

UNIVERZITET U BEOGRADU
ELEKTROTEHNIČKI FAKULTET

Tamara Lj. Muškatirović-Zekić

**Modeli digitalne predistorzije za hibridne
masivne višeantenske predajnike sa
formiranjem snopa primenom neuralnih
mreža**

doktorska disertacija

Beograd, 2023.

UNIVERSITY OF BELGRADE
SCHOOL OF ELECTRICAL ENGINEERING

Tamara Lj. Muškatirović-Zekić

**Digital Predistortion Models for Hybrid
Beamforming Massive Multiple-antenna
Transmitters using Neural Networks**

doctoral dissertation

Belgrade, 2023.

Podaci o mentoru i članovima Komisije za odbranu doktorske disertacije

Mentor:

dr Nataša Nešković, redovni profesor
Univerzitet u Beogradu – Elektrotehnički fakultet

Članovi Komisije:

dr Aleksandar Nešković, redovni profesor
Univerzitet u Beogradu – Elektrotehnički fakultet

dr Nikola Tomašević, viši naučni saradnik
Institut „Mihajlo Pupin“

dr Milan Ilić, redovni profesor
Univerzitet u Beogradu – Elektrotehnički fakultet

dr Đurađ Budimir, gostujući profesor
Univerzitet u Beogradu

Datum odbrane: _____

Zahvalnica

Zahvaljujem se svom mentoru, prof. dr Nataši Nešković, na безусловnoj i nesebičnoj pomoći i podršci koju mi je pružala tokom procesa istraživanja i pisanja teze. Neizmerno Vam hvala na svim rečima podrške, savetima i tome što ste imali veru u mene.

Posebno se zahvaljujem svojoj mami Olgi, čija me je bezrezervna ljubav pratila tokom svih prethodnih godina, podsticala i davala mi snage da ustanem i nastavim da se borim kad mi je bilo najteže.

Zahvaljujem se svojoj sestri Dunji, bratu Đorđu i supruhu Nikši na ljubavi, podsticaju, strpljenju i razumevanju tokom izrade doktorske disertacije. Ipak najveća motivacija za završetak ovog dokorskog istraživanja su moje ćerke Mia i Tea i sin Marko, moje zvezdice koje su mi osvetlile put, moja tri anđela koji daju smisao celokupnom trudu i koji svojim postojanjem ulepšavaju svaki moj dan. Hvala vam za sve.

Takođe bih se zahvalila rodbini, prijateljima i kolegama koji su bili uz mene i koji su mi pomogli da istrajem u teškim trenucima.

Doktorsku disertaciju posvećujem svom ocu Ljubisavu, koga ću zauvek čuvati u svom srcu i uspomenama.

Modeli digitalne predistorzije za hibridne masivne višesantenske predajnike sa formiranjem snopa primenom neuralnih mreža

Sažetak:

Intenzivan i brz razvoj bežičnih sistema nove generacije usko je povezan sa razvojem i primenom *Multiple-Input Multiple-Output* (MIMO) tehnika koje omogućavaju povećanje protoka i spektralne efikasnosti, kao i pouzdanosti sistema. Sa druge strane, javljaju se novi izazovi pri dizajniranju masivnih višesantenskih (*massive MIMO* – mMIMO) predajnika zbog pojave nelinearne distorzije signala. Kako bi se smanjila nelinearna distorzija signala i postigle što bolje performanse MIMO sistema, neophodno je posebnu pažnju posvetiti digitalnoj predistorziji (DPD) pojačavača kod mMIMO predajnika.

U okviru ove doktorske disertacije realizovani su i analizirani različiti DPD modeli za mMIMO predajnike sa hibridnim formiranjem snopa (*hybrid beamforming*) primenom neuralnih mreža, sa ciljem razvijanja što efikasnijeg i sofisticiranijeg DPD modela. Neuralne mreže (NN) su prvenstveno izabrane zbog svoje sposobnosti da veoma dobro aproksimiraju nelinearne funkcije, kao i zbog svoje prilagodljivosti. Predložen je efikasan *Real-Valued Time-Delay Neural Network with 2 hidden Layers* (RVTDNN2L) DPD model, kao i proširen RVTDNN2L DPD model kod koga se u cilju povećanja tačnosti modela koristi dodatni signal koji sadrži informacije o koeficijentima *beamforming*-a. Predloženi modeli su implementirani u programskom paketu *Matlab* i nakon sprovedenih sveobuhvatnih simulacija, izvršena je analiza i verifikacija efikasnosti kompenzacije nelinearne distorzije. Simulacije su izvršene za 64x64 HBF mMIMO sistem sa jednim korisnikom i sa više korisnika, pri čemu su korišćene izmerene vrednosti pojačavača. Dobijeni rezultati prikazani su korišćenjem grafika i numerički korišćenjem relevantnih metrika: normalizovane srednje kvadratne greške (NMSE) i amplitude vektora greške (EVM).

Kao rezultat sprovedenog istraživačkog rada, pokazano je da predloženi RVTDNN2L DPD model i prošireni RVTDNN2L DPD model znatno bolje kompenzuju nelinearnu distorziju u odnosu na polinomijalne modele, kao i u odnosu na ostale razmatrane NN DPD modele slične kompleksnosti, čime je izvršeno fundamentalno unapređenje efikasnosti kompenzacije nelinearne distorzije signala u bežičnim sistemima nove generacije.

