulatoru korišćenjem softvera *Advanced Design System (ADS) Momentum software* [109]. Zatim je za svaku kombinaciju lateralnih dimenzija prekidača određena rezonantna frekvencija kao minimalna vrednost modula parametra  $S_{21}$ . Dalje, rezonantna frekvencija i kapacitivnost su iskorišćene za određivanje induktivnosti za svaku kombinaciju ulaznih parametara korišćenjem jednačine (2.7 u Poglavlju 2.5.1). Poslednji korak u generisanju podataka je optimizacija vrednosti otpornosti prekidača za svaku kombinaciju lateralnih dimenzija. Optimizacija je izvršena u ADS simulatoru kola sa ciljem postizanja S-parametara koji će se poklapati sa vrednostima S-parametara koji su dobijeni u *full-wave* simulatoru.

Tako dobijeni skup podataka sačinjen od kombinacija lateralnih dimenzija i odgovarajućih elemenata ekvivalentnog kola podeljen je u trening skup neophodan za razvoj neuronskih modela i test skup koji je kasnije korišćen za validaciju tačnosti neuronskih modela. Prema tome, trening set se sastoji od 15 različitih kombinacija  $L_s$  i  $L_f$  (Tabela 5.1), a

test skup od 4 različite kombinacije  $L_s$  i  $L_f$  (Tabela 5.2). Imajući na umu da nije moguće unapred odrediti najbolju strukturu neuronskog modela, formiran je veći broj veštačkih neuronskih mreža sa različitim brojem neurona u jednom ili u dva skrivena sloja. Neuronski model koji je generisao najbolje rezultate određen je kao finalni model.

Tabela 5.1 Kombinacije dimenzija, induktivnosti i otpornosti korišćene za trening skup

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	$L$ (pH)	$R$ ( $\text{m}\Omega$ )
50	0	6.146	555.7
50	50	11.34	696.3
50	100	17.04	764.6
200	00	20.98	787.8
200	50	27.21	831.5
200	100	33.38	862.2
300	00	32.88	856.4
300	50	39.85	911.3
300	100	46.63	943.4
400	0	44.98	909.6
400	50	52.17	956.9
400	100	59.97	980.8
500	00	57.57	940.5
500	50	65.24	983.7
500	100	71.24	1005.4

Tabela 5.2 Kombinacije dimenzija, induktivnosti i otpornosti korišćene za test skup

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	$L$ (pH)	$R$ ( $\text{m}\Omega$ )
250	25	30.06	862.8
250	75	36.69	895.3
350	25	41.93	927.1
350	75	49.28	945.8

Zatim, razvijen je neuronski model sa dve zasebne veštačke neuronske mreže koji generiše zavisnost induktivnosti i otpornosti u odnosu na lateralne dimenzije mosta prekidača (Slika 5.2 (a)). Između više obučenih VNM sa različitim brojem skrivenih neurona i slojeva, najbolji rezultati su ostvareni sa neuronskim modelima koji imaju strukturu 2-10-10-1, tj. dva skrivena sloja sa po 10 neurona u svakom skrivenom sloju. VNM 1 je za ulazne kombinacije korišćene za obučavanje mreže generisala vrednosti induktivnosti sa maksimalnom apsolutnom greškom od 0.49 pH i relativnom greškom od 0.94%. Takođe, VNM 2 formirana



za određivanje otpornosti, generisala je vrednosti sa maksimalnom apolutnom greškom od 6.8 mΩ i maksimalnom relativnom greškom od 0.72% [101]. Navedeno ukazuje da su neuronski modeli vrlo dobro obučeni za generisanje željenih parametara. Takođe, ostvarena je vrlo dobra generalizacija VNM, što je ilustrovano u tabelarnom prikazu dobijenih rezultata za test kombinacije koje nisu korišćene u procesu obučavanja. U slučaju istovremenog određivanja vrednosti induktivnosti i otpornosti (sa jednim neuronskim modelom) najbolje rezultate je generisao model 2-25-1, tj. VNM 3 sa jednim skrivenim slojem od 25 neurona. U Tabeli 5.3 prikazani su rezultati predikcije induktivnosti za oba predložena pristupa za test kombinacije. Rezultati ukazuju da je apsolutna greška manja od 0.52 pH, dok je relativna greška manja od 1.2%. U Tabeli 5.4 prikazani su rezultati predikcije otpornosti predloženih pristupa za test kombinacije. U ovom slučaju apsolutna greška je manja od 8.6 mΩ, dok je relativna greška manja od 1% [101].

Tabela 5.3 Test rezultati za induktivnost

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	$L$ (target) (pH)	zasebna VNM 1 (2-10-10-1)			VNM 3 (2-25-2)		
			$L$ (VNM) (pH)	Abs. greška (pH)	Rel. greška (%)	$L$ (VNM) (pH)	Abs. greška (pH)	Rel. greška (%)
250	25	30.06	29.93	0.13	0.42	30	0.06	0.21
250	75	36.69	36.60	0.09	0.25	36.7	0.004	0.01
350	25	41.93	42.26	0.33	0.78	42.4	0.48	1.15
350	75	49.28	49.74	0.46	0.93	49.8	0.51	1.04


Tabela 5.4 Test rezultati za otpornost

$L_s$ ( $\mu\text{m}$ )	$L_f$ ( $\mu\text{m}$ )	$R$ (target) (mΩ)	zasebna VNM 2 (2-10-10-1)			VNM 3 (2-25-2)		
			$R$ (VNM) (mΩ)	Abs. greška (mΩ)	Rel. greška (%)	$R$ (VNM) (mΩ)	Abs. greška (mΩ)	Rel. greška (%)
250	25	863.8	859.6	4.2	0.49	860	3.59	0.42
250	75	895.3	893.2	2.1	0.23	889	6.18	0.69
350	25	927.1	918.7	8.4	0.91	919	8.58	0.92
350	75	945.8	951.8	6.0	0.63	945	0.58	0.06


Prezentovani rezultati navode na zaključak da elementi ekvivalentnog kola koji su određeni neuronskim modelima, u oba slučaja su veoma blizu referentnim vrednostima, što ukazuje na veoma dobru tačnost razvijenih neuronskih modela. Pri tome, ne postoji značajna razlika u pogledu tačnosti predloženih pristupa (istovremeno ili zasebno određivanje

elemenata ekvivalentnog kola). Međutim, manja prednost se može dodeliti postupku određivanja elemenata ekvivalentnog kola sa jednom VNM, iz razloga što je potrebno formiranje i obuka samo jedne VNM, čime se skraćuje vreme potrebno za razvoj i implementaciju predloženog modela. Takođe, broj izraza prilikom implementacije modela u VAR blok je manji u slučaju istovremenog određivanja elemenata ekvivalentnog kola. Međutim, navedeno zavisi od veličine mreže i ne mora biti pravilo za sve slučajeve.

Dalja validacija predloženih modela je izvršena kroz proveru tačnosti S-parametara između vrednosti dobijenih na osnovu predloženog hibridnog modela i vrednosti koje su dobijene u *full-wave* simulacijama. Naime, induktivnost i otpornost prekidača koje odgovaraju kombinaciji lateralnih dimenzija  $L_s$  i  $L_f$  su dodeljene odgovarajućim elementima elektronskog kola. Poređenje rezultata modelovanja S-parametara korišćenjem predloženog modela sa vrednostima S-parametara dobijenih u *ADS Momentum* simulatoru pokazuju veoma dobro poklapanje. U cilju ilustracije, na Slikama 5.3 i 5.4 prikazano je unutrašnje slabljenje  $|S_{21}|$  i povratno slabljenje  $|S_{11}|$  za prekidač sa lateralnim dimenzijama mosta  $L_s = 350 \mu\text{m}$  i  $L_f = 25 \mu\text{m}$  [101]. Prekidač sa navedenim dimenzijama mosta je izabran kao primer jer su neuronski modeli u ovom slučaju generisali najveću devijaciju modelovanih u odnosu na referentne vrednosti. Može se zaključiti da iako tačnost generisanih vrednosti L i R varira zavisno od kombinacije lateralnih dimenzija prekidača, ekvivalentno kolo ima skoro identične vrednosti u odnosu na ciljne vrednosti dobijene u *full-wave* simulacijama.



Slika 5.3  $S_{21}$  vrednosti RF MEMS prekidača sa dimenzijama  $L_s = 350 \mu\text{m}$  i  $L_f = 25 \mu\text{m}$


 Slika 5.4  $S_{11}$  vrednosti RF MEMS prekidača sa dimenzijama  $L_s = 350 \mu\text{m}$  i  $L_f = 25 \mu\text{m}$ 

Dodatna validacija predloženog modela, izvršena je upoređivanjem S-parametara koji su simulirani ekvivalentnim kolom i *full-wave* simulatorom sa S-parametrima koji su izmereni za realizovanu komponentu. Realizovana komponenta je proizvedena u FBK u Trentu i ima dužinu prsta mosta  $L_f = 40 \mu\text{m}$  i dužinu osnove mosta od  $L_s = 174 \mu\text{m}$ . Komponenta je optimizovana za rezonantnu frekvenciju od 15 GHz [8]. Tabele 5.5 i 5.6 prikazuju vrednosti induktivnosti i otpornosti, koje su dobijene iz razvijenih neuronskih modela za prekidač sa lateralnim dimenzijama koje ima realizovana komponenta [101].

Tabela 5.5 Induktivnost realizovane komponente dobijena neuronskim modelima


VNM model	$L$ (target) (pH)	$L$ (VNM) (pH)	Abs. greška (pH)	Rel. greška (%)
VNM 1 (2-10-10-1)	23.79	22.93	0.86	3.61
VNM 3 (2-25-2)		22.9	0.865	3.63

Tabela 5.6 Otpornost realizovane komponente dobijena neuronskim modelima

VNM model	$R$ (target) (m $\Omega$ )	$R$ (VNM) (m $\Omega$ )	Abs. greška (m $\Omega$ )	Rel. greška (%)
VNM 2 (2-10-10-1)	843.1	803.1	40.0	4.74
VNM 3 (2-25-2)		793	49.6	5.89

U odnosu na prethodna poređenja dobijenih rezultata za ulazne vrednosti koje su korišćene, dimenzije mosta razmatrane realizovane komponente su potpuno nove i nisu

korišćene u procesu obučavanja i validacije neuronskih modela. Iako je procenat relativne greške nešto veći nego u slučajevima prethodno korišćenih dimenzija, odziv ekvivalentnog kola je skoro identičan referentnom odzivu koji je dobijen u *full-wave* simulatoru. Navedeno se može potvrditi prikazanim grafikom na Slici 5.5. Pored toga, prisutno je dobro poklapanje dobijenih rezultata sa merenim vrednostima realizovane komponente.



Slika 5.5 Uporedni pregled vrednosti  $S_{21}$  dobijenih hibridnim modelom u odnosu na referentne simulacije i realizovanu komponentu RF MEMS prekidača

Razvijeni neuronski modeli ostvarili su veoma dobru generalizaciju u predikciji elemenata ekvivalentnog kola. Modeli generišu dobru tačnost u celom razmatranom opsegu dimenzija mosta RF MEMS prekidača. Elementi ekvivalentnog kola koji su dobijeni razvijenim neuronskim modelima obezbeđuju vrednosti S-parametara koja veoma malo odstupaju od referentnih vrednosti dobijenih u *full-wave* simulatoru. Imajući u vidu činjenicu da je u najvećem broju slučajeva vreme za dizajn RF MEMS prekidača ograničeno, može se zaključiti da predloženi model je veoma pogodan za buduće analize i optimizacije razmatranih uređaja.

## **6 INVERZNO MODELOVANJE RF MEMS PREKIDAČA KORIŠĆENJEM NEURONSKIH MODELA**


U prethodnim glavama prikazana je primena predloženih neuronskih modela za efikasno modelovanje i analizu EM i mehaničkih karakteristika, kao i elemenata ekvivalentnog kola RF MEMS prekidača. Međutim, u praksi je neophodno razviti brz i pouzdan model koji bi vršio predikciju dimenzija mosta prekidača za zadate vrednosti EM i mehaničke karakteristike prekidača, odnosno potrebno je razviti model koji bi vršio optimizaciju geometrijskih parametara prekidača. U konkretnom slučaju, optimizacija je proces određivanja dimenzija mosta prekidača  $L_s$  i  $L_f$  za zadate vrednosti rezonantne frekvencije  $f$  i/ili napona aktivacije. U cilju prevazilaženja složenih i dugotrajnih procedura optimizacije u standardnim simulatorima, predložena je primena inverznih neuronskih modela RF MEMS prekidača, čime se značajno unapređuje proces projektovanja prekidača.

Razvoj inverznog neuronskog modela bazira na primeni direktnih neuronskih modela koji su prethodno opisani u Glavi 4. Opšta šema direktnog neuronskog modela prikazana je na Slici 6.1, gde ModPar predstavlja parametar koji se modeluje (rezonantna frekvencija ili napon aktivacije) u zavisnosti od lateralnih dimenzija mosta prekidača  $L_s$  i  $L_f$ . Potrebno je naglasiti da u procesu optimizacije sa inverznim neuronskim modelima nije moguće istovremeno određivanje obe dimenzije mosta prekidača, jer inverzne funkcije zavisnosti rezonantne frekvencije i napona aktivacije od lateralnih dimenzija prekidača nisu jednoznačne. Navedeno proističe iz činjenice da nekoliko prekidača sa različitim kombinacijama dimenzija mosta mogu imati iste vrednosti rezonantne frekvencije ili napone aktivacije. Iz tog razloga, predloženi su inverzni modeli kod kojih je jedna od dimenzija zadata dok se druga određuje za željene električne i/ili mehaničke karakteristike (ModPar). Stoga, predložene su dve varijante inverznih neuronskih modela (Slika 6.2). U prvoj varijanti, zadata je dimenzija

osnove mosta, a određuje se dužina prstiju mosta prekidača, dok je u drugoj varijanti zadata dužina prstiju, a određuje se dimenzija osnove mosta prekidača [23]. Drugim rečima, zamisao je obučavanje neuronskih mreža za određivanje vrednosti  $L_f$  za zadate date vrednosti  $L_s$  i ModPar (Slika 6.2 (a)) ili određivanje  $L_s$  za zadate vrednosti  $L_f$  i ModPar (Slika 6.2 (b)). Postupak razvoja inverznih neuronskih modela prikazan je na Slici 6.3.

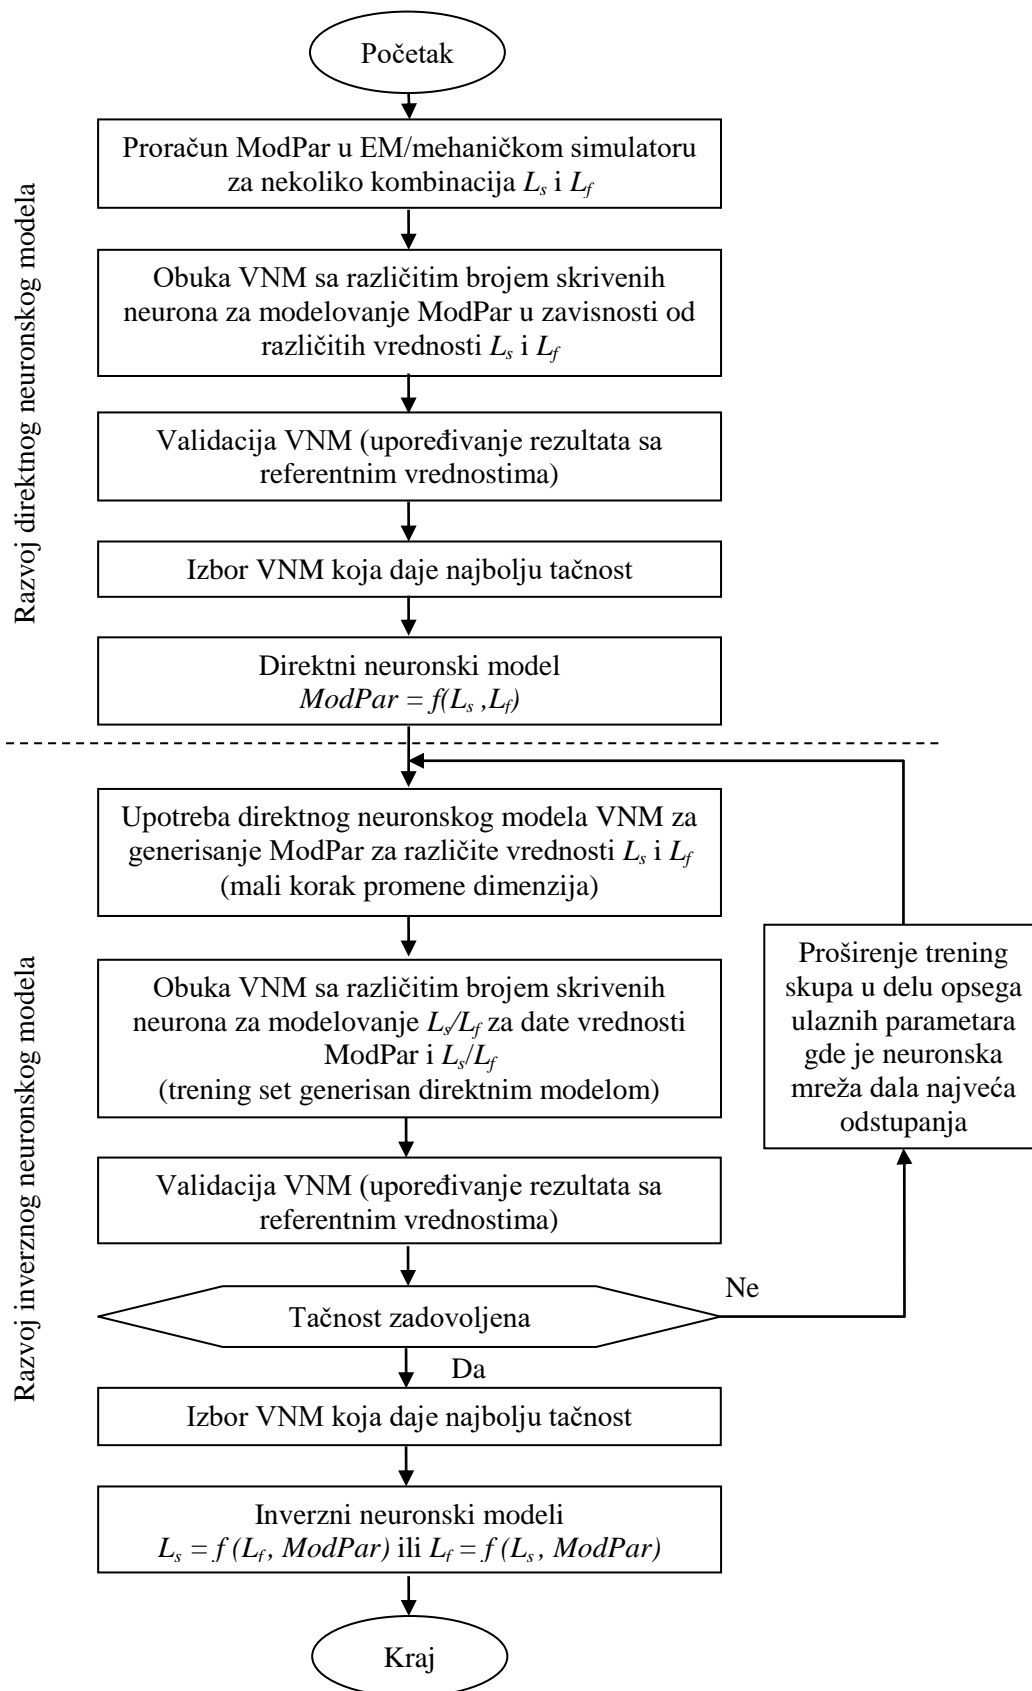


Slika 6.1 Direktni neuronski model



Slika 6.2 Inverzni neuronski modeli za određivanje: a)  $L_f$ ; b)  $L_s$

Za obuku navedenih mreža potrebni su odgovarajući trening podaci i to u obimu koji će obezbediti dovoljnu tačnost neuronskih modela u predikciji dimenzija prekidača. Prvi način obezbeđivanja trening skupa sa većim brojem podataka je primena standardnih EM ili mehaničkih simulatora, što višestruko povećava vreme potrebno za razvoj modela. Ilustracije radi, simulacija rezonantne frekvencije za jednu kombinaciju razmatranih geometrijskih parametara prekidača u *full-wave* simulatoru traje oko 5 minuta, dok proračun napona aktuacije u mehaničkom simulatoru traje oko dva sata. S obzirom da neuronski modeli trenutno generišu rezultate modelovanih parametara, veliki trening set za inverzne modele efikasno se obezbeđuje korišćenjem direktnih neuronskih modela (Slika 6.1), čime se može ostvariti značajna ušteda u vremenu generisanja potrebnog trening skupa u odnosu na klasične simulatore. Pristup korišćenja direktnih modela za generisanje velikog trening skupa u postupku razvoju inverznih neuronskih modela je primenjen za razvijanje modela prikazanih u ovom delu doktorske disertacije, a detaljan postupak je prikazan na Slici 6.3.