Ključne reči: digitalna predistorzija (DPD), neuralne mreže (NN), *massive MIMO*, *hybrid beamforming* (HBF), pojačavači snage (PA).

Naučna oblast: tehničke nauke, elektrotehnika

Uža stručna oblast: telekomunikacije

UDK broj: 621.3

Digital Predistortion Models for Hybrid Beamforming Massive Multiple-antenna Transmitters using Neural Networks

Abstract:

The intensive and rapid development of new generation wireless systems is closely related to the development and application of Multiple-Input Multiple-Output (MIMO) techniques, which increase the throughput and the spectral efficiency, as well as the reliability of a system. On the other hand, there are new challenges when designing massive MIMO (mMIMO) transmitters due to nonlinear signal distortion. In order to reduce the nonlinear signal distortion and achieve the best possible performance of a MIMO system, it is necessary to pay special attention to the digital predistortion (DPD) of amplifiers in mMIMO transmitters.

Within this doctoral dissertation, different DPD models for mMIMO transmitters with hybrid beamforming using neural networks are implemented and analyzed, with the aim of developing the most efficient and sophisticated DPD model. Neural networks (NN) were primarily chosen because of their ability to approximate nonlinear functions very well, as well as because of their adaptability. An efficient Real-Valued Time-Delay Neural Network with 2 hidden Layers (RVTDNN2L) DPD model is proposed, as well as an extended RVTDNN2L DPD model where, in order to increase the accuracy of the model, an additional signal containing information about the beamforming coefficients is used. The proposed models are implemented in the *Matlab* software package and after comprehensive simulations, the analysis and verification of the effectiveness of the nonlinear distortion compensation is performed. Simulations were performed for a single-user and multi-user 64x64 HBF mMIMO system, based on measurement data from an actual amplifier. The obtained results are presented graphically and numerically using relevant metrics: normalized mean square error (NMSE) and error vector amplitude (EVM).

As a result of the research work, it is shown that the proposed RVTDNN2L DPD model and the extended RVTDNN2L DPD model compensate for nonlinear distortion significantly better in comparison to polynomial models, as well as in relation to other considered NN DPD models of similar complexity, by which fundamental improvement in the efficiency of compensation of nonlinear distortion signals in new generation wireless systems has been achieved.

Key words: digital predistortion (DPD), neural networks (NN), massive MIMO, hybrid beamforming (HBF), power amplifiers (PA).

Scientific field: technical sciences, electrical engineering

Scientific subfield: telecommunications

UDK: 621.3

Sadržaj

Spisak slika	VIII
Spisak tabela	XII
Spisak skraćenica	XIII
1. UVOD	1
1.1 Predmet i cilj istraživanja.....	3
1.2 Struktura doktorske disertacije.....	4
2. POJAČAVAČI SNAGE.....	6
2.1 Parametri pojačavača	6
2.1.1 Pojačanje i propusni opseg.....	6
2.1.2 Tačka kompresije IP1dB i IP3	6
2.1.3 <i>Back-off</i> i PAPR.....	8
2.1.4 Efikasnost.....	9
2.1.5 AM/AM i AM/PM karakteristike	10
2.2 Parametri kvaliteta signala	10
2.2.1 EVM.....	11
2.2.2 ACPR	11
2.3 Tehnike linearizacije pojačavača	12
2.3.1 <i>Feedback</i> tehnika linearizacije.....	12
2.3.2 <i>Feedforward</i> tehnika linearizacije	12
2.3.3 LINC tehnika linearizacije	13
2.3.4 Predistorzija	14
2.4 Modelovanje ponašanja pojačavača.....	14
2.4.1 LUT model.....	15
2.4.2 <i>Volterra</i> model.....	16
2.4.3 <i>Memory Polynomial</i> model.....	17
2.4.4 <i>Wiener</i> model	18
2.4.5 <i>Hammerstein</i> model	19
2.4.6 <i>Twin Nonlinear Two-Box</i> modeli.....	20
2.5 Procena performansi modela.....	21
2.5.1 MSE	21
2.5.2 NMSE.....	21
2.5.3 ACPR	22
2.6 Određivanje koeficijenata DPD modela	22
2.6.1 DLA metoda.....	22
2.6.2 ILA metoda	23
2.7 Procena kompleksnosti DPD modela.....	24
2.8 DPD modeli sa ograničenom širinom propusnog opsega	24
3. MIMO.....	27
3.1 Radio kanal i mehanizmi prostiranja radio signala.....	27
3.2 Opis MIMO sistema.....	29
3.3 Hibridni <i>beamforming</i>	33
3.3.1 <i>Spatially Sparse Precoding</i> algoritam.....	37
3.3.2 Algoritam naizmenične minimizacije	39
3.3.3 MMSE algoritam.....	40
3.4 Model kanala.....	40

3.4.1	<i>Ray-Tracing</i> model kanala	41
3.4.2	<i>One-Ring</i> model kanala.....	42
3.4.3	<i>Saleh-Valenzuela</i> model kanala	43
3.4.4	Kronekerov model kanala	45
3.5	Neželjeni efekti u MIMO sistemu.....	45
3.5.1	Uticaj pojačavača snage	45
3.5.2	I/Q neuravnoteženost	46
3.5.3	Efekat preslušavanja	47
3.6	DPD modeli za MIMO predajnike.....	48
3.6.1	<i>Single-Pa-Feedback</i> DPD	49
3.6.2	Dekorelacioni DPD	50
3.6.3	<i>Closed-Loop</i> DPD	50
3.6.4	<i>Beam-Oriented</i> DPD	51
3.6.5	<i>Power-Scalable Beam-Oriented</i> DPD	52
3.6.6	<i>Multi-Stream Spatial</i> DPD	53
3.6.7	MP DPD za potpuno povezan HBF mMIMO predajnik.....	54
3.6.8	Poređenje različitih DPD modela za MIMO predajnike	55
4.	NEURALNE MREŽE.....	57
4.1	Model neurona	58
4.1.1	Aktivacione funkcije	59
4.2	Arhitektura neuralne mreže.....	61
4.3	Algoritmi učenja	64
4.3.1	Učenje sa propagacijom greške unazad	65
4.3.2	LM algoritam	66
4.3.3	Algoritam skaliranog konjugovanog gradijenta.....	67
4.3.4	Q učenje	67
4.3.5	Hebovo učenje.....	68
4.3.6	Kompetitivno učenje	69
4.3.7	Bolcmanovo učenje.....	70
4.4	Treniranje neuralne mreže	71
4.4.1	Prikupljanje i obrada podataka.....	72
4.4.2	Izbor tipa i arhitekture neuralne mreže	74
4.4.3	Izbor algoritma učenja	75
4.4.4	Inicijalizacija neuralne mreže	75
4.4.5	Analiza performansi mreže	76
4.5	Regularizacija.....	76
4.5.1	Tehnika ranog zaustavljanja.....	78
4.5.2	Tehnika izbacivanja	78
4.5.3	L1 I L2 regularizacija.....	79
5.	NN DPD MODELI ZA SU HBF mMIMO PREDAJNIKE.....	81
5.1	Izbor modela neuralne mreže	82
5.2	Formiranje NN DPD modela	90
5.3	Rezultati simulacija za predajnik sa 2 RF grane	93
5.4	Rezultati simulacija za predajnik sa više RF grana.....	96
6.	NN DPD ZA MU HBF mMIMO PREDAJNIKE.....	98
6.1	Formiranje RVTDNN2L DPD modela	99
6.2	Rezultati simulacija.....	100
7.	PROŠIREN NN DPD MODEL.....	103

7.1 Rezultati simulacija za SU slučaj.....	105
7.2 Rezultati simulacija za MU slučaj	107
8. ZAKLJUČAK	114
Literatura.....	118
Prilog 1 – Kod za generisanje koeficijenata za hibridni <i>beamforming</i> u <i>Matlab</i> -u	129
Prilog 2 – Kod za generisanje OFDM signala u <i>Matlab</i> -u	130
Biografija autora	131

Spisak slika

Slika 1.1 – Broj pretplatnika mobilnih sistema po tehnologijama (u milijardama).

Slika 2.1 – Tačka kompresije 1 dB: a) karakteristika izlazne snage; b) karakteristika pojačanja.

Slika 2.2 – *Third Order Intercept Point*.

Slika 2.3 – Odnos između OBO, PBO i PAPR.

Slika 2.4 – Grafički prikaz EVM u konstelacionom domenu.

Slika 2.5 – Blok šema *feedback* tehnike linearizacije.

Slika 2.6 – Blok šema *feedforward* tehnike linearizacije.

Slika 2.7 – Blok šema LINC tehnike linearizacije.

Slika 2.8 – Blok šema DPD tehnike linearizacije.

Slika 2.9 – Blok šema LUT modela.

Slika 2.10 – Blok šema ugnježđenog LUT modela.

Slika 2.11 – Blok šema *Volterra* modela.

Slika 2.12 – Blok šema MP modela.

Slika 2.13 – Blok šema *Wiener* modela.

Slika 2.14 – Blok šema uvećanog *Wiener* modela.

Slika 2.15 – Blok šema *Hammerstein* modela.

Slika 2.16 – Blok šema uvećanog *Hammerstein* modela.

Slika 2.17 – Blok šema TNTB modela: a) *forward*; b) *reverse*; c) paralelni.

Slika 2.18 – Blok šema DLA metode.

Slika 2.19 – Blok šema ILA metode.

Slika 3.1 – Višestruko prostiranje signala.

Slika 3.2 – Blok šema MIMO sistema.

Slika 3.3 – Prostorni diverziti i prostorno multipleksiranje kod MIMO sistema.

Slika 3.4 – *Beamforming* kod SU-MIMO i MU-MIMO sistema.

Slika 3.5 – Tipovi *beamforming*-a: a) analogni; b) digitalni; c) hibridni.

Slika 3.6 – Blok šema arhitekture HBF predajnika: a) potpuno povezana; b) delimično povezana.

Slika 3.7 – *Spatially Sparse Precoding* algoritam za određivanje koeficijenata za prekodovanje.

Slika 3.8 – *Spatially Sparse Precoding* algoritam za određivanje koeficijenata za kobinovanje.

Slika 3.9 – *Ray-tracing* model MIMO kanala.

Slika 3.10 – *One-ring* model MIMO kanala.

Slika 3.11 – Fizička interpretacija *Saleh-Valenzuela* modela kanala.

Slika 3.12 – Kronekerov model kanala.

Slika 3.13 – Blok šema I/Q modulatora.

Slika 3.14 – Linearno i nelinearno preslušavanje u MIMO predajniku.