Slika 6.3 Procedure razvoja modela za inverzno modelovanje RF MEMS prekidača sa generisanjem trening podataka korišćenjem direktnih neuronskih modela

## 6.1 INVERZNI NEURONSKI MODELI ZA EM I MEHANIČKE KARAKTERISTIKE RF MEMS PREKIDAČA

U ovom poglavlju predloženi su inverzni neuronski modeli koji omogućavaju direktno određivanje geometrijskih dimenzija RF MEMS prekidača za željene vrednosti rezonantne frekvencije i napona aktivacije. Modeli razmatranog prekidača razvijeni su za sledeće opsege geometrijskih parametara RF MEMS prekidača:  $L_s$  od 50  $\mu\text{m}$  do 500  $\mu\text{m}$  i  $L_f$  od 0 do 100  $\mu\text{m}$ . Formiranje trening skupa sa velikim brojem uzoraka izvršeno je korišćenjem direktnih modela opisanih u Poglavljima 4.1 i 4.2.

Za formiranje inverznih modela za određivanje električnih karakteristika formiran je skup od 814 kombinacija ulaznih veličina i odgovarajućih vrednosti izlaznih veličina. U postupku razvoja inverznih neuronskih modela formiran je veći broj mreža sa različitim brojem skrivenih slojeva i neurona u njima. Obučene mreže za inverzno modelovanje testirane su skupom test podataka koji nisu korišćeni u postupku obučavanja neuronskih mreža. U oba slučaja, tj. kod modela za određivanje  $L_s$  i modela za određivanje  $L_f$ , najbolje rezultate su dale neuronske mreže sa dva skrivena sloja sa po 15 neurona u svakom (2-15-15-1). Navedeni modeli izabrani su kao najbolji inverzni neuronski modeli za generisanje lateralnih dimenzija prekidača. U cilju ilustracije tačnosti inverznih modela, dobijeni rezultati testiranja prikazani su u Tabelama 6.1. i 6.2 [23, 89]. Potrebno je naglasiti da su vrednosti rezonantne frekvencije prikazane u tabelama dobijene u *full-wave* simulatoru za ciljnu vrednost razmatrane lateralne dimenzije.

Tabela 6.1 Inverzno modelovanje RF MEMS prekidača - određivanje  $L_f$

$L_s$ ( $\mu\text{m}$ )	$f_{res}$ (GHz)	$L_f$ (target) ( $\mu\text{m}$ )	$L_f$ (VNM) ( $\mu\text{m}$ )	Abs. greška ( $\mu\text{m}$ )	Rel. greška (%)
75	22.78	25	24.9	0.1	0.4
75	19.17	65	65.4	0.4	0.6
75	17.92	85	85.3	0.3	0.3
100	17.5	75	73.6	1.4	1.9
200	13.13	85	86.8	1.8	2.1
350	11.67	25	23.4	1.6	6.4
350	10.83	65	62.2	2.8	4.3
400	10	85	87.4	2.4	2.9




Tabela 6.2 Inverzno modelovanje RF MEMS prekidača - određivanje  $L_s$


$L_f$ ( $\mu\text{m}$ )	$f_{res}$ (GHz)	$L_s$ (target) ( $\mu\text{m}$ )	$L_s$ (VNM) ( $\mu\text{m}$ )	Abs. greška ( $\mu\text{m}$ )	Rel. greška (%)
25	22.78	75	74.9	0.1	0.1
65	19.17	75	75.5	0.5	0.7
85	17.92	75	75.3	0.3	0.4
75	17.5	100	97.9	2.1	2.1
85	13.13	200	202.7	2.7	1.4
25	11.67	350	347.8	2.2	0.6
65	10.83	350	348.0	2.0	0.6
85	10	400	403.4	3.4	0.9

Može se zaključiti da je relativna greška u većini slučajeva manja od 3%. Apsolutna razlika vrednosti određenih pomoću neuronskih modela i ciljnih vrednosti je manja od 3  $\mu\text{m}$  u slučaju modelovanja dužine  $L_f$  i manja od 3.5  $\mu\text{m}$  kod modelovanja dužine  $L_s$ , što je u granicama fabričkih tolerancija.

Predloženi inverzni modeli su validni samo u određenom delu ulaznog prostora koji je određen fizički mogućim kombinacijama ulazno-izlaznih veličina. Naime, prilikom generisanja skupa za obučavanje mreža, korišćene su rezonantne frekvencije koje odgovaraju dužinama osnove mosta  $L_s$  od 50  $\mu\text{m}$  do 500  $\mu\text{m}$  i dužinama prstiju mosta  $L_f$  od 0 do 100  $\mu\text{m}$ . To znači da vrednost rezonantne frekvencije na ulazu u inverzne modele treba da odgovara odgovarajućem opsegu vrednosti rezonantne frekvencije korišćenom za obučavanje mreža. Najbrži način za određivanje ulaznog prostora inverznih neuronskih modela je očitavanje vrednosti rezonantne frekvencije za vrednosti lateralnih dimenzija sa grafika koji su generisani direktnim neuronskim modelima (Slika 6.4). U cilju ilustracije, na Slici 6.4.(a) prikazan je ulazni prostor za inverzni model namenjen za određivanje  $L_s$ . Na primer, ako se projektuje prekidač čija rezonantna frekvencija treba da bude 12 GHz, vrednost  $L_s$  treba odabrati u opsegu od 250  $\mu\text{m}$  do 350  $\mu\text{m}$ , pošto za druge vrednosti  $L_s$  fizički nije moguće ostvariti željenu rezonantnu frekvenciju. Dok u drugom primeru, za frekvencije reda 20 GHz, mogući opseg vrednosti osnove mosta je u granicama od 50  $\mu\text{m}$  do 150  $\mu\text{m}$ . Na Slici 6.4. (b) prikazan je opseg validnosti inverznog modela za određivanje parametra  $L_f$ . Može se uočiti da je za vrednosti rezonantne frekvencije od 10 GHz do 18 GHz, moguće odrediti  $L_f$  za bilo koju od vrednosti  $L_f$  iz razmatranog opsega ovog parametra. Za rezonantnu frekvenciju 24 GHz, model je validan samo za vrednosti  $L_f$  do 40  $\mu\text{m}$ .



a)



b)

Slika 6.4 Prostor ulaznih veličina za inverzne EM modele na osnovu generisanih vrednosti iz direktnih neuronskih modela za određivanje: a)  $L_f$  i b)  $L_s$

Postupak inverznog modelovanja mehaničkih karakteristika je identičan postupku inverznog modelovanja električnih karakteristika, sa razlikom da je napon aktivacije ulazni parametar korišćen u razvoju inverznog modela. Direktni model koji je korišćen za generisanje trening skupa sa velikim brojem uzoraka je direktni neuronski model sa osam neurona u jednom skrivenom sloju (2-8-1), opisan u Poglavlju 4.3. U postupku razvoja inverznog modela, prvo je korišćen trening skup za uniformno uzorkovane vrednosti  $L_f$  i  $L_s$ . Dalje je trening skup proširivan u delovima zadanog opsega ulaznih parametara gde je

neuronska mreža za uniformni trening skup dala najveće greške. Na taj način je postupno smanjivana greška modelovanja razvijenog neuronskog modela, a trening skup sa kojim je postignuta zadovoljavajuća tačnost imao je 961 uzorak. Upotrebom ovog trening skupa izvršeno je obučavanje većeg broja inverznih modela sa različitim brojem skrivenih slojeva i broja neurona u njima. Nakon izvršenog testiranja odziva inverznih modela, izabrane su sledeće neuronske mreže sa najvećim stepenom tačnosti: mreža (2-25-25-1) za predikciju parametra  $L_f$  i mreža (2-4-6-1) za predikciju parametra  $L_s$ . Rezultati validacije navedenih inverznih modela prikazani su u Tabelama 6.3. i 6.4. Testiranje je izvršeno za kombinacije ulaznih parametara koje nisu korišćene u trening skupu tokom obučavanja neuronskih mreža [23, 102].

Tabela 6.3 *Inverzno modelovanje RF MEMS prekidača - određivanje  $L_f$*


$L_s$ ( $\mu\text{m}$ )	$V_{PI}$ (V)	$L_f$ (target) ( $\mu\text{m}$ )	$L_f$ (VNM) ( $\mu\text{m}$ )	Aps. greška ( $\mu\text{m}$ )	Rel. greška (%)
150	55.6	25	24.9	0.1	0.5
150	43	65	66.7	1.7	2.7
250	33.3	25	24.3	0.7	2.9
250	28.2	65	65.1	0.1	0.1
350	25.2	10	11.2	1.2	12.0
350	23.8	25	24.0	1.0	4.1
350	21.1	65	62.7	2.3	3.5
350	20.5	75	74.4	0.6	0.8
450	16.9	65	62.5	2.5	3.9

Tabela 6.4 *Inverzno modelovanje RF MEMS prekidača - određivanje dimenzije  $L_s$*


$L_f$ ( $\mu\text{m}$ )	$V_{PI}$ (V)	$L_s$ (target) ( $\mu\text{m}$ )	$L_s$ (VNM) ( $\mu\text{m}$ )	Abs. greška ( $\mu\text{m}$ )	Rel. greška (%)
25	55.6	150	150.1	0.1	0.1
65	43	150	151.6	1.6	1.1
25	33.3	250	250.2	0.2	0.1
65	28.2	250	250.2	0.2	0.1
10	25.2	350	350.03	0.03	0.01
25	23.8	350	347.4	2.5	0.7
65	21.1	350	348.	1.9	0.5
75	20.5	350	349.1	0.9	0.2
65	16.9	450	447.0	2.0	0.4

Na osnovu prikazanih rezultata može se zaključiti da je relativna greška u većini slučajeva manja od 4%. Međutim, u svim slučajevima je apsolutna razlika između ciljne

vrednosti i vrednosti dobijenih inverznim modelima manja od  $3 \mu\text{m}$ , što je približno vrednosti fabričkih tolerancija.



a)



(b)

Slika 6.5 Prostor ulaznih veličina za inverzne mehaničke modele na osnovu generisanih vrednosti iz direktnih neuronskih modela za određivanje: a)  $L_f$  i b)  $L_s$

Kao i kod inverznih električnih modela, i kod primene mehaničkih inverznih modela treba voditi računa o ulaznim vrednostima za koje se primenjuje model, odnosno predloženi inverzni modeli su validni samo u određenom delu ulaznog prostora koji je određen fizički mogućim kombinacijama ulazno-izlaznih veličina. Naime, prilikom generisanja skupa za obučavanje mreža, korišćene su vrednosti napona aktivacije koje odgovaraju dužinama osnove


mosta  $L_s$  od 125  $\mu\text{m}$  do 500  $\mu\text{m}$  i dužine prstiju mosta  $L_f$  od 0 do 100  $\mu\text{m}$ . To znači da vrednosti napona aktivacije na ulazu u inverzne modele treba da odgovara odgovarajućem opsegu vrednosti napona aktivacije korišćenom za obučavanje mreža.

Na Slici 6.5. prikazani su opsezi validnosti inverznih mehaničkih modela za određivanje  $L_s$  i  $L_f$ , a koji su generisani direktnim neuronskim modelima. Na taj način su direktni neuronski modeli iskorišćeni kao najbrži način određivanja ulaznog prostora inverznih neuronskih modela. Na primer, ako se određuje dimenzija  $L_f$ , tako da napon aktivacije bude 40V, ulazna vrednost  $L_s$  može biti u opsegu od 125  $\mu\text{m}$  do 260  $\mu\text{m}$  (Slika 6.5 (a)). Za istu vrednost napona, za bilo koju od razmatranih vrednosti  $L_f$  u opsegu do 100  $\mu\text{m}$  moguće je odrediti odgovarajuću vrednost  $L_s$  korišćenjem modela za određivanje  $L_s$  (Slika 6.5 (b)). Takođe, vrednosti napona aktivacije od 18 V do 40 V, moguće je ostvariti sa bilo kojom dimenzijom  $L_f$  iz razmatranog opsega ovog parametra.

## **6.2 INVERZNI NEURONSKI MODELI ZA ELEKTRO-MEHANIČKE KARAKTERISTIKE RF MEMS PREKIDAČA**

Uzimajući u obzir da geometrijski parametri prekidača određuju električne i mehaničke karakteristike RF MEMS prekidača, u prethodnim poglavljima disertacije predloženi su inverzni neuronski modeli koji se odnose zasebno na električne i mehaničke karakteristike prekidača. U cilju pojednostavljenja postupka, predložen je prošireni pristup inverznog modelovanja, tj. postupak koji kombinuje električne i mehaničke karakteristike RF MEMS prekidača. Time je u potpunosti izbegnut dugotrajan postupak modelovanja komponente u EM i mehaničkom simulatoru, kao i proces optimizacije geometrijskih dimenzija prekidača [23, 103].

Osnovna ideja predloženog elektro-mehaničkog inverznog modelovanja RF MEMS kapacitivnog prekidača je obučavanje neuronske mreže za određivanje jedne lateralne dimenzije mosta prekidača  $L_f$  (ili  $L_s$ ) na osnovu zadate vrednosti druge dimenzije mosta  $L_s$  (ili  $L_f$ ) u cilju postizanja željene rezonantne frekvencije  $f_{res}$  i napona aktivacije  $V_{PI}$ . Predloženi neuronski model ima tri ulazne vrednosti  $L_f$  (ili  $L_s$ ),  $f_{res}$  i  $V_{PI}$ , a na izlazu se generiše vrednost  $L_s$  (ili  $L_f$ ). Na Slici 6.6. prikazani su predloženi elektro-mehanički neuronski modeli.



Slika 6.6 Predloženi inverzni elektro-mehanički modeli za određivanje: a)  $L_f$  i b)  $L_s$

U cilju razvoja modela potrebno je obezbediti vrednosti rezonantne frekvencije i napona aktuacije za određeni broj kombinacija dimenzija  $L_s$  ili  $L_f$ . Generalno, ti podaci se mogu obezbediti simulacijom u odgovarajućim standardnim simulatorima. Drugi mnogo brži i jednostavniji način je primenom ranije razvijenih direktnih neuronskih modela za određivanje električnih i mehaničkih karakteristika, na isti način koji je opisan u prethodnom poglavlju, a što je primenjeno i u postupku razvoja inverznih elektro-mehaničkih modela. Dakle, trening skup za razvoj neuronskog modela dobijen je iz direktnih neuronskih modela  $f_{res}=f_{VNM}(L_s, L_f)$  i  $V_{pi}=f_{VNM}(L_s, L_f)$ , opisanih u Glavi 4, generisanjem vrednosti rezonantne frekvencije i napona aktuacije za određeni broj kombinacija razmatranih dimenzija mosta prekidača. Formiran je trening skup od 4131 uzoraka, sa većim brojem uzoraka u delovima ulaznog prostora gde postoji brža promena modelovanog parametra. Neuronski modeli su, kao i u svim prethodnim slučajevima, obučavani korišćenjem *Levenberg-Marquardt*-og algoritma. Kako broj skrivenih slojeva i neurona nije moguće u napred odrediti, treniran i testiran je veći broj neuronskih mreža sa različitim brojem skrivenih neurona. Razvijene mreže testirane su test skupom od 40 kombinacija vrednosti  $L_s$  i  $L_f$ , koje su dobijene simulacijama rezonantne frekvencije i napona aktuacije u EM i mehaničkom simulatoru. Kao konačni modeli, izabrani su inverzni elektro-mehanički modeli koji su pokazali najbolje rezultate testiranja. Kod određivanja vrednosti  $L_f$  najbolji rezultati ostvareni su inverznim elektro-mehaničkim modelom koji se sastoji od dva skrivena sloja sa 10 neurona u prvom i 20 neurona u drugom skrivenom sloju (3-10-20-1). Za određivanje vrednosti  $L_s$  najbolji inverzni elektro-mehanički model je neuronska mreža od dva skrivena sloja sa 20 neurona u prvom i 10 neurona u drugom skrivenom sloju (3-20-10-1). U Tabelama 6.5 i 6.6 dati su rezultati testiranja izabranih neuronskih mreža.