Slika 3.15 – Blok šema *Single-PA-Feedback* DPD modela.

Slika 3.16 – Blok šema dekorelacionog DPD modela za jedan podniz.

Slika 3.17 – Blok šema *closed-loop* DPD modela za jedan podniz.

Slika 3.18 – Blok šema BO-DPD modela.

Slika 3.19 – Blok šema PSBO-DPD modela.

Slika 3.20 – Blok šema kaskadnog modela pojačavača skalabilnog po snazi.

Slika 3.21 – Blok šema *Multi-Stream Spatial* DPD modela.

Slika 3.22 – Blok šema MP DPD modela za FC HBF mMIMO.

Slika 3.23 – Blok šema MP modela za $M=3$, $K=11$.

Slika 4.1 – Blok šema modela neurona.

Slika 4.2 – Tipovi aktivacionih funkcija: a) linearna, b) funkcija praga, c) deo-po-deo linearna, d) *logsig*, e) *tansig*, f) ispravljena linearna.

Slika 4.3 – Klasifikacija neuralnih mreža.

Slika 4.4 – Arhitektura neuralne mreže: a) *feedforward*, b) rekurentna.

Slika 4.5 – Geometrijska interpretacija kompetitivnog učenja: a) početno stanje mreže, b) krajnje stanje mreže.

Slika 4.6 – Dijagram toka treniranja neuralne mreže.

Slika 4.7 – Postupak unakrsne validacije (*10-fold cross-validation*).

Slika 4.8 – Ilustracija problema podnaučenosti i prenaučivosti.

Slika 4.9 – Zavisnost greške od kompleksnosti modela za prenaučeni i podnaučeni model.

Slika 4.10 – Tehnika ranog zaustavljanja.

Slika 4.11 – Tehnika izbacivanja.

Slika 4.12 – L1 i L2 tehnike regularizacije.

Slika 5.1 – Blok šema NN DPD modela za SU FC HBF mMIMO predajnik.

Slika 5.2 – Blok šeme izabranih modela neuralnih mreža: a) DNN, b) RVTDDNN, c) ARVTDDNN, d) RVTDDNN2L.

Slika 5.3 – AM/AM i AM/PM karakteristike pojačavača.

Slika 5.4 – Treniranje neuralne mreže koja vrši modelovanje ponašanja pojačavača.

Slika 5.5 – Spektralna gustina snage izlaznog signala pojačavača.

Slika 5.6 – Spektralna gustina snage izlaznog signala FC HBF mMIMO predajnika: a) 4x4; b) 16x16; c) 64x64.

Slika 5.7 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika sa više grana.

Slika 6.1 – Blok šema arhitekture 1 RVTDDNN2L DPD modela za MU FC HBF mMIMO predajnik.

Slika 6.2 – Blok šema arhitekture 2 RVTDDNN2L DPD modela za MU FC HBF mMIMO predajnik.

Slika 6.3 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika – korisnik 1.

Slika 6.4 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika – korisnik 2.

Slika 7.1 – Blok šema proširenog RVTDDNN2L DPD modela za SU FC HBF mMIMO predajnik.

Slika 7.2 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika za klasičan i proširen RVTDDNN2L DPD model.

Slika 7.3 – Uporedni prikaz spektralne gustine snage izlaznog signala 64x64 FC HBF mMIMO predajnika za svih šest analiziranih DPD modela.

Slika 7.4 – Blok šema arhitekture 1 proširenog RVTDNN2L DPD modela za MU FC HBF mMIMO predajnik.

Slika 7.5 – Blok šema arhitekture 2 proširenog RVTDNN2L DPD modela za MU FC HBF mMIMO predajnik.

Slika 7.6 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika – korisnik 1: a) $I=18$, $\Pi=9$, b) $I=32$, $\Pi=15$, c) $I=48$, $\Pi=21$.

Slika 7.7 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika – korisnik 2: a) $I=18$, $\Pi=9$, b) $I=32$, $\Pi=15$, c) $I=48$, $\Pi=21$.

Spisak tabela

Tabela 2.1 – Potreban broj FLOP-ova za određene računarske operacije.

Tabela 2.2 – Performanse i kompleksnost *band-limited* DPD modela.

Tabela 3.1 – Performanse DPD modela za hibridne *beamforming* MIMO predajnike.

Tabela 5.1 – EVM za 4x4 FC HBF mMIMO sistem sa 2 RF grane [%].

Tabela 5.2 – NMSE za 4x4 FC HBF mMIMO sistem sa 2 RF grane [dBm].

Tabela 5.3 – Broj koeficijenata RVDNN2L DPD modela.

Tabela 5.4 – Broj FLOP-ova RVDNN2L DPD modela.

Tabela 5.5 – Parametri i kompleksnost izabranih modela neuralnih mreža.

Tabela 5.6 – Performanse različitih DPD modela za 4x4 FC HBF mMIMO predajnik.

Tabela 5.7 – Performanse različitih DPD modela za 16x16 FC HBF mMIMO predajnik.

Tabela 5.8 – Performanse različitih DPD modela za 64x64 FC HBF mMIMO predajnik.

Tabela 5.9 – Performanse različitih DPD modela za 64x64 FC HBF mMIMO predajnik sa više RF grana.

Tabela 6.1 – Performanse RVDNN2L DPD modela za 64x64 FC HBF mMIMO predajnik – korisnik 2.