Tabela 6.5 Test rezultati izabranog neuronskog modela (3-10-20-1) za određivanje  $L_f$

$L_s$ [ $\mu\text{m}$ ]	$f_{res}$ [GHz]	$V_{PI}$ [V]	$L_f$ (target) [ $\mu\text{m}$ ]	$L_f$ (VNM) [ $\mu\text{m}$ ]	Abs. greška [ $\mu\text{m}$ ]	Rel. greška [%]
200	16.39	53.5	0	0.20	0.20	Inf
300	13.13	33	0	0.05	0.05	Inf
400	11.25	23.8	0	0.07	0.07	Inf
500	10.00	18.8	0	0.74	0.74	Inf
125	20.21	76.5	10	10.02	0.02	0.21
250	14.17	35.9	10	10.47	0.47	4.70
350	11.88	25.2	10	10.51	0.51	5.10
450	10.42	20.8	10	9.53	0.47	4.70
200	15.56	43.1	20	19.21	0.79	3.90
300	12.71	28.4	20	19.19	0.81	4.00
400	10.83	21.2	20	19.63	0.37	1.90
500	9.583	17.1	20	20.45	0.45	2.30
150	17.92	55.6	25	25.77	0.77	3.10
250	13.75	33.3	25	25.89	0.89	3.60
350	11.67	23.8	25	24.15	0.86	3.40
450	10.21	18.6	25	24.28	0.72	2.90
125	18.13	58.9	40	39.10	0.90	2.20
200	14.81	38.6	40	39.28	0.72	1.80
300	12.08	26.2	40	40.42	0.42	1.10
400	10.63	20.1	40	40.77	0.77	1.90
200	14.44	36.6	50	49.68	0.32	0.64
300	11.88	25.4	50	48.67	1.34	2.70
400	10.42	19.6	50	48.97	1.03	2.10
500	9.375	15.9	50	50.25	0.25	0.49
150	15.56	43	65	65.33	0.33	0.51
250	12.71	28.2	65	65.81	0.81	1.20
350	10.83	21.1	65	64.78	0.22	0.34
450	9.583	16.9	65	66.05	1.05	1.60
250	12.5	27.2	75	75.39	0.39	0.51
350	10.63	20.5	75	77.49	2.49	3.30
450	9.583	16.5	75	72.60	2.40	3.20
200	13.13	31.4	85	86.01	1.01	1.20
300	11.25	22.7	85	84.62	0.38	0.44
400	10.00	17.9	85	86.35	1.35	1.60
500	8.958	14.8	85	84.16	0.84	0.99
125	14.79	41.1	100	100.18	0.18	0.18
200	12.92	29.8	100	98.65	1.35	1.30
300	11.04	21.7	100	100.45	0.45	0.45
400	9.792	17.4	100	98.67	1.33	1.30
500	8.924	14.4	100	101.37	1.37	1.40


Tabela 6.6 Test rezultati izabranog neuronskog modela (3-20-10-1) za određivanje  $L_s$

$L_f$ [ $\mu\text{m}$ ]	$f_{res}$ [GHz]	$V_{PI}$ [V]	$L_s$ (target) [ $\mu\text{m}$ ]	$L_s$ (VNM) [ $\mu\text{m}$ ]	Abs. greška [ $\mu\text{m}$ ]	Rel. greška [%]
0	16.39	53.5	200	199.35	0.65	0.33
0	13.13	33	300	300.68	0.68	0.23
0	11.25	23.8	400	400.74	0.74	0.19
0	10.00	18.8	500	499.85	0.15	0.03
10	20.21	76.5	125	125.67	0.67	0.53
10	14.17	35.9	250	250.62	0.62	0.25
10	11.88	25.2	350	349.67	0.33	0.09
10	10.42	20.8	450	446.90	3.10	0.69
20	15.56	43.1	200	198.90	1.10	0.55
20	12.71	28.4	300	298.89	1.11	0.37
20	10.83	21.2	400	402.22	2.22	0.55
20	9.583	17.1	500	499.37	0.63	0.13
25	17.92	55.6	150	150.38	0.38	0.26
25	13.75	33.3	250	250.52	0.52	0.21
25	11.67	23.8	350	348.15	1.85	0.53
25	10.21	18.6	450	449.61	0.39	0.09
40	18.13	58.9	125	124.84	0.16	0.12
40	14.81	38.6	200	197.93	2.07	1.00
40	12.08	26.2	300	300.45	0.45	0.15
40	10.63	20.1	400	402.36	2.36	0.59
50	14.44	36.6	200	199.72	0.28	0.14
50	11.88	25.4	300	297.79	2.21	0.74
50	10.42	19.6	400	399.62	0.38	0.09
50	9.375	15.9	500	497.31	2.69	0.54
65	15.56	43	150	150.84	0.84	0.56
65	12.71	28.2	250	251.10	1.10	0.44
65	10.83	21.1	350	350.61	0.61	0.17
65	9.583	16.9	450	447.71	2.29	0.51
75	12.5	27.2	250	249.73	0.27	0.11
75	10.63	20.5	350	351.58	1.58	0.45
75	9.583	16.5	450	450.09	0.09	0.02
85	13.13	31.4	200	200.83	0.83	0.42
85	11.25	22.7	300	299.98	0.02	0.01
85	10.00	17.9	400	399.61	0.39	0.09
85	8.958	14.8	500	499.29	0.71	0.14
100	14.79	41.1	125	123.58	1.42	1.10
100	12.92	29.8	200	198.93	1.07	0.53
100	11.04	21.7	300	301.26	1.26	0.42
100	9.792	17.4	400	396.59	3.41	0.85
100	8.924	14.4	500	498.45	1.55	0.31




Može se uočiti dobro slaganje vrednosti dobijenih neuronskim modelom sa ciljnim vrednostima. Iako za pojedine ulazne kombinacije vrednosti relativne greške dostižu 6%, apsolutna odstupanja su do  $2\ \mu\text{m}$  u slučaju određivanja  $L_f$  i do  $3.5\ \mu\text{m}$  u slučaju određivanja  $L_s$ , a što je u nivou fabričkih tolerancija.

U cilju dodatne ilustracije tačnosti modelovanja, na Slici 6.7 prikazani su korelacioni dijagrami vrednosti  $L_f$  i  $L_s$  dimenzija dobijenih pomoću inverznih elektro-mehaničkih modela u odnosu na ciljne vrednosti dimenzija. Može se uočiti veoma malo rasejanje u odnosu na dijagonalnu liniju  $y = x$  koja predstavlja idealno modelovanje, što potvrđuje tačnost razvijenih inverznih modela.



a)



b)

Slika 6.7 Grafički prikaz tačnosti modelovanja: a)  $L_f$  i b)  $L_s$

Radi daljeg potvrđivanja tačnosti predloženih modela, izvršena je analiza tačnosti određivanja rezonantne frekvencije i napona aktuacije korišćenjem vrednosti dimenzija određenih pomoću razvijenih inverznih elektro-mehaničkih modela za zadate ciljne vrednosti rezonantne frekvencije i napona aktuacije.

U konkretnom primeru, postavljen je zadatak da se odrede dimenzije prekidača upotrebom razvijenih inverznih elektro-mehaničkih modela za zadate vrednosti  $f_{res}=12$  GHz i  $V_{PI}=25$  V. Postupak je sledeći: za zadate vrednosti rezonantne frekvencije i napona aktuacije određene su vrednosti  $L_f$  za nekoliko vrednosti  $L_s$  pomoću odgovarajućeg inverznog elektro-mehaničkog modela:

$$L_{f\_inv} = f_{VNM\_inv}(L_s, V_{PI}, f_{res}), \quad (6.1)$$

Zatim su tako dobijene vrednosti korišćene kao ulazne vrednosti direktnih neuronskih modela za predikciju rezonantne frekvencije i napona aktuacije, respektivno:

$$f_{res\_dir} = f_{VNM\_dirE}(L_{f\_inv}, L_s), \quad (6.2)$$

$$V_{PI\_dir} = f_{VNM\_dirM}(L_{f\_inv}, L_s), \quad (6.3)$$

Isti postupak je primenjen i na model za određivanje vrednosti  $L_s$ . Najpre su za zadate vrednosti rezonantne frekvencije i napona aktuacije određene su vrednosti  $L_s$  za nekoliko vrednosti  $L_f$  pomoću odgovarajućeg inverznog elektro-mehaničkog modela:

$$L_{s\_inv} = f_{VNM\_inv}(L_f, V_{PI}, f_{res}), \quad (6.4)$$

koje su dalje korišćene kao ulazne vrednosti direktnih neuronskih modela za predikciju rezonantne frekvencije i napona aktuacije, respektivno:

$$f_{res\_dir} = f_{VNM\_dirE}(L_{s\_inv}, L_f), \quad (6.5)$$

$$V_{PI\_dir} = f_{VNM\_dirM}(L_{s\_inv}, L_f), \quad (6.6)$$

U oba slučaja, ovako dobijene vrednosti upoređivane su sa inicijalno zadatim vrednostima  $f_{res}$  i  $V_{PI}$  koje su korišćene kao ulazi za inverzne modele. Stepen tačnosti predloženog modela iskazan je kroz vrednosti apsolutne i relativne greške, što je prikazano u Tabelama 6.7 – 6.10.

Korišćene oznake imaju sledeće definicije prikazanih grešaka:

$$AG_{f_{res}} = |f_{res\_dir} - f_{res}|, \quad (6.7)$$

$$AG_{V_{PI}} = |V_{PI\_dir} - V_{PI}|, \quad (6.8)$$

$$RG_{f_{res}} = AG_{f_{res}}/f_{res}, \quad (6.9)$$

$$RG_{V_{PI}} = AG_{V_{PI}}/V_{PI}, \quad (6.10)$$

Tabela 6.7 Rezultati inverznog modelovanja dimenzije  $L_f$  RF MEMS prekidača:  $f_{res}$

$L_s$ [ $\mu\text{m}$ ]	$f_{res}$ [GHz]	$V_{PI}$ [V]	$L_{f\_inv}$ [ $\mu\text{m}$ ]	$f_{res\_dir}$ [GHz]	$AG_{f_{res}}$ [GHz]	$RG_{f_{res}}$ [%]
280	12	25	71.35	11.89	0.11	0.95
290	12	25	61.70	11.86	0.14	1.20
300	12	25	52.23	11.83	0.17	1.40
310	12	25	43.43	11.79	0.21	1.80
320	12	25	35.36	11.76	0.25	2.00
330	12	25	26.92	11.88	0.12	0.97
340	12	25	16.59	12.01	0.01	0.07

Tabela 6.8 Rezultati inverznog modelovanja dimenzije  $L_f$  RF MEMS prekidača:  $V_{PI}$

$L_s$ [ $\mu\text{m}$ ]	$f_{res}$ [GHz]	$V_{PI}$ [V]	$L_{f\_inv}$ [ $\mu\text{m}$ ]	$V_{PI\_dir}$ [V]	$AG_{V_{PI}}$ [V]	$RG_{V_{PI}}$ [%]
280	12	25	71.35	25.17	0.17	0.68
290	12	25	61.70	25.14	0.14	0.57
300	12	25	52.23	25.12	0.12	0.48
310	12	25	43.43	25.08	0.08	0.33
320	12	25	35.36	25.06	0.06	0.22
330	12	25	26.92	25.13	0.13	0.52
340	12	25	16.59	25.38	0.38	1.50

Tabela 6.9 Rezultati inverznog modelovanja dimenzije  $L_s$  RF MEMS prekidača:  $f_{res}$

$L_f$ [ $\mu\text{m}$ ]	$f_{res}$ [GHz]	$V_{PI}$ [V]	$L_{s\_inv}$ [ $\mu\text{m}$ ]	$f_{res\_dir}$ [GHz]	$AG_{f_{res}}$ [GHz]	$RG_{f_{res}}$ [%]
10	12	25	348.22	12.76	0.76	6.30
20	12	25	336.28	12.75	0.75	6.30
30	12	25	327.64	12.73	0.72	6.00
40	12	25	315.55	12.72	0.72	6.00
50	12	25	302.88	12.71	0.71	5.90
60	12	25	291.71	12.70	0.70	5.80
70	12	25	280.52	12.69	0.69	5.70
80	12	25	270.03	12.67	0.67	5.60
90	12	25	260.08	12.65	0.65	5.40
100	12	25	250.09	12.63	0.63	5.30


Tabela 6.10 Rezultati inverznog modelovanja dimenzije  $L_s$  RF MEMS prekidača:  $V_{PI}$

$L_f$ [ $\mu\text{m}$ ]	$f_{res}$ [GHz]	$V_{PI}$ [V]	$L_{s\_inv}$ [ $\mu\text{m}$ ]	$V_{PI\_dir}$ [V]	$AG_{V_{PI}}$ [V]	$RG_{V_{PI}}$ [%]
10	12	25	348.22	23.78	1.22	4.90
20	12	25	336.28	23.96	1.04	4.20
30	12	25	327.64	23.87	1.13	4.50
40	12	25	315.55	24.09	0.91	3.60
50	12	25	302.88	24.41	0.59	2.40
60	12	25	291.71	24.60	0.40	1.60
70	12	25	280.52	24.82	0.18	0.74
80	12	25	270.03	24.96	0.04	0.15
90	12	25	260.08	25.05	0.05	0.20
100	12	25	250.09	25.14	0.14	0.56

Na osnovu prikazanih rezultata, može se zaključiti da je relativna greška odstupanja rezonantne frekvencije i napona aktivacije od zadatih vrednosti u slučaju određivanja dimenzije  $L_f$  pomoću inverznog elektro-mehaničkog modela u svim slučajevima manja od 2%, čime je potvrđena veoma dobra tačnost predloženog pristupa (Tabele 6.7 i 6.8). Sa druge strane, u slučaju određivanja dimenzije  $L_s$  pomoću predloženog inverznog elektro-mehaničkog modela javljaju se nešto veća odstupanja vrednosti rezonantne frekvencije i napona aktivacije od zadatih vrednosti: relativna greška se kreće do 6%, dok apsolutne greške nisu veće od 0.7 GHz za rezonantnu frekvenciju i 1 V za napon aktivacije (Tabele 6.9 i 6.10).

Treba takođe pomenuti da i kod ovih modela treba voditi računa o prostoru mogućih vrednosti ulaznih veličina. Naime, prostor ulaznih veličina za koje je moguće dobiti fizički smislene rezultate je isti kao i kod posebnih EM i mehaničkih inverznih modela, s tim što treba uzeti u obzir veze obe lateralne dimenzije mosta prekidača sa rezonantnom frekvencijom i naponom aktivacije. Za proveru fizičke opravdanosti izabrane kombinacije ulaznih parametara može se iskoristiti kombinacija dijagrama sa Slike 6.8, na kome je prikazan prostor mogućih kombinacija rezonantne frekvencije i napona aktivacije i dijagrama prikazanih na Slikama 6.4 i 6.5. Postupak provere može biti objašnjen na sledećem primeru. Neka je zahtev da se projektuje RF MEMS prekidač čija bi rezonantna frekvencija bila 12 GHz i neka se razmatra model za određivanje  $L_f$ . Sa Slike 6.8 očitava se opseg vrednosti napona aktivacije od 25 V do 27 V za rezonantnu frekvenciju od 12 GHz. Rezonantna frekvencija se može ostvariti samo za vrednosti  $L_s$  u opsegu od 250  $\mu\text{m}$  do 350  $\mu\text{m}$  (Slika 6.4 (a)). Za bilo koju od izabranih vrednosti  $L_s$  i  $V_{PI}$  potrebno je proveriti na Slici 6.5 b, da li je željena kombinacija moguća. Na primer, za  $V_{PI} = 22$  V,  $L_s$  može imati vrednosti od 270  $\mu\text{m}$

do 400  $\mu\text{m}$ . Imajući u vidu prethodno određeni opseg za  $L_s$  od 250  $\mu\text{m}$  do 350  $\mu\text{m}$ , zaključuje se da je za frekvenciju 12 GHz i napon 22 V, opseg vrednosti  $L_s$  od 270  $\mu\text{m}$  do 350  $\mu\text{m}$ .




Slika 6.8 *Prostor mogućih kombinacija ulaznih veličina  $f_{res}$  -  $V_{PI}$*

### **6.3 PRIMENA INVERZNIH NEURONSKIH MODELA**

Prethodno predloženi inverzni neuronski modeli mogu se u jednostavnom i brzom postupku iskoristiti za određivanje dimenzija prekidača u cilju dostizanja željenih električnih i mehaničkih karakteristika, olakšavajući na taj način postupak projektovanja prekidača. Time je predstavljena osnovna prednost primene predloženih neuronskih modela u odnosu na klasične simulacione metode, uzimajući u obzir činjenicu da određivanje karakteristika prekidača zahteva veliki broj pojedinačnih simulacija i optimizacija za svaku konkretnu dimenziju prekidača, a takve procedure su proračunski i vremenski vrlo zahtevne. U nastavku će biti ilustrovane primene inverznih neuronskih modela za projektovanje RF MEMS prekidača.

### 6.3.1 Primena inverznog modela EM karakteristika za projektovanje RF MEMS prekidača


Za projektovanje RF MEMS prekidača u ovom delu korišćeni su inverzni neuronski modeli EM karakteristika, koji su opisani u Poglavlju 6.2, tj. neuronski modeli za određivanje dimenzije prsta mosta prekidača- $L_f$  za zadatu dužinu osnove mosta- $L_s$  i rezonantnu frekvenciju- $f_{res}$ . U prvom koraku, predloženi inverzni neuronski modeli su iskorišćeni za određivanje ukupne dužine mosta prekidača- $L_t$  (koja predstavlja zbir lateralnih dimenzija mosta  $L_t = L_s + L_f$ ) u cilju dostizanja željene vrednosti rezonantne frekvencije [98]. Na taj način je izbegnut problem nejednoznačnosti mapiranja između dimenzija mosta i željene vrednosti rezonantne frekvencije, odnosno pojava da različitim kombinacijama dimenzija mosta prekidača odgovara ista vrednosti rezonantne frekvencije. Na početku potrebno je utvrditi da li je moguće ostvariti zadatu vrednost rezonantne frekvencije za željenu ukupnu dužinu mosta prekidača. To se vrlo lako određuje analizom grafika na Slici 6.9, koji je dobijen kombinovanjem generisanih vrednosti dimenzija prekidača iz direktnih neuronskih modela (Poglavlje 4.4.4), iskazanih preko ukupne dužine prekidača  $L_t$ . Kao primer, neka je zadata vrednost rezonantne frekvencije 20 GHz, sa grafika se može očitati da je navedena vrednost ostvarljiva sa ukupnom dužinom mosta prekidača u rasponu od 130  $\mu\text{m}$  do 150  $\mu\text{m}$  ( $130 \mu\text{m} \leq L_t \leq 150 \mu\text{m}$ ).




Slika 6.9 Dužina mosta u odnosu na  $f_{res}$  u razmatranom opsegu dimenzija prekidača

Pošto se ustanovi da kombinacija željenih vrednosti  $L_t$  i  $f_{res}$  ispunjava fizičke uslove zadatih dimenzija prekidača i fizički je ostvarljiva, prelazi se na drugi korak u kojem se vrednosti  $L_s$  i  $L_f$  veoma lako očitavaju sa grafika. Vrednosti  $L_s$  i  $L_f$  su tačke preseka funkcije

inverznog neuronskog modela  $L_f = f_{inv\_VNM}(L_s, f_{res})$  i funkcije za vrednost  $L_f = L_t - L_s$ . U obe navedene funkcije, vrednost  $L_s$  treba da bude između  $0 \mu\text{m}$  i  $L_t$ . Kao primer, uzмимо da je željena vrednost  $f_{res} = 13 \text{ GHz}$  a  $L_t = 300 \mu\text{m}$ . Upotrebom inverznog neuronskog modela, za  $L_s$  od  $0$  do  $300 \mu\text{m}$  generisane se vrednosti  $L_f$  i prikazane na grafiku (puna linija na Slici 6.10 (a)). Na istom grafiku je isprekidanom linijom prikazana linearna funkcija  $L_f = L_t - L_s$ . Slika 6.10 (b) je u stvari uvećan deo Slike 6.10 (a) u oblasti preseka grafika, odnosno Slika 6.10 (b) predstavlja fizički moguće vrednosti  $L_f$  (zadebljani deo linije na Slici 6.10 (a)) [98]. Mesto preseka linija odgovara sledećim dimenzijama mosta prekidača:  $L_s = 228 \mu\text{m}$  i  $L_f = 72 \mu\text{m}$ .



a)




b)

Slika 6.10 Određivanje dimenzija  $L_s$  i  $L_f$  za zadatu ukupnu dužinu mosta  $L_t = 300 \mu\text{m}$ :

a) prikaz za celi opseg  $L_s$  i b) uvećani prikaz za  $L_s$  od  $200$  do  $300 \mu\text{m}$


### 6.3.2 Primena inverznog modela mehaničkih karakteristika za projektovanje RF MEMS prekidača

Kao što je opisan postupak upotrebe inverznih modela EM karakteristika, na isti način su inverzni neuronski modeli mehaničkih karakteristika (tj. modeli koji su opisani u Poglavlju 6.2.) iskorišćeni za određivanje dimenzija pri projektovanju RF MEMS prekidača u cilju prevazilaženja postupka optimizacije dimenzija prekidača za željenu vrednost napona aktucije. Time je u veoma kratkom vremenskom periodu moguće odrediti dimenzije prsta mosta prekidača- $L_f$  za zadatu dužinu osnove mosta- $L_s$  i napona aktucije- $V_{PI}$  [99]. U prvom koraku, predloženi inverzni neuronski modeli su iskorišćeni za određivanje ukupne dužine mosta prekidača- $L_t$  (koja predstavlja zbir lateralnih dimenzija  $L_t = L_s + L_f$ ) u cilju dostizanja željene vrednosti napona aktucije. Uvođenjem ukupne dužine mosta prekidača izbegnut je problem nejednoznačnosti mapiranja između dimenzija mosta i željene vrednosti napona aktucije, odnosno pojava da različitim kombinacijama dimenzija mosta prekidača odgovara ista vrednosti napona aktucije. Na samom početku, analizom grafika na Slici 6.11 određuje se da li je moguće ostvariti zadatu vrednost napona aktucije u dodeljenoj ukupnoj dužini mosta prekidača. Navedeni grafik predstavlja sublimaciju generisanih vrednosti dimenzija prekidača iz direktnih neuronskih modela (Poglavlje 4.4.5), iskazanih preko ukupne dužine prekidača  $L_t$ . Kao primer, neka je zadata vrednost napona aktucije 30 V, sa grafika možemo očitati da je navedena vrednost ostvarljiva sa ukupnom dužinom mosta prekidača u rasponu od 290  $\mu\text{m}$  do 330  $\mu\text{m}$ .




Slika 6.11 Ukupna dužina mosta prekidača u odnosu na napon aktucije u razmatranom opsegu dimenzija prekidača





a)



b)

Slika 6.12 Određivanje dimenzija  $L_s$  i  $L_f$  za zadatu ukupnu dužinu mosta  $L_t = 300 \mu\text{m}$ :

a) prikaz za celi opseg  $L_s$  i b) uveličani prikaz za  $L_s$  od 200 do 300  $\mu\text{m}$

Kada se ustanovi da je kombinacija željenih vrednosti  $L_t$  i  $V_{PI}$  fizički ostvarljiva, prelazi se na drugi korak u kojem se vrednosti  $L_s$  i  $L_f$  očitavaju sa grafika, gde su one predstavljene kao tačke preseka funkcije inverznog neuronskog modela  $L_f = f_{inv\_VNM}(L_s, V_{PI})$  i funkcije za vrednost  $L_f = L_t - L_s$ . U obe funkcije  $L_s$  treba da bude između 0  $\mu\text{m}$  i  $L_t$ . Na primer, neka je željena vrednost  $V_{PI} = 30 \text{ V}$  a  $L_t = 300 \mu\text{m}$ . Upotrebom inverznog neuronskog modela, za  $L_s$  od 0 do 300  $\mu\text{m}$  generisane se vrednosti  $L_f$  i prikazane na grafiku (puna linija na Slici 6.12 (a)). Na istom grafiku je isprekidanom linijom prikazana linearna funkcija  $L_f = L_t - L_s$ .

Slika 6.12 (b) prikazuje oblasti preseka grafika sa Slike 6.12 (a), odnosno Slika 6.12 (b) predstavlja fizički moguće vrednosti  $L_f$  (zadebljani deo linije na Slici 6.12 (a)) [99]. Očitavanjem mesto preseka linija zaključujemo da su odgovarajuće dimenzije mosta prekidača:  $L_s = 258 \mu\text{m}$  i  $L_f = 42 \mu\text{m}$ .

Na ovaj način prikazan je efikasan pristup u primeni inverznih neuronskih modela u cilju određivanja lateralnih dimenzija prekidača za zadate vrednosti napona aktuacije. Time su izbegnute složene i veoma vremenski zahtevne optimizacije i numeričke simulacije u mehaničkim simulatorima.


### **6.3.3 Primena elektro-mehaničkog neuronskog modela u analizi RF MEMS prekidača**

Prethodno razvijeni inverzni neuronski modeli za elektro-mehanički karakteristike RF MEMS prekidača (Poglavlje 6.3) iskorišćeni su za projektovanje ulaznih parametara u datom opsegu i određivanje fizičkih dimenzija mosta prekidača koje će obezbediti željene vrednosti napona aktuacije i rezonantne frekvencije. Za to je iskorišćen inverzni elektro-mehanički model razvijen za predikciju dužine prsta mosta u odnosu na prethodno zadate vrednosti dužine osnove mosta prekidača, napona aktuacije i rezonantne frekvencije, a koji je prikazan na Slici 6.6 (a) [104].


Kao kod prethodnih predloženih inverznih modela, inverzni elektro-mehanički modeli se suočavaju sa problemom nejednoznačnosti mapiranja dimenzija mosta u odnosu na napon aktuacije i rezonantnu frekvenciju. Iz tog razloga neophodno je definisati zahtev ukupne dužine mosta prekidača  $L_t$  kako bi se jednoznačno odredile lateralne dimenzije mosta. Uzimajući navedeno u obzir, upotrebom predloženih neuronskih modela moguće je generisati dimenzije  $L_s$  i  $L_f$  za željenu vrednost rezonantne frekvencije samo ukoliko je data ukupna dimenzija mosta prekidača  $L_t = L_s + L_f$ . Na samom početku analize potrebno je odrediti da li je moguće sa ukupnom dužinom mosta  $L_t = L_s + L_f$  ostvariti željene vrednosti rezonantne frekvencije i napona aktuacije. To se postiže postupcima koji su opisani u Poglavljima 6.4.1 i 6.4.2, odnosno očitavanjem mogućih ukupnih dužina mosta za vrednosti rezonantne frekvencije (Slika 6.9) i ukupnih dužina mosta za vrednosti napona aktuacije (Slika 6.11). Takođe, sa grafika na Slici 6.8 potrebno je potvrditi da su željene vrednosti rezonantne frekvencije i napona aktuacije obuhvaćene prostorom mogućih kombinacija ulaznih veličina  $f_{res} - V_{PI}$ . Kada se potvrdi da su za ukupnu dužinu mosta  $L_t$  ostvarljive željene vrednosti rezonantne frekvencije i napona aktuacije, onda se konkretne dimenzije  $L_s$  i  $L_f$  mogu odrediti očitavanjem tačaka preseka na grafiku koji predstavlja funkcije  $L_f = f_{inv\_VNM}(L_s, f_{res}, V_{PI})$  i

$L_f = L_t - L_s$ . Vrednosti funkcije  $L_f = f_{inv\_VNM}(L_s, f_{res}, V_{PI})$  su u stvari vrednosti  $L_f$  generisane predloženim inverznim elektro-mehaničkim modelom. U oba slučaja korišćene su vrednosti  $L_s$  u opsegu od 0  $\mu\text{m}$  do  $L_t$ .

Ilustracije radi, neka je željena rezonantna frekvencija 14 GHz, napon aktivacije 35 V a ukupna dužina mosta prekidača 260  $\mu\text{m}$ . Elektro-mehaničkim neuronskim modelom generisane su vrednosti  $L_f$  za  $L_s$  u opsegu od 0 do 260  $\mu\text{m}$  i prikazane su punom linijom na Slici 6.13 (a). Vrednosti  $L_f = L_t - L_s$  predstavljaju linearnu funkciju i na Slici 6.13 (a) prikazane su isprekidanom linijom.



a)



b)

Slika 6.13 Određivanje dimenzija mosta prekidača za ukupnu dužinu mosta  $L_s = 260$   $\mu\text{m}$

S obzirom da postoje dve tačke preseka, prva na oko  $L_s = 110 \mu\text{m}$  i druga na  $L_s = 200 \mu\text{m}$ . Očitavanjem sa grafika na Slici 6.9 jasno je da sa dimenzijom  $L_s$  od  $110 \mu\text{m}$  nije moguće postići željenu rezonantnu frekvenciju od 14 GHz, pa ova tačka prekida nije moguća solucija. Slika 6.13 (b) predstavlja uvećan deo grafika sa slike 6.13 (a) u opsegu oko tačke preseka koja predstavlja izvodljivu soluciju (druga tačka preseka). Tako se može preciznije odrediti da su  $L_s = 200 \mu\text{m}$  i  $L_f = 60 \mu\text{m}$  lateralne dimenzije sa kojima se postižu zahtevane vrednosti rezonantne frekvencije, napona aktivacije i ukupne dužine mosta prekidača.

## **7 HIBRIDNI PRISTUPI ZA INVERZNO MODELOVANJE RF MEMS PREKIDAČA**

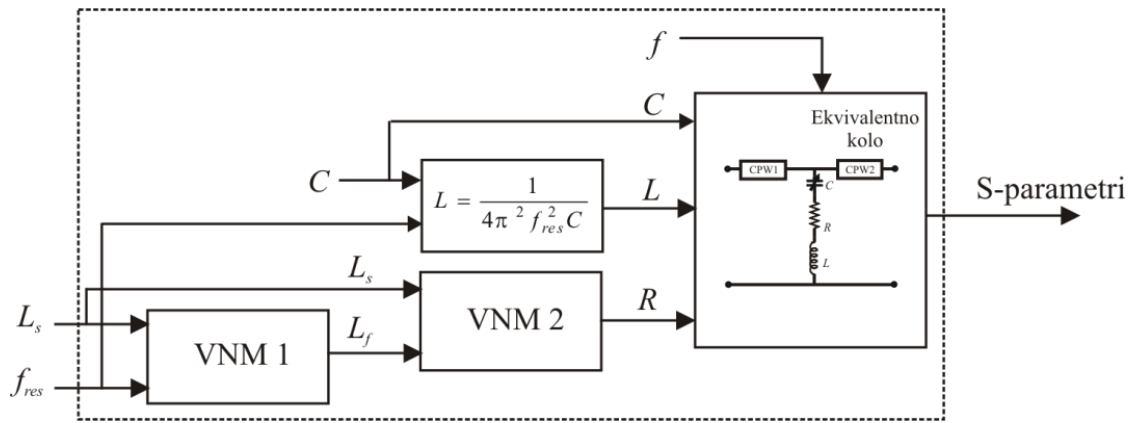
Projektovanje elektronskih kola koja sadrže RF MEMS prekidače zahteva veliki broj simulacija i/ili optimizacija karakteristika prekidača, pa se iz tog razloga na početku procesa projektovanja elektronskih kola razvijaju modeli RF MEMS prekidača koji treba da budu tačni i pouzdani. Tokom projektovanja RF MEMS prekidača vrlo važan zadatak je određivanje njegovih električnih karakteristika. Električne karakteristike direktno zavise od lateralnih dimenzija prekidača. Električne karakteristike prekidača mogu se precizno odrediti primenom *full-wave* elektromagnetskog simulatora. Simulirani modeli su kompleksne strukture pa je i proces simulacija vremenski zahtevan postupak. Iz tog razloga, opcija koja prevazilazi navedene probleme je primena modela elektronskih kola u simulatorima kola [110, 111]. Modeli koji baziraju na ekvivalentnim kolima su brže simulacione procedure u odnosu na *full-wave* simulacije. Međutim, ukoliko se analiziraju različite dimenzije i strukture mosta prekidača, potrebno je izvršiti ponavljanje procedure određivanja elemenata ekvivalentnog kola za svaku dimenziju i strukturu mosta prekidača ponaosob, što je vremenski veoma zahtevan postupak. Značajne prednosti se ostvaruju primenom veštačkih neuronskih mreža, koje ostvaruju skalabilnost elemenata ekvivalentnog kola sa dimenzijama mosta prekidača, odnosno modeluju zavisnost elemenata ekvivalentnog kola u odnosu na dimenzije mosta prekidača [101]. U cilju prevazilaženja dugotrajnih i složenih simulacionih i optimizacionih postupaka koji se sprovode u procesu modelovanja karakteristika RF MEMS prekidača, predloženo je alternativno rešenje, odnosno pristup inverznog modelovanja, koji predstavlja kombinaciju veštačkih neuronskih mreža sa elementima ekvivalentnog kola.

## 7.1 HIBRIDNI PRISTUPI ZA INVERZNO MODELOVANJE ZA ZADATU REZONANTNU FREKVENCIJU

Ovaj pristup omogućava određivanje jedne dimenzije mosta prekidača za zadatu rezonantnu frekvenciju i drugu dimenziju mosta, uz istovremeno generisanje elemenata ekvivalentnog kola prekidača. U prethodnom delu disertacije predloženi su *black-box* inverzni modeli RF MEMS prekidača, uz pomoć kojih se određuju lateralne dimenzije mosta prekidača za zadate EM i mehaničke karakteristike prekidača (Glava 6). Međutim, u ovom poglavlju predložen je prošireni pristup inverznog modelovanja zasnovan na neuronskim modelima, koji pored određivanja dimenzija prekidača određuju i elemente ekvivalentnog kola. Time se stvaraju uslovi da se model baziran na ekvivalentnom kolu kasnije koristi za simulacije kola koji sadrži razmatrani RF MEMS prekidač. Drugim rečima, to je kombinacija modelovanja sa *black-box* inverznim neuronskim modelima [91, 92, 102] i modifikacijom hibridnog modela baziranog na ekvivalentnom kolu [101]. Predloženi model nije moguće koristiti za istovremeno određivanje obe lateralne dimenzije zbog činjenice da različite kombinacije lateralnih dimenzija mosta prekidača mogu da daju istu vrednost rezonantne frekvencije. Iz tog razloga, razvijena su dva hibridna pristupa kako bi se sagledale mogućnosti zasebnog modelovanja za obe lateralne dimenzije mosta prekidača ( $L_s$  i  $L_f$ ).

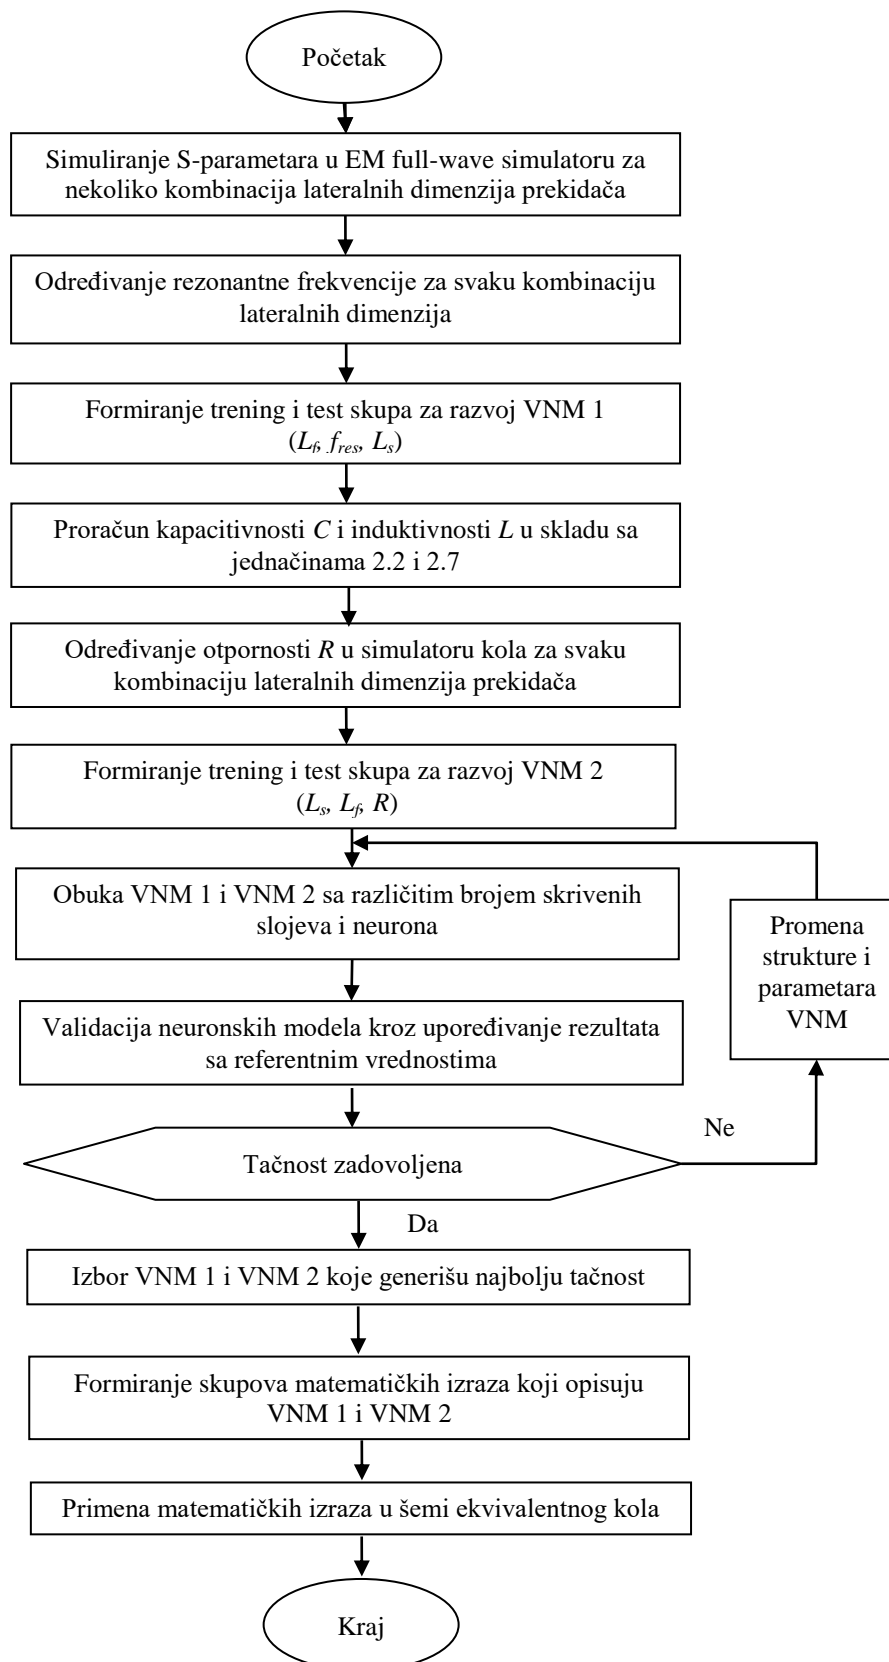
### 7.1.1 Hibridni inverzni model sa ulaznim vrednostima $f_{res}$ i $L_s$

U prvom predloženom pristupu neuronski model se koristi za određivanje dimenzije prsta mosta prekidača ( $L_f$ ) za zadate vrednosti osnove mosta prekidača ( $L_s$ ) i rezonantne frekvencije ( $f_{res}$ ) [106]. Šematski dijagram predloženog modela dat je na Slici 7.1. Zadatak prve neuronske mreže (VNM 1) je da odredi vrednosti prsta mosta prekidača za zadate vrednosti tela mosta i rezonantne frekvencije [89, 91, 102]. Druga neuronska mreža (VNM 2) modeluje odnos između otpornosti i lateralnih dimenzija prekidača. Postupak razvoja predloženog hibridnog inverznog modela prikazan je u blok dijagramu na Slici 7.2.