Tabela 6.2 – Performanse RVDNN2L DPD modela za 64x64 FC HBF mMIMO predajnik – korisnik 2.

Tabela 6.3 – Kompleksnost različitih arhitektura RVDNN2L DPD modela.

Tabela 7.1 – Performanse proširenog i klasičnog RVDNN2L DPD modela za 64x64 FC HBF mMIMO predajnik.

Tabela 7.2 – Parametri i kompleksnost proširenog i klasičnog RVDNN2L DPD modela.

Tabela 7.3 – Performanse proširenog i klasičnog RVDNN2L DPD modela za 64x64 FC HBF mMIMO predajnik sa dva korisnika – korisnik 1.

Tabela 7.4 – Performanse proširenog i klasičnog RVDNN2L DPD modela za 64x64 FC HBF mMIMO predajnik sa dva korisnika – korisnik 2.

Tabela 7.5 – Kompleksnost različitih arhitektura klasičnog i proširenog RVDNN2L DPD modela.

Spisak skraćenica

3D	Three-Dimensional
3G	3rd Generation
3GPP	3rd Generation Partnership Project
5G	5th Generation
6G	6th Generation

A

A/D	Analog-to-Digital
ACLR	Adjacent Channel Leakage Ratio
ACPR	Adjacent Channel Power Ratio
ADALINE	ADaptive LInear Element
ADC	Analog-to-Digital Conversion
AM	Amplitude Modulation
ANN	Artificial Neural Network
AR	Augmented Reality
ARFPD	Analog Radio Frequency Predistortion
ARVTDNN	Augmented Real-Valued Time-Delay Neural Network

B

BO-DPD	Beam-Oriented Digital Predistortion
BS	Base Station

C

CDF	Cumulative Distribution Function
CNN	Convolutional Neural Network
CSI	Channel State Information

D

D/A	Digital-to-Analog
DAC	Digital-to-Analog Conversion
DC	Direct Current
DLA	Direct Learning Architecture
DNN	Deep Neural Network
DPD	Digital Predistortion
DSP	Digital Signal Processing
DUT	Device Under Test

E

EPA	Error Power Amplifier
EVM	Error Vector Magnitude

F

FC	Fully Connected
FIR	Finite Impulse Response
FLOP	Floating point Operations Per Second

		G
GMP	Generalized Memory Polynomial	
		H
HBF	Hybrid Beamforming	
		I
I/Q	In-phase/Quadrature	
IBO	Input Back-Off	
IEEE	Institute of Electrical and Electronics Engineers	
IIP3	Third Order Input Intercept Point	
ILA	Indirect Learning Architecture	
IMD	Intermodulation	
IoE	Internet of Everything	
IP1dB	1 dB compression point	
IP3	Third Order Intercept Point	
IRR	Image Rejection Ratio	
		L
LINC	Linear Amplification using Nonlinear Components	
LM	Levenberg-Marquardt	
LMS	Least Mean Squares	
LTE	Long Term Evolution	
LO	Local Oscillator	
LoS	Line-of-Sight	
LUT	Look-Up Table	
		M
MAC	Media Access Control	
MAD	Mean Absolute Deviation	
MAPE	Mean Absolute Percentage Error	
MIMO	Multiple Input Multiple Output	
MLP	MemoryLess Polynomial	
mMIMO	massive Multiple Input Multiple Output	
MMSE	Minimum Mean Squared Error	
MO	Manifold Optimization	
MP	Memory Polynomial	
MSE	Mean Squared Error	
MU	Multi-User	
		N
NMSE	Normalized Mean-Squared Error	
NN	Neural Network	
		O
OBO	Output Back-Off	
OFDM	Orthogonal Frequency Division Multiplexing	
OIP3	Third Order Output Intercept Point	

OMP Orthogonal Matching Pursuit
OTA Over-The-Air

P

PA Power Amplifier
PAE Power Added Efficiency
PAPR Peak-to-Average Power Ratio
PBO Peak Back-Off
PM Phase Modulation
PSBO-DPD Power Scalable Beam-Oriented Digital Predistortion
PTNTB Parallel Twin Nonlinear Two-Box

Q

QAM Quadrature Amplitude Modulation

R

RDRS Random Demodulation based Reduced Sampling rate
ReLU Rectified Linear Unit
RF Radio Frequency
RMSE Root Mean Square Error
RNN Recurrent Neural Network
RVTDNN Real-Valued Time-Delay Neural Network
RVTDNN2L Real-Valued Time-Delay Neural Network with 2 hidden Layers
RX Receiver

S

S/N Signal-to-Noise
SA Subarray
SCG Scaled Conjugate Gradient
SISO Single Input Single Output
SNN Shallow Neural Network
SNR Signal-to-Noise Ratio
SOM Self-Organizing Map
STBC Space-Time Block Coding
SU Single-User
SVD Singular Value Decomposition