Slika 7.1 Predloženi hibridni inverzni model [106]

Za razliku od modela koji je opisan u Glavi 5 gde je neuronskim modelom modelovana zavisnost induktivnosti od lateralnih dimenzija prekidača, u ovom pristupu induktivnost je izračunavana matematičkom formulom, pošto je poznata vrednost rezonantne frekvencije a kapacitivnost je konstantna i ne zavisi od lateralnih dimenzija prekidača. Navedene vrednosti su izračunate upotrebom jednačina 2.2 i 2.7 iz Poglavlja 2.5.1 i direktno primenjene u ekvivalentnom kolu. Korišćene su višeslojne veštačke neuronske mreže sa jednim ulaznim, jednim izlaznim i više skrivenih slojeva. Obe neuronske mreže imaju po dva ulazna neurona i jedan izlazni neuron ( $L_f$ , odnosno  $R$ ). Obuka i validacija neuronskog modela VNM 1 vršena je sa setom uzoraka koji su dobijeni simulacijama S-parametara u *full-wave* simulatoru za svaku kombinaciju dimenzija mosta prekidača, a šta je detaljno opisano u Poglavlju 6.1. Vrednosti otpornosti korišćene za obuku VNM 2 određene su procesom optimizacije u simulatoru kola za prethodno izračunate vrednosti kapacitivnosti i induktivnosti. Cilj optimizacije je usklađivanje simulirane rezonantne frekvencije (tj. svih S-parametara) sa rezonantnom frekvencijom koja je dobijena simulacijama u *full-wave* simulatoru za zadate kombinacije dimenzija mosta prekidača.



Slika 7.2 Blok dijagram procedure razvoja hibridnog inverznog modela



Korišćenje razvijenog inverznog modela ne zahteva dodatne simulacije u *full-wave* simulatoru niti dodatne optimizacije u simulatoru kola. Za željene vrednosti rezonantne frekvencije i date dimenzije osnove mosta prekidača, moguće je simultano odrediti dužinu prsta mosta prekidača, kao i odgovarajuće elemente ekvivalentnog kola, a zatim simulirati S-parametre u željenom frekvencijskom opsegu. Pošto se sve operacije vrše u simulatoru kola, celi proces se obavlja u jednoj sekundi, što je značajno brže nego što su procesi optimizacije u *full-wave* simulatoru prilikom određivanja dimenzija prekidača i procesa optimizacije u simulatoru kola za određivanje otpornosti prekidača.

Razvoj predloženog modela vršen je po sledećem postupku. Inverzni neuronski modeli razvijeni su za dimenzije mosta prekidača u sledećim opsezima: dimenzija osnove mosta  $L_s$  u opsegu od 50  $\mu\text{m}$  do 500  $\mu\text{m}$ , dok je dimenzija prsta mosta  $L_f$  u opsegu od 0 do 100  $\mu\text{m}$ . U cilju pripreme podataka za razvoj modela, određeni su elementi ekvivalentnog kola  $R$ ,  $L$  i  $C$  za nekoliko različitih kombinacija lateralnih dimenzija mosta prekidača  $L_s$  i  $L_f$ . Relativna dielektrična konstanta silicijuma je 3.9 i dimenzije koje određuju vrednost kapacitivnosti u stanju kada je prekidač u statusu kratkog spoja su  $A=13000 \mu\text{m}^2$  i  $t_d = 0.1 \mu\text{m}$ . Dalje, upotrebom jednačine 2.2 iz Poglavlja 2.5.1, izračunata je vrednost kapacitivnosti i ona iznosi 4.48907 pF. Za svaku korišćenu kombinaciju dimenzija  $L_s$  i  $L_f$ , izračunate su vrednosti S-parametara u *full-wave* simulatoru u softveru *Advanced Design System (ADS) Momentum software* [112] i za svaku kombinaciju je određena rezonantna frekvencija kao minimalna vrednost modula parametra  $S_{21}$ . Dalje, kombinacije lateralnih dimenzija i rezonantnih frekvencija koje su dobijene u *full-wave* simulatoru korišćene su za obuku VNM 1, što je opisano u Poglavlju 6.1, a korišćene vrednosti prikazane su u Tabeli 6.1.

U daljem postupku, rezonantna frekvencija i kapacitivnost su korišćene za određivanje induktivnosti za svaku kombinaciju dimenzija  $L_s$  i  $L_f$ . Induktivnost je izračunata preko jednačine 2.7 iz Poglavlja 2.5.1, a dobijeni rezultati su prikazani u Tabeli 7.2. Zatim je razvijen neuronski model VNM 2 za određivanje otpornosti za zadate lateralne dimenzije mosta prekidača. Ciljne vrednosti otpornosti izračunate su u procesu optimizacije otpornosti prekidača za svaku razmatranu kombinaciju dimenzija  $L_s$  i  $L_f$ . Između većeg broja treniranih veštačkih neuronskih mreža sa različitim brojem skrivenih neurona, najbolji rezultati su ostvareni sa neuronskim modelom strukture 2-4-8-1. U Tabeli 7.1 prikazane su vrednosti otpornosti koje su ostvarene sa ANN 2 za osam test kombinacija, a u Tabeli 7.2 prikazane su vrednosti elementa ekvivalentnog kola za iste test kombinacije. Navedene test kombinacije nisu korišćene u procesu obuke mreže.


Tabela 7.1 Rezultati određivanja otpornosti  $R$  neuronskim modelom VNM 2

$L_s$ ( $\mu\text{m}$ )	$L_f$ (VNM 1) ( $\mu\text{m}$ )	$R$ (VNM 2) ( $\text{m}\Omega$ )
75	24.9	638.05
75	65.4	739.45
75	85.3	763.26
100	73.6	764.92
200	86.8	857.68
350	23.4	908.49
350	62.2	946.07
400	87.4	977.75


Tabela 7.2 Vrednosti elemenata ekvivalentnog kola

$L_s$ ( $\mu\text{m}$ )	$L_f$ (VNM 1) ( $\mu\text{m}$ )	$C$ (pF)	$f_{res}$ (GHz)	$L$ (pH)	$R$ (VNM 2) ( $\text{m}\Omega$ )
75	24.9	4.48695	22.78	10.879	638.05
75	65.4	4.48695	19.17	15.363	739.45
75	85.3	4.48695	17.92	17.581	763.26
100	73.6	4.48695	17.5	18.435	764.92
200	86.8	4.48695	13.13	32.748	857.68
350	23.4	4.48695	11.67	41.455	908.49
350	62.2	4.48695	10.83	48.135	946.07
400	87.4	4.48695	10	56.457	977.75

Validacija predloženog hibridnog inverznog modela izvršena je tako što su za test kombinacije dimenzija mosta prekidača, izračunate vrednosti  $C$ ,  $L$  i  $R$  pridružene odgovarajućim elementima ekvivalentnog kola i iskorišćene za simulaciju S-parametara.




a)




b)

Slika 7.3 Vrednosti parametara  $S_{11}$  (a) i  $S_{21}$  (b) za dimenzije  $L_s = 100 \mu\text{m}$  i  $L_f = 75 \mu\text{m}$  (RLC model – crvena linija, full-wave simulator - plava linija)

Poređenje S-parametara određenih simulacijama u ekvivalentnom kolu sa S-parametrima određenim u full-wave simulatoru pokazuju veoma dobro poklapanje. Kao ilustracija ostvarenih rezultata, na Slikama 7.3 i 7.4 prikazane su vrednosti unutrašnjeg slabljenja ( $|S_{21}|$  u dB) i povratnog slabljenja ( $|S_{11}|$  u dB) za dva prekidača sa različitim lateralnim dimenzijama mosta prekidača. Prvi prekidač ima dimenzije mosta  $L_s = 100 \mu\text{m}$  i  $L_f = 75 \mu\text{m}$ , dok su dimenzije mosta drugog prekidača  $L_s = 350 \mu\text{m}$  i  $L_f = 25 \mu\text{m}$ .



a)



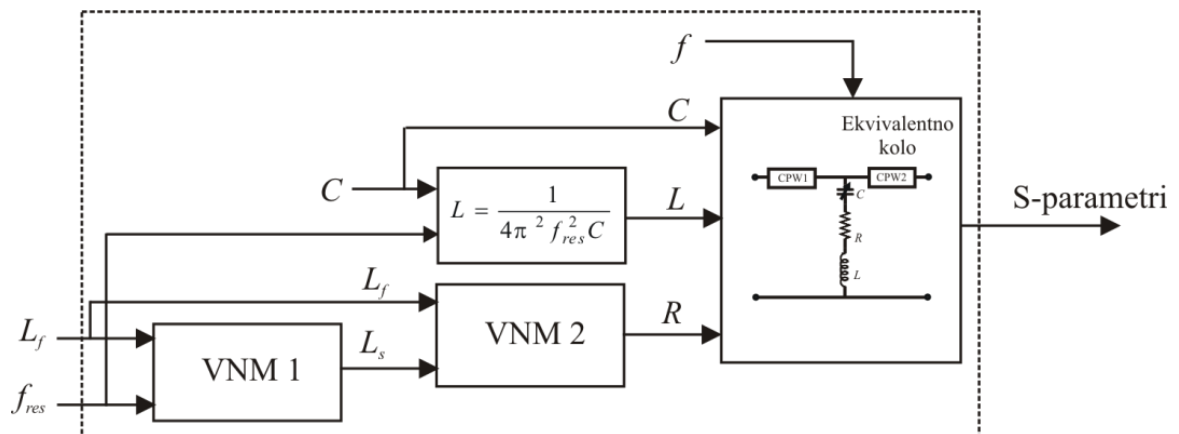
b)

Slika 7.4 Vrednosti parametara  $S_{11}$  (a) i  $S_{21}$  (b) za dimenzije  $L_s = 350 \mu\text{m}$  i  $L_f = 25 \mu\text{m}$  (RLC model - crvena linija, full-wave simulator - plava linija)

Kao što se sa slika može zaključiti, u oba slučaja vrednosti S-parametara iz ekvivalentnog kola su skoro identični sa referentnim vrednostima S-parametara koji su dobijeni simulacijama u *full-wave* simulatoru. Navedeno potvrđuje tačnost predloženog hibridnog modela. Za prikaz tačnosti predloženog modela namenski je izabran prekidač sa dimenzijama mosta  $L_s = 350 \mu\text{m}$  i  $L_f = 25 \mu\text{m}$  jer je navedena kombinacija lateralnih dimenzija mosta na izlazu VNM 1 generisala najveću devijaciju modelovanih vrednosti u odnosu na referentne vrednosti. Čak i u takvom slučaju, odgovor ekvivalentnog kola je skoro identičan sa ciljnim vrednostima dobijenim u *full-wave* simulacijama.

### 7.1.2 Hibridni inverzni model sa ulaznim vrednostima $f_{res}$ i $L_s$

Kao u prethodnom poglavlju, nastavljen je razvoj hibridnih inverznih modela koji kombinuju upotrebu inverznih neuronskih modela sa parametrima hibridnog modela baziranog na ekvivalentnom kolu u cilju razvoja procedure za određivanje lateralnih dimenzija prekidača i elemenata kola za zadate vrednosti rezonantne frekvencije. Postupak formiranja modela je identičan kao i u slučaju predloženog hibridnog pristupa u prethodnom poglavlju, sa promenom lateralne dimenzije mosta prekidača koja se modeluje u VNM 1. Odnosno, u ovom slučaju polazne zadate vrednosti su rezonantna frekvencija ( $f_{res}$ ) i dimenzija prsta mosta prekidača ( $L_f$ ) [105]. Predloženi hibridni model prikazan je na Slici 7.5. Postupak razvoja predloženog hibridnog inverznog modela isti je kao i postupak razvoja modela iz prethodnog poglavlja (Poglavljje 7.1.1) i prikazan je u blok dijagramu na Slici 7.2. Neuronskim modelom VNM 1 modeluje se dimenzija osnove mosta  $L_s$  za zadate vrednosti rezonantne frekvencije i dimenzije prsta mosta prekidača  $L_f$ . Takođe, isti je postupak određivanja vrednosti kapacitivnosti i induktivnosti (primena jednačina 2.2 i 2.7).



Slika 7.5 Predloženi pristup hibridnog modela [105]

Postupak razvoja neuronskog modela VNM 1 za generisanje  $L_s$  detaljno je opisan u Poglavlju 6.1 [23, 89]. Veštačka neuronka mreža koja je u procesu obuke i testiranja generisala najveću tačnost je mreža 2-15-15-1, tj. mreža sa dva skrivena sloja i sa po 15 neurona u svakom skrivenom sloju. Neuronski model je obučavan trening skupom koji je sačinjen od vrednosti rezonantnih frekvencija koje su simulirane u *full-wave* simulatoru za različite kombinacije lateralnih dimenzija mosta prekidača (postupak je opisan u Poglavlju 6.1 a korišćene vrednosti prikazane su u Tabeli 6.2).

Da bi se obezbedile kombinacije ulazno-izlaznih parametara za obuku VNM 2, prethodno je izračunati elemente ekvivalentnog kola  $R$ ,  $L$  i  $C$  za nekoliko kombinacija lateralnih dimenzija prekidača. U prvom koraku, simulirani su S-parametri za svaku kombinaciju dimenzija  $L_s$  i  $L_f$  u *full-wave* simulatoru u *Advanced Design System (ADS) Momentum* programskom paketu. Za svaku kombinaciju dimenzija, rezonantna frekvencija je određena na osnovu minimalne vrednosti  $S_{21}$ . Kapacitivnost  $C$  i induktivnost  $L$  je izračunata kao i u predloženom pristupu u prethodnom poglavlju, tj. upotrebom jednačina 2.2 i 2.7. Poslednji korak je optimizacija vrednosti otpornosti u ADS simulatoru kola za svaku kombinaciju lateralnih dimenzija. Cilj optimizacije je postizanje dobrog poklapanja simuliranih S-parametara sa S-parametrima dobijenim u *full-wave* simulatoru. Takvi podaci su kasnije iskorišćeni za obuku i testiranje neuronskog modela VNM 2. Nakon obuke i testiranja većeg broja neuronskih modela sa različitim brojem skrivenih neurona, izabran je neuronski model koji je u test rezultatima generisao najbolju tačnost. Kao finalni model izabran je neuronski model sa dva skrivena sloja, u prvom sloju sa četiri neurona a u drugom skrivenom sloju sa osam neurona (2-4-8-1). Navedeni neuronski model je testiran sa osam test kombinacija i dobijeni rezultati prikazani su u Tabeli 7.3. Tim korakom obezbeđena su sva tri elementa ekvivalentnog kola ( $R$ ,  $L$  i  $C$ ), a koji su prikazani u Tabeli 7.4.


Tabela 7.3 Rezultati određivanja otpornosti  $R$  neuronskim modelom VNM 2

$L_f$ ( $\mu\text{m}$ )	$L_s$ (VNM 1) ( $\mu\text{m}$ )	$R$ (VNM 2) ( $\text{m}\Omega$ )
25	74.9	733.19
65	75.5	748.48
85	75.3	758.08
75	97.9	773.49
85	202.7	845.29
25	347.8	900.9
65	348.0	915.65
85	403.4	940.2


Validacija predloženog hibridnog pristupa sa inverznim modelovanjem izvršena je na sledeći način. Prvo, dobijene vrednosti  $C$ ,  $L$  i  $R$  za kombinacije dimenzija mosta iz test skupa pridružene su odgovarajućim elementima ekvivalentnog kola, a zatim su simulirani S-parametri. U odnosu na dobijene rezultate, može se zaključiti da S-parametri RF MEMS prekidača koji su simulirani u ekvivalentnom kolu imaju vrlo dobro poklapanje sa S-parametrima koji su određeni u ADS momentum simulacijama.

Tabela 7.4 Elementi ekvivalentnog kola

$L_f$ ( $\mu\text{m}$ )	$L_s$ (VNM 1) ( $\mu\text{m}$ )	$f_{res}$ (GHz)	$C$ (pF)	$L$ (pH)	$R$ (VNM 2) ( $\text{m}\Omega$ )
25	74.9	22.78	4.48695	10.879	733.19
65	75.5	19.17	4.48695	15.363	748.48
85	75.3	17.92	4.48695	17.581	758.08
75	97.9	17.5	4.48695	18.435	773.49
85	202.7	13.13	4.48695	32.748	845.29
25	347.8	11.67	4.48695	41.455	900.9
65	348.0	10.83	4.48695	48.135	915.65
85	403.4	10	4.48695	56.457	940.2



a)





b)

Slika 7.6 Vrednosti parametara  $S_{11}$  (a) i  $S_{21}$  (b) za dimenzije  $L_f = 75 \mu\text{m}$  i  $L_s = 100 \mu\text{m}$  (RLC model - crvena linija, full-wave simulator - plava linija)

Navedeno je predstavljeno grafičkim prikazima na Slikama 7.6 i 7.7, gde je unutrašnje slabljenje ( $|S_{21}|$  u dB) i povratno slabljenje ( $|S_{11}|$  u dB) prikazano za dva uređaja sa različitim

lateralnim dimenzijama. Prvi prekidač je sa dimenzijama mosta  $L_f = 75 \mu\text{m}$  i  $L_s = 100 \mu\text{m}$ , dok je drugi sa dimenzijama mosta  $L_f = 25 \mu\text{m}$  i  $L_s = 350 \mu\text{m}$ . U oba slučaja odzivi ekvivalentnog kola su skoro identični sa referentnim vrednostima koje su dobijene u *full-wave* simulatoru, čime se potvrđuje veoma dobra tačnost razvijenih neuronskih modela i predloženog pristupa. Bitno je napomenuti da je u prvom primeru ostvareno veoma dobro poklapanje S-parametara, iako je reč o prekidaču sa kombinacijom lateralnih dimenzija koji je u VNM 1 generisao najveću grešku.