T

TDNN Time-Delay Neural Network
TNTB Twin Nonlinear Two-Box
TX Transmitter

U

ULA Uniform Linear Array

V


VLSI Very-Large-Scale Integration
VR Virtual Reality

1. UVOD

Povezanost i prenos informacija putem bežičnih mobilnih mreža postali su sastavni deo našeg svakodnevnog života, nešto bez čega se ne može zamisliti moderno društvo. Kao što se može videti na slici 1.1, a na osnovu *Ericsson*-ovog izveštaja, broj korisnika mobilnih mreža u 2022. godini dostigao je 8.4 milijardi, od kojih je oko 1 milijarde 5G mobilnih pretplatnika, dok je očekivan broj mobilnih pretplatnika do kraja 2028. godine 9.2 milijarde, od čega se predviđa da će oko 5 milijardi biti mobilnih pretplatnika 5G sistema [1]. Od prenosa poruka i kratkih medija, preko sve zahtevnijeg video sadržaja, 3D filmova, aplikacija virtuelne (*Virtual Reality* – VR) i proširene stvarnosti (*Augmented Reality* – AR), sve do potpuno povezanog Internet društva (*Internet of Everything* – IoE) sa povezanim različitim uređajima poput pametnih uređaja u domaćinstvu, automobilima, različitim senzora i mašina koje međusobno komuniciraju, globalni prenos podataka putem mobilnih mreža se praktično udvostručuje svake dve godine [1]. Pored zahteva za prenosom velike količine podataka i dostupnosti mobilnih servisa i aplikacija u svakom trenutku na bilo kom mestu, korisnici očekuju i veoma pouzdanu komunikaciju sa jako malim kašnjenjem. Samim tim su i očekivanja i ciljevi koje treba da zadovolje mobilni sistemi nove generacije (5G i budući 6G) postavljeni visoko. Očekuju se brzine prenosa podataka do 20Gb/s, ultra malo kašnjenje (ispod 10 ms), širok propusni opseg (reda stotinak MHz, pa sve do nekoliko GHz) i efikasna upotreba spektra i energije [2]-[6]. Kako je radio-frekvencijski spektar ograničen resurs, u cilju povećanja propusnog opsega i spektralne efikasnosti koriste se širokopolasni (*wideband*) pojačavači, milimetarski talasi (*mmWave*), *massive Multiple Input Multiple Output* (mMIMO) tehnologija [7]-[8] i tehnike usmeravanja snopa (*beamforming*). Zbog velikog broja RF lanaca, kompleksnost i cena opreme kod konvencionalnih digitalnih *beamforming* mMIMO predajnika nije zanemarljiva, te je stoga predloženo korišćenje hibridnog *beamforming*-a (HBF) [9]-[10]. Kod hibridnog *beamforming*-a vrši se analogni *beamforming* u RF domenu, primenom analognog prekodera koji se sastoji od faznih pomerača, i digitalni *beamforming* u osnovnom opsegu, primenom niskodimenzionog digitalnog prekodera. Na ovaj način je smanjen broj RF lanaca, faznih pomerača, mešača i ADC/DAC konvertora, čime je pored cene same opreme, smanjena i njena kompleksnost, kao i potrošnja snage.

Energetska efikasnost uređaja ima značajan uticaj na trenutno najveći ekološki problem, koji privlači pažnju svetske javnosti, na klimatske promene i globalno zagađenje usled povišenih emisija ugljenika. Kako telekomunikacioni sektor predstavlja osnovu moderne, globalne ekonomije, on ima presudan značaj u smanjenju emisije gasova i ispunjenju ciljeva održivog razvoja [11]. Stoga je potrebno posebnu pažnju posvetiti povećanju energetske efikasnosti i smanjenju potrošnje energije u mobilnim mrežama nove generacije (tzv. *green communications*). Različita istraživanja su pokazala da je najveći potrošač energije u mobilnim mrežama bazna stanica, dok u okviru same bazne stanice pojačavač snage (*Power Amplifier* – PA) troši najveći deo energije (oko 65%) [12]-[14]. U cilju uštede energije i postizanja maksimalne energetske efikasnosti, pojačavači rade u oblasti blizu zasićenja, tj. u nelinearnom delu prenosne karakteristike, što dovodi do pojave nelinearne distorzije signala. Stoga je neophodno pronaći kompromis između ova dva suprotstavljena zahteva, efikasnosti i linearnosti pojačavača. Opšti pristup ovom problemu je povećanje efikasnosti pojačavača, dizajniranjem predajnog sklopa tako da pojačavač radi u nelinearnom delu prenosne karakteristike, a zatim linearizacija pojačavača, uvođenjem dodatnih blokova za linearizaciju i obradu signala [15]-[16]. Kako bi se rešio problem nelinearne distorzije

signala i izbeglo narušavanje performansi sistema, koriste se različite tehnike linearizacije pojačavača.



Slika 1.1 – Broj pretplatnika mobilnih sistema po tehnologijama (u milijardama) [1].

Digitalna predistorzija (*Digital Predistortion – DPD*) predstavlja jednu od najčešće korišćenih tehnika za linearizaciju pojačavača, čiji se osnovni princip sastoji u uvođenju dodatnog nelinearnog bloka pre pojačavača, sa funkcijom prenosa koja je inverzna funkciji prenosa pojačavača, tako da se množenjem ove dve funkcije dobija linearan izlaz. Mnogobrojni istraživački radovi bave se pronalaženjem i razvijanjem jeftinih i efikasnih modela digitalne predistorzije, što sa pojavom sve kompleksnijih primopredajnih sistema postaje pravi izazov. U slučaju mMIMO predajnika, primena konvencionalnih DPD sistema, kod kojih za svaki pojačavač postoji poseban DPD blok za njegovu linearizaciju, predstavlja skupo i nepraktično rešenje usled velikog broja pojačavača. Time je pred inženjere postavljen novi zadatak i izazov, realizovati DPD model koji efikasno linearizuje više pojačavača u nizu. Zbog značaja kompenzacije nelinearne distorzije kod HBF mMIMO predajnika, postoji veliki broj istraživačkih radova koji se bave ovom problematikom [17]-[23].

Veštačke neuralne mreže (*Artificial Neural Network – ANN*) imaju sve rasprostranjeniju primenu u različitim oblastima savremenog života, samim tim i u oblasti linearizacije pojačavača. Jedan od razloga za široku primenu neuralnih mreža u dizajniranju i optimizaciji različitih modela za digitalnu predistorziju signala jeste mogućnost neuralnih mreža da dobro aproksimiraju nelinearnu vezu između ulaznih i izlaznih parametara koja se ne može eksplicitno opisati analitičkom formulom. Najčešće korišćeni modeli neuralnih mreža imaju jedan ulaz, jedan ili više skrivenih slojeva i jedan izlaz. Zavisno od broja skrivenih slojeva, neuralne mreže se dele na „plitke“ (*Shallow Neural Network – SNN*) i „duboke“ (*Deep Neural Network – DNN*) neuralne mreže. SNN imaju jedan ili dva skrivena sloja, dok DNN imaju tri i više skrivenih slojeva, sa većim brojem neurona u svakom od njih. Većina dosadašnjih istraživanja vezanih za primenu neuralnih mreža u oblasti digitalne predistorzije bazirana je na primeni različitih neuralnih mreža za linearizaciju jednog pojačavača [24]-[30].

Analizom literature, ustanovljeno je da do sada nije razmatrana mogućnost primene neuralnih mreža za digitalnu predistorziju kod HBF mMIMO predajnika, te je stoga fokus ove disertacije na

razvoju efikasnih modela digitalne predistorzije za HBF mMIMO predajnike primenom neuralnih mreža.

1.1 Predmet i cilj istraživanja

Predmet istraživanja doktorske disertacije je analiza modela digitalne predistorzije za hibridne masivne višiantenske predajnike sa formiranjem snopa (hibridne *beamforming* mMIMO predajnike) i ispitivanje efikasnosti primene različitih konfiguracija neuralnih mreža za konstrukciju bloka za digitalnu predistorziju. Neuralne mreže su izabrane zbog njihove visoke tačnosti modelovanja i jednostavnije implementacije u *Very Large-Scale Integration* (VLSI) tehnologiji u odnosu na klasične modele zasnovane na polinomima. Pored toga, neuralne mreže mogu veoma dobro da aproksimiraju nelinearne funkcije i da se relativno lako i brzo prilagode promenljivim uslovima sredine. U okviru doktorske disertacije predložen je efikasan *Real-Valued Time-Delay Neural Network with 2 hidden Layers* (RVTDDN2L) DPD model za hibridne *beamforming* mMIMO predajnike [31]. Takođe, predložen je i proširen RVTDDN2L DPD model, kod koga je za potrebe treniranja neuralne mreže doveden dodatni signal koji sadrži informacije o koeficijentima *beamforming*-a, kako bi se povećala tačnost NN DPD modela.

Da bi se opslužio veći broj korisnika u mobilnim mrežama, pored klasičnih *Single-User* (SU), sve više se koriste i *Multi-User* (MU) mMIMO sistemi, kod kojih se signali koji se šalju nakon hibridnog *beamforming*-a formiraju na osnovu podataka svih korisnika. U tom slučaju je potrebno prilikom konstrukcije modela predistortera uzeti u obzir signale svih korisnika. Stoga je u ovom istraživanju razmotrena i mogućnost implementacije predloženih modela u slučaju sistema sa više korisnika.

Tehnike digitalne predistorzije predstavljaju veoma rasprostranjen i efikasan metod za smanjenje distorzije signala, kako unutar tako i van opsega, što potvrđuje veliki broj radova u ovoj oblasti. Postojeća rešenja za kompenzaciju nelinearne distorzije kod hibridnih *beamforming* mMIMO predajnika koriste metode zasnovane na polinomima, koje usled velikog broja pojačavača u ovim predajnicima dovode do povećane računarske kompleksnosti modela. Sa druge strane, neuralne mreže smanjuju kompleksnost modela za digitalnu predistorziju i uspešno su primenjene u modelovanju ponašanja pojačavača snage, kao i u digitalnoj predistorziji širokopoljanskih pojačavača. Polazeći od navedenih hipoteza, cilj istraživanja doktorske disertacije je realizacija i razvoj efikasnih modela za digitalnu predistorziju signala kod hibridnih *beamforming* mMIMO predajnika primenom neuralnih mreža.