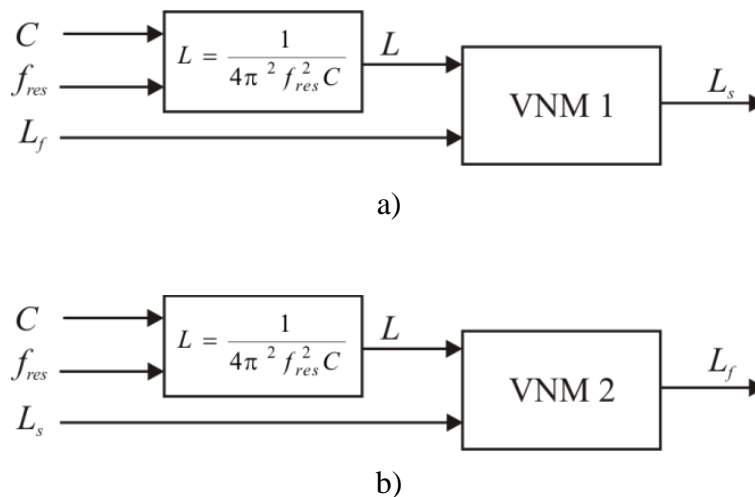
Slika 7.7 Vrednosti parametara  $S_{11}$  (a) i  $S_{21}$  (b) za dimenzije  $L_f = 25 \mu\text{m}$  i  $L_s = 350 \mu\text{m}$   
(RLC model - crvena linija, full-wave simulator - plava linija)



## 7.2 HIBRIDNI PRISTUP ZA INVERZNO MODELOVANJE RF MEMS PREKIDAČA SA ZADATOM VREDNOŠĆU JEDNOG ELEMENTA EKVIVALENTNOG KOLA

Efikasnost primene inverznih neuronskih modela u procesu projektovanja RF MEMS prekidača iskorišćena je i u oblasti kombinovanja zavisnosti lateralnih dimenzija u odnosu na elemente ekvivalentnog kola, a konkretno u ovom slučaju, u odnosu na induktivnost RF MEMS kapacitivnog prekidača. S tim u vezi, predložen je novi pristup inverznog modelovanja RF MEMS prekidača gde su prednosti primene veštačkih neuronskih mreža iskorišćene za određivanje jedne lateralne dimenzije mosta prekidača za date vrednosti druge lateralne dimenzije mosta i induktivnosti prekidača [107].

U prethodnim poglavljima već je napominjano da dimenzije prekidača određuju lateralne dimenzije mosta prekidača, odnosno dužine osnove mosta ( $L_s$ ) i prsta mosta prekidača ( $L_f$ ). Ukoliko se za zadatu rezonantnu frekvenciju izračuna induktivnost prekidača upotrebom jednačine 2.7 (Poglavlje 2.5.1), onda se lateralne dimenzije mosta prekidača mogu generisati preko neuronskih modela koji su prikazani na Slici 7.8.



Slika 7.8 Inverzni neuronski modeli za a)  $L_s$  i b)  $L_f$

Potrebno je naglasiti da induktivnost prekidača nije jednoznačna za različite vrednosti dimenzija prekidača, tj. ista vrednost induktivnosti odgovara za nekoliko različitih vrednosti dimenzija  $L_s$  i  $L_f$ . Uzimajući navedeno u obzir, sa jednom VNM nije moguće istovremeno odrediti obe lateralne dimenzije. Iz tog razloga predložena su dva neuronska modela koja

zasebno određuju dimenzije  $L_s$  i  $L_f$ . Oba predložena neuronska modela za jednu fiksiranu lateralnu dimenziju generišu vrednost druge lateralne dimenzije mosta prekidača. Kao što je prikazano na Slici 7.8, prvi neuronski model određuje dimenziju osnove mosta za zadanu dimenziju prsta mosta, dok drugi model određuje dimenziju prsta mosta za zadanu dimenziju osnove mosta prekidača.

Za obuku predloženih neuronskih modela potrebno je odrediti induktivnost ekvivalentnog kola za određen broj različitih kombinacija lateralnih dimenzija mosta prekidača. To je postignuto tako što su u *full-wave* simulatoru izračunate vrednosti S-parametara za različite kombinacije lateralnih dimenzija mosta prekidača. Rezonantna frekvencija je određena za svaku simuliranu kombinaciju lateralnih dimenzija na osnovu minimalne vrednosti frekvencije u modulu parametara  $S_{21}$ . Zatim je primenom jednačine 2.7 izračunata induktivnost ekvivalentnog kola za svaku kombinaciju lateralnih dimenzija ponaosob. Da bi se kompletirao model ekvivalentnog kola, otpornost je određena optimizacijom u simulatoru kola. Međutim, za ovu svrhu moguće je kao dodatni model koristi neuronski model za određivanje otpornosti u odnosu na lateralne dimenzije mosta prekidača, a što je opisano u Poglavlju 7.1 [105, 106]. Obuka neuronskih modela vršena je sa različitim trening algoritmima i tom prilikom je ustanovljeno da su sa raspoloživim podacima najbolji rezultati učenja na trening skupu (tačnost modelovanja sa trening vrednostima) i u smislu generalizacije (tačnost modelovanja za test vrednosti) ostvareni sa algoritmom Bajesove regularizacije. Za oba predložena modela, formiran je veći broj veštačkih neuronskih mreža sa različitim brojem skrivenih neurona. Zatim je njihova tačnost upoređivana i VNM sa najvećom tačnošću je izabrana kao konačni model. Tačnost predloženih modela je ocenjivana u skladu sa parametrima apsolutnih i relativnih grešaka generisanih vrednosti.

Obuka VNM 1 vršena je sa trening skupom od 10 kombinacija jedne lateralne dimenzije i vrednosti induktivnosti, što je i prikazano u predstojećim tabelama. Za neuronski model VNM 1 izabran je model sa dva skrivena sloja sa po 25 neurona u svakom skrivenom sloju (2-25-25-1). U Tabeli 7.5 prikazani su rezultati testiranja predloženog neuronskog modela na trening skupu, a u Tabeli 7.6 rezultati testiranja na test skupu. U oba slučaja apsolutna greška je za sve testirane kombinacije manja od 3  $\mu\text{m}$ , a relativna greška je manja od 1%. Navedene greške su prihvatljive jer su u okviru granica fabričke tolerancije.

Tabela 7.5 Rezultati testiranja VNM 1 na trening skupu za određivanje dimenzija  $L_s$

$L_f$ [ $\mu\text{m}$ ]	$L$ [pH]	$L_s$ (target) [ $\mu\text{m}$ ]	$L_s$ (VNM) [ $\mu\text{m}$ ]	Abs. greška [ $\mu\text{m}$ ]	Rel. greška [%]
50	11.35	50	49.82	0.18	0.36
100	17.04	50	51.02	1.02	2.04
50	27.21	200	198.93	1.07	0.54
100	33.38	200	197.75	2.25	1.13
50	39.85	300	302.55	2.55	0.85
100	46.63	300	300.05	0.05	0.02
50	52.17	400	399.43	0.57	0.14
100	59.97	400	402.90	2.90	0.73
50	65.24	500	501.71	1.71	0.34
100	71.23	500	497.91	2.09	0.42

Tabela 7.6 Rezultati testiranja VNM 1 na test skupu za određivanje dimenzija  $L_s$

$L_f$ [ $\mu\text{m}$ ]	$L$ [pH]	$L_s$ (target) [ $\mu\text{m}$ ]	$L_s$ (VNM) [ $\mu\text{m}$ ]	Abs. greška [ $\mu\text{m}$ ]	Rel. greška [%]
25	30.06	250	252.68	2.68	1.07
75	36.69	250	251.05	1.05	0.42
25	41.93	350	348.05	1.95	0.56
75	49.28	350	347.11	2.89	0.83

Obuka VNM 2 vršena je sa istim podacima koji su korišćeni za obuku VNM 1. Rezultati testiranja VNM 2 sa trening i test skupom prikazani su u Tabelama 7.7 i 7.8, respektivno.

Tabela 7.7 Rezultati testiranja VNM 2 na trening skupu za određivanje dimenzija  $L_f$

$L_s$ [ $\mu\text{m}$ ]	$L$ [pH]	$L_f$ (target) [ $\mu\text{m}$ ]	$L_f$ (VNM) [ $\mu\text{m}$ ]	Abs. greška [ $\mu\text{m}$ ]	Rel. greška [%]
50	11.35	50	49.96	0.04	0.08
50	17.04	100	100.06	0.06	0.06
200	27.21	50	50.29	0.29	0.58
200	33.38	100	99.39	0.39	0.39
300	39.85	50	50.25	0.25	0.50
300	46.63	100	100.76	0.76	0.76
400	52.17	50	48.76	1.24	2.48
400	59.97	100	100.16	0.16	0.16
500	65.24	50	51.42	1.42	2.84
500	71.23	100	99.05	0.95	0.95

Tabela 7.8 Rezultati testiranja VNM 2 na test skupu za određivanje dimenzija  $L_f$

$L_s$ [ $\mu\text{m}$ ]	$L$ [pH]	$L_f$ (target) [ $\mu\text{m}$ ]	$L_f$ (VNM) [ $\mu\text{m}$ ]	Abs. greška [ $\mu\text{m}$ ]	Rel. greška [%]
250	30.06	25	23.93	1.07	4.28
250	36.69	75	74.31	0.69	0.92
350	41.93	25	22.72	2.28	9.12
350	49.28	75	73.41	1.59	2.13

Neuronski model koji je generisao najveću tačnost sastoji se od dva skrivena sloja sa po 50 neurona u svakom skrivenom sloju (2-50-50-1). Kao i slučaju prethodnog neuronskog modela (VNM 1), apsolutna greška prilikom testiranja sa trening i test skupom je u okviru granične vrednosti od 3  $\mu\text{m}$ . Relativna greška je u većini slučajeva manja od 1%.

Efikasnost predloženih inverznih neuronskih modela može se ilustrovati i poređenjem sa inverznim neuronskim modelima za modelovanje lateralnih dimenzija u zavisnosti od rezonantne frekvencije (Poglavlje 6.2). Da bi se ostvarila zadovoljavajuća tačnost navedenog inverznog modela bilo je neophodno povećati trening skup do broja od 814 različitih kombinacija (kombinacije koje su generisane direktnim neuronskim modelima, tj. modelima koji su trenirani da određuju rezonantnu frekvenciju za zadate lateralne dimenzije mosta prekidača). Međutim, takav prošireni trening skup nije potreban da bi se obezbedila zadovoljavajuća tačnost inverznih neuronskih modela (apsolutna greška manja od 3  $\mu\text{m}$ ) koji modeluju lateralnu dimenziju u odnosu na induktivnost prekidača. Zadovoljavajuća tačnost takvih modela je postignuta bez dodatnih simulacija u cilju povećanja trening skupa, odnosno zadata tačnost predloženih inverznih modela je postignuta sa trening skupom od samo 10 kombinacija ulazno-izlaznih vrednosti. Na osnovu rezultata testiranja na trening i test skupovima može se zaključiti da razlika između dobijenih i ciljnih vrednosti je manja od devijacija od normalnih vrednosti koje mogu nastupiti u procesu fabrikacije prekidača.

## 8 ZAKLJUČAK

RF MEMS prekidači su veoma važne komponente u savremenim mikrotalasnim komunikacionim sistemima. Primena RF MEMS prekidača u mikrotalasnim sistemima je u konstantnom porastu, što neminovno aktuelizuje istraživački rad u oblasti njihovog projektovanja i praktične primene, a naročito u oblasti Internet inteligentnih uređaja (*Internet of Things-IoT* i *Internet of Everything-IoE*) i mobilnih sistema novih generacija. U procesu projektovanja neophodno je poznavati EM i mehaničke karakteristike RF MEMS prekidača, pre svega, parametre rasejanja, rezonantnu frekvenciju i napon aktivacije. Određivanje navedenih parametara je dosta složen i vremenski zahtevan proces. Naime, pojedinačni RF MEMS prekidači se standardno modeluju u komercijalnim elektromagnetskim *full-wave* i mehaničkim simulatorima. Iako modeli u okviru ovih simulatora obezbeđuju zadovoljavajuću tačnost, obično su ograničeni na jednu analizu za određenu strukturu, tako da vreme izračunavanja i zauzeće računarske memorije postaju veoma veliki kada je potrebno izvršiti određene optimizacije ili ponovljene simulacije razmatrane strukture. Takođe, kada je nekoliko prekidača uključeno u veće kolo, elektromagnetska analiza cele strukture postaje vremenski veoma zahtevna. Određivanje električnih karakteristika RF MEMS prekidača često se vrši modelima baziranim na ekvivalentnom kolu u simulatoru elektronskih kola, što je vremenski manje zahtevna procedura od *full-wave* simulacija. Međutim i takav pristup je složen postupak, jer u slučaju kada se razmatra veći broj komponenti čije se dimenzije razlikuju, potrebno je izvršiti veliki broj optimizacija, tj. postupak određivanja elemenata ekvivalentnog kola se ponavlja za svaku kombinaciju vrednosti dimenzija.

Kod ovakvih pristupa modelovanja RF MEMS prekidača često izostaju direktne relacije između geometrijskih parametara prekidača i njegovih elektromagnetskih/mehaničkih karakteristika, koje bi bile upotrebljene pri optimizaciji karakteristika prekidača ili kola koja ih sadrže. Ove relacije mogu biti efikasno uspostavljene pomoću veštačkih neuronskih mreža.

Veštačke neuronske mreže su nelinearne strukture napravljene po ugledu na prirodni nervni sistem. Osnovna karakteristika veštačkih neuronskih mreža je sposobnost učenja zavisnosti između dva skupa veličina. Proces učenja mreže predstavlja nadgledani proces u toku koga se optimizuju vrednosti parametara neuronske mreže tako da signal na izlazu mreže bude što bliži željenoj vrednosti za zadate ulaze u mrežu. Slojevite veštačke neuronske mreže su posebno pogodne za primene kod problema koji nisu u potpunosti definisani, odnosno kod problema kod kojih ne postoje adekvatni matematički/fizički modeli. Posebno treba istaći još jednu veoma značajnu karakteristiku veštačkih neuronskih mreža, a to je sposobnost generalizacije obučene mreže, tj. sposobnost da da korektan odziv i za vrednosti ulaznih veličina koje joj nisu predstavljene tokom učenja.

Kao što je prikazano u doktorskoj disertaciji, primenom veštačkih neuronskih mreža moguće je razviti modele električnih i mehaničkih karakteristika RF MEMS prekidača u zavisnosti od geometrijskih parametara prekidača. Pri tome, primenjena su dva najčešće korišćena tipa slojevitih veštačkih neuronskih mreža, višeslojna perceptronska mreža (*Multi-Layer Perceptron-MLP*) i neuronska mreža sa radijalnom funkcijom (*Radial Base Function-RBF*). Ovi modeli se karakterišu velikom tačnošću, veoma su efikasni u smislu brzine generisanja odziva i predstavljaju alternativu kompleksnim i vremenski zahtevnim EM i mehaničkim simulacijama. Naime, dobijanje odziva neuronskih modela je praktično trenutno jer se bazira na izvršavanju elementarnih matematičkih operacija i matematičkih funkcija, kao što je eksponencijalna funkcija. Prednost neuronskih modela u odnosu na simulacije u standardnim EM/mehaničkim simulatorima je naročito izražena u procesu optimizacije karakteristika RF MEMS prekidača, kada je potrebno izvršiti veći broj ponovljenih simulacija. Takođe, imajući u vidu da tačnost neuronskih modela ostaje na nivou tačnosti kompleksnih modela, neuronski modeli imaju prednost i nad pojednostavljenim modelima, koji zbog uvedenih aproksimacija često važe samo u pojedinim oblastima rada ili su nedovoljno tačni.

Osnovni model baziran na veštačkim neuronskim mrežama predstavljen u disertaciji je model koji se sastoji od jedne ili više višeslojnih neuronskih mreža kojima se direktno modeluje zavisnost između dva skupa veličina. Svi rezultati prikazani u disertaciji odnose se na modelovanje kapacitivnih i omskih RF MEMS prekidača realizovanih u koplanarnoj tehnologiji primenom veštačkih neuronskih mreža. Razmatrani geometrijski parametri su lateralne dimenzije mosta prekidača, tj. dužina osnove mosta i dužina prstiju mosta.

Pre svega, razvijeni su sledeći modeli EM karakteristika kapacitivnih RF MEMS prekidača: modeli parametara rasejanja (S-parametri) i modeli rezonantne frekvencije u

zavisnosti od geometrijskih parametara prekidača [23, 89]. Za određivanje S-parametara prekidača, na ulaz mreže dovode se vrednosti geometrijskih parametara mosta i frekvencije prekidača, dok su za određivanje rezonantne frekvencije, na ulazu mreže dovode vrednosti parametara mosta prekidača. Za obučavanje mreža korišćeni su podaci o S-parametrima i rezonantnoj frekvenciji dobijenih pomoću *full-wave* numeričkih simulacija karakteristika prekidača u softverskom paketu *Advanced Design System - ADS (ADS Momentum)*. Razvijeni modeli važe u širem opsegu vrednosti razmatranih geometrijskih parametara mosta prekidača. Vrednosti S-parametara i rezonantne frekvencije mogu se veoma brzo generisati jednostavnim određivanjem odziva neuronskih mreža za proizvoljne vrednosti ulaznih parametara, bez potrebe za dodatnim promenama u strukturi modela ili EM simulacijama.

Dalje, razvijen je model za određivanje mehaničkih karakteristika kapacitivnih RF MEMS prekidača u zavisnosti od geometrijskih parametara prekidača [91, 92]. Model je razvijen korišćenjem podataka dobijenih određenim brojem numeričkih simulacija karakteristika prekidača u mehaničkom FEM (*Finite Element Method*) simulatoru *COMSOL Multiphysics*. Razvijeni neuronski model trenutno određuje napon aktivacije RF MEMS prekidača na osnovu zadatih vrednosti razmatranih geometrijskih parametara prekidača sa tačnošću približno jednakoj tačnosti mehaničkog simulatora.

U cilju validacije predloženog postupka, svi rezultati dobijeni neuronskim modelima EM/mehaničkih karakteristika upoređivani su sa odgovarajućim rezultatima iz *full-wave*, odnosno, mehaničkih simulatora, kao i sa odgovarajućim raspoloživim merenim karakteristikama realizovanih komponenti. Veoma dobro poklapanje postignutih rezultata potvrđuje efikasnost predloženih neuronskih modela RF MEMS prekidača.

Sposobnost razvijениh modela za određivanje EM i mehaničkih karakteristika RF MEMS prekidača da trenutno generišu odziv, iskorišćena je za brzu i efikasnu analizu karakteristika prekidača sa promenama razmatranih dimenzija. Kroz analizu osetljivosti karakteristika RF MEMS prekidača sagledano je ponašanje prekidača, tj. promena rezonantne frekvencije i napona aktivacije sa promenama dimenzija mosta prekidača, pre svega uslovljenim odstupanjima dimenzija pri fabrikaciji [93, 94, 96, 97]. Analizom dobijenih rezultata, zaključeno je da osetljivost promene rezonantne frekvencije opada sa povećanjem dimenzija mosta prekidača. Iako su u procesu izrade prekidača, dužine osnove mosta veće od dužine prstiju mosta, promene dužine osnove mosta značajnije utiču na promenu rezonantne frekvencije. Takođe, zaključak je da promene vrednosti razmatranih dimenzija mosta u granicama fabričkih tolerancija, ne utiču značajno na promene rezonantne frekvencije prekidača, kao ni na promene napona aktivacije. Sledeća primenljivost razvijениh neuronskih

modela predstavljena je kroz postupak brzog i efikasnog projektovanja prekidača u skladu sa definisanim zahtevima, odnosno određivanje lateralnih dimenzija prekidača za zadate vrednosti rezonantne frekvencije, napona aktucije i ukupne dužine mosta prekidača [98, 99].

U cilju sagledavanja tačnosti neuronskih modela koji baziraju na različitim vrstama veštačkih neuronskih mreža, izvršena je uporedna analiza efikasnosti i tačnosti modela zasnovanih na višeslojnoj perceptronskoj mreži (MLP) i neuronskoj mreži sa radijalnom funkcijom (RBF) [100]. Dobijeni rezultati ukazuju da oba predložena modela generišu rezultate koji su veoma blizu referentnim vrednostima (vrednosti dobijene simulacijama u mehaničkom simulatoru), te da su veoma podesni za analizu i optimizaciju karakteristika RF MEMS prekidača.

S obzirom da se u praksi često koriste modeli bazirani na ekvivalentnom kolu u simulatoru elektronskih kola, u disertaciji je predložena upotreba hibridnih modela RF MEMS prekidača. Ovakvi modeli kombinuju neuronske modele i modele baziranih na ekvivalentnom kolu, gde se neuronski modeli koriste za određivanje vrednosti elemenata ekvivalentnog kola. Efikasnost ovakvog pristupa modelovanja karakteristika RF MEMS prekidača potvrđena je na primeru modelovanja sa različitim dimenzijama mosta prekidača [101].

Zatim, predložen je pristup inverznog modelovanja prekidača baziran na neuronskim modelima koji ne podrazumeva optimizacione postupke. Naime, veštačkim neuronskim mrežama modelovana je jedna lateralna dimenzija mosta prekidača na osnovu druge dimenzije i rezonantne frekvencije (ili napona aktucije) [102]. Postupak je ograničen na zasebno modelovanje jedne lateralne dimenzije jer inverzne funkcije zavisnosti rezonantne frekvencije i napona aktucije od lateralnih dimenzija nisu jednoznačne. Na ovaj način razvijeni su inverzni neuronski modeli. U cilju smanjenja vremena potrebnog za generisanje podataka za obučavanje neuronskih mreža korišćeni su veći trening skupovi dobijeni generisanjem iz prethodno razvijenih direktnih modela. Dobijenim rezultatima potvrđena je efikasnost predloženih modela, a u povećanju tačnosti značajan udeo imala je upotreba većih trening skupova koji su korišćeni u postupku razvoja neuronskih modela.

Kako promena dimenzija utiče istovremeno i na promenu EM i mehaničkih karakteristika, predloženi su i elektromehanički inverzni modeli, tj. modeli koji za zadate vrednosti rezonantne frekvencije, napona aktucije i jedne lateralne dimenzije određuju vrednost druge dimenzije mosta prekidača [103]. Predloženim modelima se prevazilazi kompleksna optimizacija lateralnih dimenzija prekidača, kao i složenost istovremene analize u EM i mehaničkim simulatorima, čime se značajno smanjuje vreme potrebno za projektovanje RF MEMS prekidača sa željenim karakteristikama. U disertaciji je posebna pažnja posvećena



i detaljnoj analizi prostora ulaznih veličina razvijenih inverznih neuronskih modela.

Ovako razvijeni inverzni neuronski modeli iskorišćeni su za projektovanje RF MEMS prekidača sa zadatim EM/mehaničkim karakteristikama, a sve u cilju prevazilaženja postupka optimizacije dimenzija prekidača za željene vrednosti rezonantne frekvencije/napona aktuacije [98, 99]. Time su izbegnute složene i veoma vremenski zahtevne optimizacije i numeričke simulacije u EM, odnosno mehaničkim simulatorima.

Takođe, u okviru ove doktorske disertacije, inverzni neuronski modeli zajedno sa modelima baziranim na ekvivalentnom kolu integrisani su u modifikovane hibridne modele [105-107]. Predloženi modeli ne zahtevaju dodatne simulacije u *full-wave* simulatoru niti dodatne optimizacije u simulatoru kola. Za željene vrednosti rezonantne frekvencije i zadate jedne dimenzije mosta prekidača, moguće je simultano odrediti drugu dimenziju mosta prekidača, kao i odgovarajuće elemente ekvivalentnog kola, a zatim simulirati S-parametre u željenom frekvencijskom opsegu. Time je postignut znatno efikasniji optimizacioni postupak u odnosu na klasične simulacione tehnike.

Obučavanje i testiranje veštačkih neuronskih mreža korišćenih za istraživanja u oblasti primene neuronskih modela u modelovanju RF MEMS prekidača vršeno je u okruženju programskog paketa MATLAB. Testiranje modela baziranih u potpunosti na veštačkim neuronskim mrežama vršeno je u okruženju programskog paketa MATLAB, dok je testiranje hibridnih modela koji predstavljaju kombinaciju neuronskih mreža i modela baziranih na ekvivalentnom kolu vršeno u okviru standardnog mikrotalasnog simulatora ADS.

Na osnovu prikazanih rezultata istraživanja i izvedenih zaključaka, kao glavni doprinosi doktorske disertacije mogu se izdvojiti:

- Razvoj neuronskih modela za modelovanje zavisnosti S-parametara od frekvencije i geometrijskih dimenzija mosta razmatranog RF MEMS prekidača;
- Razvoj neuronskih modela za modelovanje zavisnosti rezonantne frekvencije i napona aktuacije od geometrijskih dimenzija mosta razmatranog RF MEMS prekidača;
- Efikasnost upotrebe i tačnost razvijenih neuronskih modela potvrđena je validacijom i analizom postignutih rezultata sa rezultatima dobijenim postupkom simulacija i sa odgovarajućim raspoloživim merenim karakteristikama realizovanih komponenti;

- Primena razvijenih neuronskih modela za efikasnu analizu promene rezonantne frekvencije i napona aktuacije usled mogućih odstupanja dimenzija mosta pri fabrikaciji RF MEMS prekidača;
- Primena razvijenih modela za brzo i efikasno projektovanje RF MEMS prekidača u električnom i mehaničkom domenu na osnovu definisanih zahteva;
- Sagledavanje tačnosti neuronskih modela koji baziraju na različitim vrstama slojevitih neuronskih mreža, gde je izvršena uporedna analiza efikasnosti i tačnosti modela zasnovanih na višeslojnom perceptronu (MLP) i neuronskoj mreži sa radijalnom funkcijom (RBF);
- Razvoj hibridnog modela RF MEMS prekidača za određivanje elemenata ekvivalentnog kola za različite vrednosti lateralnih dimenzija mosta prekidača, a koji predstavlja kombinaciju razvijenih neuronskih modela sa modelom baziranom na ekvivalentnom kolu u simulatoru elektronskih kola;
- Razvoj inverznih modela za određivanje dimenzija mosta RF MEMS prekidača kojima se eliminiše potreba za vremenski zahtevnim optimizacijama u EM/mehaničkim simulatorima;
- Primena inverznih neuronskih modela za određivanje lateralnih dimenzija prekidača za zadate vrednosti rezonantne frekvencije i napona aktuacije, čime je unapređen proces projektovanja RF MEMS prekidača;
- Razvoj hibridnih inverznih modela zasnovanih na neuronskim modelima koji pored određivanja dimenzija prekidača određuju i elemente ekvivalentnog kola za simulacije kola razmatranog RF MEMS prekidača.

## 9 LITERATURA

- [1] G. M. Rebeiz, *RF MEMS: Theory, Design, and Technology*, John Wiley&Sons Inc, January 2003.
- [2] M. J. Madou, *Fundamentals of Microfabrication: The Science of Miniaturization*, 2<sup>nd</sup> ed., CRC Press, Boca Raton, FL, 2002.
- [3] M. Gad-el-Hak, *The MEMS Handbook*, 2<sup>nd</sup> ed., CRC Press/Taylor and Francis, Boca Raton, FL, 2006.
- [4] F. Chollet, H. Liu, *A Short Introduction to MEMS*, CC Publ. Franche-Comte, France, 2011.
- [5] J. B. Muldavin, *Design and Analysis of Series and Shunt MEMS Switches*, PhD dissertation, The University of Michigan, 2001.
- [6] H. Jaafar, K. S. Beh, N. A. M. Yunus, W. Z. W. Hasan, S. Shafe, O. Sidek, „A comprehensive study on RF MEMS switch“, *Microsystem Technologies*, Springer-verlag Berlin Heidelberg, 2014.
- [7] G. M. Rebeiz, „RF MEMS switches: status of the technology“, *12<sup>th</sup> International Conference on Solid State Sensors, Actuators and Microsystems, TRANSDUCERS '03*, Boston, June 8-12, 2003.
- [8] D. Hyman, M. Mehregany, „Contact Physics of Gold Microcontacts for MEMS Switches“, *IEEE Trans. Comp. Packaging Technology*, vol. 22, no. 3, pp. 357–364, Sep. 1999.
- [9] S. DiNardo, P. Farinelli, F. Giacomozzi, G. Mannocchi, R. Marcelli, B. Margesin, P. Mezzanotte, V. Mulloni, P. Russer, R. Sorrentino, F. Vitulli, L. Vietzorreck, „Broadband RF-MEMS based SPDT“, *Proc. European Microwave Conference 2006, Manchester*, Great Britain, September 2006.
- [10] M. R. Douglass, *DMD Reliability: A MEMS Success Story*, *Proceedings of the Reliability, Testing and Characterization of MEMS/MOEMS II*, Bellingham, WA, 2003.
- [11] J. Iannacci, *Practical Guide to RF MEMS*, Wiley-VCH, Germany, 2013.
- [12] J. Iannacci, *RF-MEMS Technology for High-Performance Passives*, IOP Publishing Ltd, 2017.
- [13] Status of the MEMS Industry 2020 report, Yole developpement, 2020

- [14] J. Iannacci, „RF-MEMS for 5G applications: a reconfigurable 8-bit power attenuator working up to 110 GHz. Part 2 - Experimental characterisation of the RF behavior”, *Microsystem Technologies*, September 2019
- [15] J. Iannacci, „RF-MEMS technology as an enabler of 5G: Low-loss ohmic switch tested up to 110 GHz“, *Elsevier, Sensors and Actuators*, A 279, pp. 624–629, 2018.
- [16] J. Iannacci, „Internet of things (IoT); internet of everything (IoE); tactile internet; 5G-A (not so evanescent) unifying vision empowered by EH-MEMS (energy harvesting MEMS) and RF-MEMS (radio frequency MEMS)“, *Elsevier, Sensors and Actuators*, A 272, pp. 187–198, 2018.
- [17] L. Vietzorreck, „EM Modeling of RF MEMS“, *7<sup>th</sup> International Conference on Thermal, Mechanical and Multiphysics Simulation and Experiments in Micro-Electronics and Micro-Systems, EuroSime 2006*, pp.1 – 4, April 24-26, 2006.
- [18] Z. J. Guo, N. E. McGruer, G. G. Adams, „Modeling, simulation and measurement of the dynamic performance of an ohmic contact, electrostatically actuated RF MEMS switch“, *J. Micromech. Microeng* 17, pp. 1899-1909, 2007.
- [19] E. Hamad, A. Omar, „An improved two-dimensional coupled electrostatic-mechanical model for RF MEMS switches“, *J. Micromech. Microeng.* 16 1424, 2006.
- [20] R. Marcelli, A. Lucibello, G. De Angelis, E. Proietti, „Mechanical modelling of capacitive RF MEMS shunt switches“ *Symposium on Test, Integration & Packaging of MEMS/MOEMS*, pp. 19 - 22, 2009.
- [21] Z. Marinković, M. Milijić, O. Pronić-Rančić, V. Marković, T. Kim, L. Vietzorreck, „Modelovanje parametara rasejanja kapacitivnih RF MEMS prekidača pomoću neuronskih mreža“, *Zbornik radova 57. Konferencije za ETRAN*, Zlatibor, pp. MT1.4 1-4, 3-6. jun 2013.
- [22] V. Marković, L. Vietzorreck, Z. Marinković, O. Pronić-Rančić, T. Kim, „Modeling of RF MEMS switches for application in communication systems”, *XXX simpozijum o novim tehnologijama u poštanskom i telekomunikacionom saobraćaju - PosTel 2012*, pp. 245-254, Beograd, 4-5. Decembar 2012.
- [23] T. Ćirić, „Primena veštačkih neuronskih mreža u modelovanju kapacitivnih RF MEMS prekidača“, magistarska teza, Elektronski fakultet, Niš, oktobar 2014.
- [24] S. Haykin, *Neural networks*, New York, IEEE, 1994.
- [25] S. Milenković, *Veštačke neuronske mreže*, Zadužbina Andrejević, Beograd, 1997.
- [26] Q. J. Zhang, K. C. Gupta, *Neural Networks for RF and Microwave Design*, Artech House, 2000.
- [27] G. L. Creech, B. J. Paul, C. D. Lesniak, T. J. Jenkins, M. C. Calcaterra, „Artificial neural networks for fast and accurate EM-CAD of microwave circuits“, *IEEE Trans. on Microwave Theory and Technique*, vol. 45, no. 5, pp. 794-802, 1997.
- [28] M. Vai, S. Prasad, „Neural networks in microwave circuit design - Beyond black-box models”, *Int. J. RF Microwave Computer-Aided Eng.*, vol. 9, pp. 187–197, 1999.
- [29] P. Burrascano, S. Fiori, M. Mongiardo, „A review of artificial neural network applications in microwave computer-aided design (Invited Article)”, *Int. J. of RF and Microwave CAE*, vol. 9, pp. 158-174, May 1999.
- [30] S. Wang, F. Wang, V. K. Devbahaktuni, Q. J. Zhang, „A hibrid neural and circuit-

- based model structure for microwave modeling”, *Proc. 29<sup>th</sup> European Microwave Conf.*, Munich, pp. 174-177, October 1999.
- [31] C. Christodoulou, M. Gerogiopoulos, *Applications of Neural Networks in Electromagnetics*, Artech House, 2001.
- [32] Q. J. Zhang, K. C. Gupta, V. K. Devabhaktuni, „Artificial neural networks for RF and microwave design - From theory to practice“, *IEEE Trans. Microw. Theory Tech.*, vol. 51, no. 4, pp. 1339–1350, April 2003.
- [33] B. Milovanović, V. Marković, Z. Marinković, Z. Stanković, „Some applications of neural networks in microwave modeling”, *JAC - Journal of Automatic Control*, University of Belgrade, vol. 13(1), pp. 39-46, 2003.
- [34] J. E. Rayas-Sanchez, „EM-based optimization of microwave circuits using artificial neural networks: The state-of-the-art”, *IEEE Trans. Microw. Theory Tech.*, vol. 52, no. 1, pp. 420–435, Jan. 2004.
- [35] H. Kabir, L. Zhang, M. Yu, P. Aaen, J. Wood, Q. J. Zhang, „Smart modeling of microwave devices“, *IEEE Microw. Mag.*, vol. 11, pp.105–108, May 2010.
- [36] P. M. Watson, K. C. Gupta, „Design and optimization of CWP Circuits using EM-ANN models for CPW components“, *IEEE Trans. on Microwave Theory and Technique*, vol. 45, no. 12, pp. 2515-2523, 1997.
- [37] F. Wang, Q. J. Zhang, „Knowledge based neural networks for microwave design“, *IEEE Trans. on Microwave Theory and Technique*, vol. 45, pp. 2333-2343, 1997.
- [38] M. Agatonović, Z. Marinković, V. Marković, „Application of ANNs in Evaluation of Microwave Pyramidal Absorber Performance“, *Applied Computational Electromagnetics Society Journal*, vol. 27, no. 4, pp. 326-333, April 2012.
- [39] A. Jarndal, „Neural network electrothermal modeling approach for microwave active devices“, *International Journal of RF and Microwave Computer-Aided Engineering*, John Wiley & Sons Inc, vol. 29, Septembre 2019.
- [40] J. Jin, F. Feng, J. N. Zhang, S. X. Yan, W. C. Na, Q. J. Zhang, „A novel deep neural network topology for parametric modeling of passive microwave components,” *IEEE Access*, vol. 8, pp. 82273-82285, May 2020.
- [41] J. Jin, F. Feng, W. C. Na, S. X. Yan, W. Y. Liu, L. Zhu, Q. J. Zhang, „Recent advances in neural network-based inverse modeling techniques for microwave applications,” *International Journal on Numerical Modeling*, 2020.
- [42] Z. Marinković, „Primena veštačkih neuronskih mreža u modelima malošumnih mikrotalasnih mikrotalasnih tranzistora”, doktorska disertacija, Elektronski fakultet, Niš, januar 2007.
- [43] A. Caddemi, F. Catalfamo, N. Donato, „A neural network approach for compact cryogenic modeling of HEMT’s“, *Int. J. Electron.*, vol. 94, no. 9, pp. 877-887, 2007.
- [44] Z. Marinković, G. Crupi, A. Caddemi, V. Marković, „Comparison between analytical and neural approaches for multibias small signal modeling of microwave scaled FETs“, *Microwave and Optical Technology Letters*, vol. 52, no. 10, pp. 2238-2244, October 2010.
- [45] Z. Marinković, G. Crupi, D. Schreurs, A. Caddemi, V. Marković, „Microwave FinFET modeling based on artificial neural networks including lossy silicon substrate“, *Microelectronic Engineering*, vol. 88, no. 10, pp. 3158-3163, October 2011.

- [46] Z. Marinković, O. Pronić-Rančić, V. Marković, „Artificial Neural Networks as a Tool for Improving Microwave Transistor Empirical Noise Models“, Chapter 14 in „*Artificial Intelligence and Hybrid Systems*“, edited by Claudio Rocha, iConcept Press Ltd., 2012.
- [47] Z. Marinković, O. Pronić-Rančić, V. Marković, „Small-signal and noise modelling of class of HEMTs using knowledge-based artificial neural networks“, *International Journal for RF and Microwave Computer-Aided Engineering*, vol. 23, no. 1, pp. 34-39, January 2013.
- [48] Z. Marinković, N. Ivković, O. Pronić-Rančić, V. Marković, A. Caddemi, „Analysis and validation of neural approach for extraction of small-signal models of microwave transistors“, *Microelectronics Reliability*, vol. 53, no. 3, pp. 414–419, March 2013.
- [49] Z. Marinković, V. Đorđević, N. Ivković, O. Pronić-Rančić, V. Marković, A. Caddemi, „Parameter extraction of small-signal and noise models of microwave transistors based on artificial neural networks“, Chapter 8 in „*Artificial Neural Networks: New Research*“, edited by Gayle Cain, Nova Science Publishers Inc., 2016.
- [50] L. Pantoli, A. Leoni, Z. Marinković, V. Stornelli, G. Leuzzi, „ANN approach to active inductor based filter design“, *International Journal of RF and Microwave Computer-Aided Engineering*, John Wiley & Sons, vol. 28, no. 9, pp. e21568, November 2018.
- [51] Z. Marinković, G. Crupi, A. Caddemi, V. Marković, D. Schreurs, „A review on the artificial neural network applications for small-signal modeling of microwave FETs“, *Int. Journal of Numerical Modeling: Electronic Networks, Devices and Fields, Special Issue: Devices and Circuits for Millimeter Wave and THz Applications*, vol. 33, no. 3, May/June 2020.
- [52] B. O’Brien, J. Dooley, T. Brazil, „RF power amplifier behavioral modeling using a globally recurrent neural network“, *IEEE MTT-S International Microwave Symposium Digest*, pp. 1089-1092, 2006.
- [53] F. Giannini, P. Colantonio, G. Orenco, A. Serino, G. Stegmayer, M. Pirola, G. Ghione, „Neural networks and volterra series for time-domain power amplifier behavioral models“, *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 17, no 2, pp.160–168, 2007.
- [54] F. Mkadem, M. Ayed, S. Boumaiza, J. Wood, P. Aen, „Behavioral modeling and digital predistortion of power amplifiers with memory using two hidden layers artificial neural networks“, *IEEE MTT-S International Microwave Symposium Digest*, pp. 656-659, 2010.
- [55] G. Washington, „Aperture antenna shape prediction by feed forward neural networks“, *IEEE Trans. on Antennas and Propagation*, vol. 45, no. 4, pp. 683-688, 1997.
- [56] H. L. Southall, J. A. Simmers, T. H. O’Donnell, „Direction finding in phased arrays with neural network beamformer“, *IEEE Trans. on Antennas and Propagation*, vol. 43, no. 12, pp. 1369-1374, 1995.
- [57] B. Milovanović, M. Milijić, A. Atanasković, Z. Stanković, „Modeling of Patch Antennas using Neural Networks“, *Proceeding of 7<sup>th</sup> International Conference on Telecommunications in Modern Satellite, Cable Broadcasting Services – TELSIS 2005*, Niš, pp. 385-388, September 2005.
- [58] M. Sarevska, B. Milovanović, Z. Stanković, „Alternative Signal Detection For Neural Network-Based Smart Antenna“, *Proceedings of the 7<sup>th</sup> Conference on Neural*

- Network Application in Electrical Engineering - NEUREL 2004*, Beograd, pp. 85-89, September 2004.
- [59] M. Agatonović, Z. Stanković, „Hybrid ANN Model for Accurate 2D DOA Estimation of a Radiating Source“, *11<sup>th</sup> Conference on Telecommunications in Modern Satellite, Cable and Broadcasting Services TELSIKS 2013*, Niš, Serbia, pp. 370-373, October 16-19, 2013.
- [60] M. W. Roth, „Survey of neural network technology for automatic target recognition“, *IEEE Trans. on Neural Networks*, vol. 1, no. 10, pp. 28-43, 1990.
- [61] J. Anderson, M. Gately, P. Pertz, D. Collins, „Radar signal categorization using a neural network“, *Proc. IEEE*, vol. 78, no. 10, pp. 353-354, 1993.
- [62] V. Litovski, M. Andrejevic, M. Zwolinski, „ANN based modeling, testing and diagnosis of MEMS capacitive pressure transducer example“, *7<sup>th</sup> Seminar on Neural Network Applications in Electrical Engineering (NEUREL 2004)*, pp. 183-188, 2004,
- [63] V. Litovski, M. Andrejevic, M. Zwolinski, „Behavioural modelling, simulation, test and diagnosis of MEMS using ANNs“, *IEEE International Symposium on Circuits and Systems (ISCAS 2005)*, vol. 5, pp. 5182 – 5185, May 2005.
- [64] Y. Lee, D. S. Filipovic, „Combined full-wave/ANN based modeling of MEMS switches for RF and microwave applications“, *IEEE Antennas and Propagation Society International Symposium*, vol. 1A, pp. 85-88, July 2005.
- [65] Y. Lee, D. S. Filipovic, „ANN based electromagnetic models for the design of RF MEMS switches“, *IEEE Microwave and Wireless Components Letters*, IEEE, vol. 15, no. 11, pp. 823-825, Nov. 2005.
- [66] Y. Lee, Y Park, F. Niu, D. Filipovic, „Artificial neural network based macromodeling approach for two-port RF MEMS resonating structures“, *IEEE Proceedings of Networking, Sensing and Control*, pp. 261 – 266, March 2005.
- [67] Y. Lee, Y Park, F. Niu, B. Bachman, K. C. Gupta, D. Filipovic, „Artificial neural network modeling of RF MEMS resonators“, *International Journal of RF and Microwave Computer-Aided Engineering, Special Issue: RF Applications of MEMS and Micromachining*, vol. 14, no. 4, pp. 302–316, July 2004.
- [68] Y. Lee, Y Park, F. Niu, D. Filipovic, „Design and optimisation of one-port RF MEMS resonators and related integrated circuits using ANN-based macromodelling approach“, *IEE Proceedings of Circuits, Devices and Systems*, vol. 153, no. 5, pp. 480-488, October 2006.
- [69] Y. Lee, Y Park, F. Niu, D. Filipovic, „Design and optimization of RF ICs with embedded linear macromodels of multiport MEMS devices“, *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 17, no. 2, pp. 196-209, 2007.
- [70] G. H. Yang, Q. Wu, J. H. Fu, K. Tang, J. X. He, „An efficient modeling technique for RF MEMS phase shifter based on RBF neural network“, *International Conference on Microwave and Millimeter Wave Technology (ICMMT 2008)*, vol. 2, pp. 475-478, April 2008.
- [71] G. H. Yang, Q. Wu, J. H. Fu, K. Tang, J. X. He, „Modeling technique for down-state of RF MEMS phase shifter based on artificial neural network“, *6<sup>th</sup> IEEE International Conference on Industrial Informatics (INDIN 2008)*, pp. 176-180, July 2008.
- [72] Y. Mafinejad, A. Z. Kouzani, K. Mafinezhad, „Determining RF MEMS switch

- parameter by neural networks“, *IEEE Region 10 Conference TENCON 2009*, pp. 1-5, Jan. 2009.
- [73] Y. Gong, F. Zhao, H. Xin, J. Lin, Q. Bai, „Simulation and optimal design for RF MEMS cantilevered beam switch“, *International Conference on Future Computer and Communication (FCC '09)*, pp. 84-87, June 2009.
- [74] G. H. Yang, Q. Wu, J. H. Fu, F. Y. Meng, „Modeling approach for distributed RF MEMS phase shifter based on IA-BP neural network“, *International Conference on Microwave and Millimeter Wave Technology (ICMMT 2010)*, pp. 1063-1066, 2010.
- [75] J. Wang, L. Sun, Y. Linag, „Accurate EC-ANN modeling for a RF-MEMS extended tuning range varactor“, *Asia Pacific Conference on Postgraduate Research in Microelectronics and Electronics (PrimeAsia 2010)*, pp. 360 – 363, Sept. 2010.
- [76] S. Suganthi, S. Raghavan, „Neural based optimization analysis of distributed MEMS transmission line phase shifters“, *International Conference on Intelligent Control and Information Processing (ICICIP 2010)*, pp. 639 – 643, Aug. 2010.
- [77] S. Suganthi, K. Murugesan, S. Raghavan, „Neural Network based realization and circuit analysis of lateral RF MEMS series switch“, *International Conference on Computer, Communication and Electrical Technology (ICCCET 2011)*, pp. 260 – 265, March 2011.
- [78] S. N. Naduvinamani, B. G. Sheeparamatti, S. Kalalbandi, S. R. Sheeparamatti, „Simulation of micro-cantilever based series switch and development of its ANN model“, *37<sup>th</sup> Annual Conference on IEEE Industrial Electronics Society (IECON 2011)*, pp. 4078 – 4083, Nov. 2011.
- [79] M. S. Diab, S. Husain, A. Jarndal, „On Diabetes Classification and Prediction using Artificial Neural Networks“, *International Conference on Communications, Computing, Cybersecurity and Informatics (CCCI)*, November 2020.
- [80] A. Jarndal, S. Husain, O. Zaatar, T. Al Gumaiei, A. Hamadeh, „GPR and ANN based Prediction Models for COVID-19 Death Cases“, *International Conference on Communications, Computing, Cybersecurity and Informatics (CCCI)*, November 2020.
- [81] M. Milosavljević, *Veštačka inteligencija*, Univerzitet Singidunum, Beograd, 2019.
- [82] J.A. Garcia, „Modeling MESFET’s and HEMT’s intermodulation distortion behavior using a generalized RBF network“, *Int. Journal of RF and Microwave CAE, Special issue on Applications of ANN to RF and Microwave Design*, vol. 9, pp. 261-276, 1999.
- [83] S. Reddy, D. Vakula, N. Sarma, „Design of multiple function antenna array using radial basis function neural network“, *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, vol. 12, no.1, 2013.
- [84] M. Passos, P. Silva, H. Fernandes, „A RBF/MLP Modular Neural Network for Microwave Device Modeling“, *International Journal of Computer Science and Network Security-IJCSNS*, vol. 6, no. 5A, 2006.
- [85] R. Zirak, S. Roshani, „Design and Modeling of RF Power Amplifiers with Radial Basis Function Artificial Neural Networks“, *International Journal of Advanced Computer Science and Applications-IJACSA*, vol. 7, no. 6, 2016.
- [86] J. W. Bandler, R. M. Biernacki, S. H. Chen, P. A. Grobelny, R. H. Hemmers, „Space mapping technique for electromagnetic optimization“, *IEEE Trans. Microwave Theory Tech.*, vol. 42, pp. 2536–2544, 1994.



- [87] D. Pozar, *Microwave Engineering*, J. Wiley & Sons, 1998.
- [88] B. Milovanovic, V. Markovic, N. Maleš-Ilic, O. Pronic-Rancic: „*Mikrotalasna tehnika - I deo*“, Elektronski fakultet, Niš, Edicija: Osnovni udžbenici, 2009
- [89] Z. Marinković, T. Kim, V. Marković, M. Milijić, O. Pronić-Rančić, T. Ćirić, L. Vietzorreck, „Artificial Neural network based design of RF MEMS capacitive shunt switches“, *Applied Computational Electromagnetics Society Journal*, vol. 31 no. 7, pp. 756-764, July 2016.
- [90] T. Kim, Z. Marinković, V. Marković, M. Milijić, O. Pronić-Rančić, L. Vietzorreck, „Efficient Modelling of an RF MEMS Capacitive Shunt Switch with Artificial Neural Networks“, *Proc. of URSI-B 2013 International Symposium on Electromagnetic Theory*, Hiroshima, Japan, pp. 550-551, May 20-24, 2013.
- [91] Z. Marinković, V. Marković, T. Ćirić, L. Vietzorreck, O. Pronić-Rančić, „Artificial neural networks in RF MEMS switch modelling“, *Facta Universitatis, Series: Electronics and Energetics*, vol. 29, no 2, pp. 177-191, 2016.
- [92] T. Ćirić, Z. Marinković, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „ANN approach for modeling of mechanical characteristics of RF MEMS capacitive switches - an overview“, *Microwave Review*, vol. 23, no. 1, pp. 25-34, June 2017.
- [93] Z. Marinković, T. Ćirić, V. Đorđević, O. Pronić-Rančić, T. Kim, M. Milijić, V. Marković, L. Vietzorreck, „ANN Approach for the Analysis of the Resonant Frequency Behavior of RF MEMS Capacitive Switches,“ *1<sup>st</sup> International Conference on Electrical, Electronic and Computing Engineering (IcETRAN 2014)*, Vrnjačka Banja, Serbia, pp. MTI2.1.1-5, June 2-6, 2014.
- [94] T. Ćirić, Z. Marinković, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „ANN approach for analysis of actuation voltage behavior of RF MEMS capacitive switches“, *12<sup>th</sup> Conference on Telecommunications in Modern Satellite, Cable and Broadcasting Services (TELSIKS 2015)*, Niš, Serbia, pp. 381-384, October 14-17, 2015.
- [95] M. Milijić, Z. Marinković, T. Kim, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „Modeling and optimization of ohmic series RF MEMS switches by using neural networks“, *German Microwave Conference (GeMIC)*, Aachen, Germany, pp. 1-4, March 10-12, 2014.
- [96] T. Ćirić, Z. Marinković, M. Milijić, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „Analysis of RF MEMS ohmic switches based on their neural models“, *3<sup>rd</sup> International Conference on Electrical, Electronic and Computing Engineering (IcETRAN 2016)*, Zlatibor, Serbia, pp. MTI2.5.1-6, June 13-16, 2016.
- [97] T. Ćirić, Z. Marinković, M. Milijić, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „ANN approach for return loss analysis of ohmic series RF MEMS switches“, *51<sup>th</sup> International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST 2016)*, Ohrid, Macedonia, pp. 45-48, 2016.
- [98] Z. Marinković, A. Aleksić, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „Analysis of RF MEMS capacitive switches by using switch EM ANN models“, *TELFOR Journal*, vol. 7, no. 2, pp. 80-85, December 2015.
- [99] Z. Marinković, A. Aleksić, T. Ćirić, O. Pronić-Rančić, V. Marković, „Analysis of RF MEMS capacitive switches by using neural model of actuation voltage“, *2<sup>nd</sup> International Conference on Electrical, Electronic and Computing Engineering (IcETRAN 2015)*, Silver Lake, Serbia, pp. MTI2.3.1-5, June 8-11, 2015.

- [100] T. Ćirić, Z. Marinković, M. Milijić, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „Modeling of actuation voltage of RF MEMS capacitive switches based on RBF ANNs“, *13<sup>th</sup> Symposium on Neural Networks and Applications (NEUREL)*, Belgrade, Serbia, pp. 119-122, November 22-24, 2016.
- [101] T. Ćirić, R. Dhuri, Z. Marinković, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „Neural Based Lumped Element Model of Capacitive RF MEMS Switches“, *Frequenz*, Walter de Gruyter GmbH, Berlin/Boston, vol. 72, issue 11-12, pp. 539–546, November 2018.
- [102] Z. Marinković, T. Ćirić, T. Kim, L. Vietzorreck, O. Pronić-Rančić, M. Milijić, V. Marković, „ANN Based Inverse Modeling of RF MEMS Capacitive Switches“, *11<sup>th</sup> Conference on Telecommunications in Modern Satellite, Cable and Broadcasting Services (TELSIKS 2013)*, Niš, Serbia, pp. 366-369, October 16-19, 2013.
- [103] T. Ćirić, Z. Marinković, T. Kim, L. Vietzorreck, O. Pronić-Rančić, M. Milijić, V. Marković, „ANN based inverse electro-mechanical modeling of RF MEMS capacitive switches,” *XLIX Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST 2014)*, Niš, Serbia, vol. 2, pp. 127-130, June 25-27, 2014.
- [104] Z. Marinković, A. Aleksić, T. Ćirić, O. Pronić-Rančić, V. Marković, L. Vietzorreck, „Inverse electro-mechanical ANN model of RF MEMS capacitive switches-applicability evaluation“, *L Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST 2015)*, Sofia, Bulgaria, pp. 157-160, June 24-26, 2015.
- [105] T. Ćirić, R. Dhuri, O. Pronić-Rančić, V. Marković, Z. Marinković, „Hybrid ANN-ECP Approach for Design of Capacitive RF MEMS switches“, *14<sup>th</sup> Conference on Telecommunications in Modern Satellite, Cable and Broadcasting Services (TELSIKS 2019)*, Niš, Serbia, pp. 327-330, October 23-25, 2019.
- [106] T. Ćirić, Z. Marinković, R. Dhuri, O. Pronić-Rančić, V. Marković, „Hybrid neural lumped element approach in inverse modeling of RF MEMS switches“, *Facta Universitatis, Series: Electronics and Energetics*, vol. 33, no 1, pp. 27-31, 2020.
- [107] R. Dhuri, T. Ćirić, O. Pronić-Rančić, V. Marković, Z. Marinković, „A neural approach for lumped element circuit based inverse modeling of RF MEMS switches“, *54<sup>th</sup> International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST 2019)*, Ohrid, North Macedonia, pp. 15-18, June 27-29, 2019.
- [108] COMSOL Multiphysics 4.3, *COMSOL, Inc.*
- [109] Advanced Design System 2009. Santa Rosa, CA: Electronic design automation software system produced by Keysight EEs of EDA.
- [110] J. Iannacci, R. Gaddi, A. Gnudi, „A Experimental Validation of Mixed Electromechanical and Electromagnetic Modeling of RF-MEMS Devices Within a Standard IC Simulation Environment“, *Journal of Microelectromechanical Systems*, vol. 19, no. 3, pp.526-537, 2010.
- [111] <http://www.coventor/mems-solutions/products/mems>
- [112] F. Giacomozzi, V. Mulloni, S. Colpo, J. Iannacci, B. Margesin, A. Faes, „A Flexible Fabrication Process for RF MEMS Devices“, *Romanian Journal of Information Science and Technology (ROMJIST)*, vol. 14, no. 3, pp. 259-268, 2011.

## **BIOGRAFIJA AUTORA**

Tomislav Ćirić rođen je 26. 04. 1978. godine u Bihaću. Osnovnu školu završio je u Nišu, a zatim gimnaziju u Beogradu. Osnovne studije završio je 2001. godine na Vojnoj akademiji u Beogradu. Magistarske studije na Elektronskom fakultetu u Nišu, smer Telekomunikacije završio je 2014. godine.

Novembra 2014. upisao je doktorske akademske studije na Elektronskom fakultetu u Nišu, na smeru Telekomunikacije.

U okviru dosadašnjeg naučno-istraživačkog rada objavio je kao autor/koautor ukupno 18 naučnih radova, od čega: dva rada u međunarodnim časopisima sa SCI/SCIE liste, 11 radova sa međunarodnih skupova štampanih u celini, tri rada u nacionalnim časopisima i dve autorizovane diskusije sa međunarodnih skupova.

## ИЗЈАВА О АУТОРСТВУ

Изјављујем да је докторска дисертација, под насловом

### **NOVI PRISTUPI U MODELOVANJU RF MEMS PREKIDAČA**

која је одбрањена на Elektronskom fakultetu Универзитета у Нишу:

- резултат сопственог истраживачког рада;
- да ову дисертацију, ни у целини, нити у деловима, нисам пријављивао/ла на другим факултетима, нити универзитетима;
- да нисам повредио/ла ауторска права, нити злоупотребио/ла интелектуалну својину других лица.

Дозвољавам да се објаве моји лични подаци, који су у вези са ауторством и добијањем академског звања доктора наука, као што су име и презиме, година и место рођења и датум одбране рада, и то у каталогу Библиотеке, Дигиталном репозиторијуму Универзитета у Нишу, као и у публикацијама Универзитета у Нишу.

У Нишу, 20.01.2021. godine.

Потпис аутора дисертације:



---

Tomislav I. Ćirić

**ИЗЈАВА О ИСТОВЕТНОСТИ ЕЛЕКТРОНСКОГ И ШТАМПАНОГ  
ОБЛИКА ДОКТОРСКЕ ДИСЕРТАЦИЈЕ**

Наслов дисертације:

**NOVI PRISTUPI U MODELOVANJU RF MEMS PREKIDAČA**

Изјављујем да је електронски облик моје докторске дисертације, коју сам предао/ла за уношење у **Дигитални репозиторијум Универзитета у Нишу**, истоветан штампаном облику.

У Нишу, 20.01.2021. godine.

Потпис аутора дисертације:



---

Tomislav I. Ćirić

## ИЗЈАВА О КОРИШЋЕЊУ

Овлашћујем Универзитетску библиотеку „Никола Тесла“ да у Дигитални репозиторијум Универзитета у Нишу унесе моју докторску дисертацију, под насловом:

### **NOVI PRISTUPI U MODELOVANJU RF MEMS PREKIDAČA**

Дисертацију са свим прилозима предао/ла сам у електронском облику, погодном за трајно архивирање.

Моју докторску дисертацију, унету у Дигитални репозиторијум Универзитета у Нишу, могу користити сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons), за коју сам се одлучио/ла.

1. Ауторство (CC BY)
2. Ауторство – некомерцијално (CC BY-NC)
3. Ауторство – некомерцијално – без прераде (CC BY-NC-ND)
4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)
5. Ауторство – без прераде (CC BY-ND)
6. Ауторство – делити под истим условима (CC BY-SA)

У Нишу, 20.01.2021. godine.

Потпис аутора дисертације:



---

Tomislav I. Ćirić