Razvijanje efikasnog modela digitalne predistorzije primenom neuralnih mreža je kompleksan problem i zahteva da se u obzir uzmu različiti aspekti, kako iz oblasti digitalne predistorzije, tako i iz oblasti veštačkih neuralnih mreža. Shodno tome, istraživanje je sprovedeno u pet faza. U prvoj fazi je izvršeno proučavanje naučno-stručne literature iz oblasti digitalne predistorzije. Suština ove faze istraživanja je u sagledavanju postojećih rešenja digitalne predistorzije za HBF mMIMO predajnike, uz poseban osvrt na neke od mogućih problema pri primeni predloženih tehnika digitalne predistorzije u širokopoljanskim sistemima nove generacije koji predstavljaju izazov za dalje istraživanje. U drugoj fazi je izvršeno proučavanje naučno-stručne literature iz oblasti neuralnih mreža. U radu je analizirano nekoliko različitih modela neuralnih mreža u cilju pronalazanja optimalnog rešenja problema digitalne predistorzije za HBF mMIMO predajnik. Kao mera kvaliteta analiziranih rešenja računata je njihova kompleksnost, koja se može izraziti kroz broj koeficijenata potrebnih za konstrukciju modela, kao i kroz broj FLOP-ova (*FLoating point Operations Per Second*). U trećoj fazi su definisani različiti modeli digitalne predistorzije za HBF mMIMO predajnike primenom neuralnih mreža i izvršeno je poređenje njihovih mogućnosti linearizacije signala. Za procenu performansi modela korišćena su dva parametra: normalizovana

srednja kvadratna greška (*Normalized Mean-Square Error* – NMSE) i amplituda vektora greške (*Error Vector Magnitude* – EVM). Istraživanje je zasnovano na analizi digitalne predistorzije kod potpuno povezane (*Fully Connected* – FC) arhitekture hibridnog *beamforming* mMIMO predajnika, koja podrazumeva da je svaka antena povezana sa svakim od P RF lanaca. Povratna informacija za algoritam digitalne predistorzije uzimana je sa izlaza svih pojačavača snage, odnosno analiziran je *direct-end feedback* DPD algoritam. U četvrtoj fazi je izvršena implementacija predloženih modela u programskom paketu *Matlab* (R2021a). Na osnovu sprovedenih simulacija izvršena je njihova verifikacija i validacija smanjenja nelinearne distorzije koju unose pojačavači kod SU i MU hibridnih *beamforming* mMIMO predajnika primenom predloženih rešenja. U okviru pete faze izvršena je analiza dobijenih rezultata i definisani su dalji pravci istraživanja vezani za digitalnu predistorziju u mobilnim sistemima nove generacije.

Očekivani doprinos ove doktorske disertacije ogleda se u unapređenju efikasnosti kompenzacije nelinearne distorzije kod savremenih bežičnih predajnika, prvenstveno kod hibridnog *beamforming* mMIMO predajnika. Pored doprinosa u pogledu unapređenja efikasnosti kompenzacije nelinearne distorzije, značaj ovog istraživačkog rada ogleda se i u očekivanom sistematičnom pregledu postojeće literature u oblasti digitalne predistorzije signala u savremenim bežičnim sistemima.

Uzimajući u obzir da su tehnike digitalne predistorzije za mMIMO predajnike u fazi razvoja i da se konstantno vrši unapređivanje efikasnosti postojećih modela, kao i razvoj novih modela, očekuje se da dobijeni rezultati u okviru ove doktorske disertacije mogu naći široku primenu u digitalnoj predistorziji signala u savremenim bežičnim sistemima.

1.2 Struktura doktorske disertacije

Sprovedeno istraživanje, izloženo u okviru doktorske disertacije, sastoji se od teorijskog dela i simulacija u programskom paketu *Matlab*. U okviru teorijskog dela doktorske disertacije, analizirana je literatura iz oblasti digitalne predistorzije, sa posebnim osvrtom na postojeća rešenja za linearizaciju signala kod mMIMO predajnika, kao i iz oblasti neuralnih mreža, čija je primena u oblasti obrade signala, samim tim i u oblasti digitalne predistorzije, u sve većem porastu. Nakon sveobuhvatne teorijske analize literature i postojećih rešenja za digitalnu predistorziju kod mMIMO predajnika, predloženi su efikasni modeli digitalne predistorzije za hibridne *beamforming* mMIMO predajnike primenom neuralnih mreža i sprovedene su opsežne simulacije u kojima su ispitane performanse predloženih modela za digitalnu predistorziju.

U drugom poglavlju su opisani osnovni parametri pojačavača snage, njihove nelinearne karakteristike i distorzija koju unose. Opisane su osnovne tehnike linearizacije pojačavača, kao i najznačajniji modeli korišćeni za modelovanje ponašanja pojačavača. Takođe su izloženi osnovni parametri koji služe za određivanje kvaliteta signala, kao i metrike koje se koriste za procenu performansi i kompleksnosti modela koji se koriste za linearizaciju pojačavača. Na kraju poglavlja prikazani su postojeći modeli sa ograničenom širinom propusnog opsega za digitalnu predistorziju širokopojasnih signala. Ovo poglavlje predstavlja teorijski osnov za dalji istraživački rad.

U trećem poglavlju ukratko su opisani osnovni mehanizmi prostiranja signala kroz radio frekvencijski (RF) kanal, koji predstavljaju teorijsku osnovu za dalje razumevanje MIMO sistema. Izložen je model MIMO sistema, kao i najznačajniji matematički modeli radio kanala. Opisana je tehnika hibridnog *beamforming*-a, uključujući i opis različitih matematičkih algoritama za određivanje koeficijenata hibridnog *beamforming*-a. U ovom poglavlju izvršen je i poseban osvrt na problem linearizacije signala kod MIMO sistema, izloženi su i analizirani neki od postojećih DPD modela za MIMO predajnike.

U četvrtom poglavlju izložena je osnovna teorija neuralnih mreža (NN) relevantna za izradu doktorske disertacije. Dat je opis modela neurona i arhitekture neuralne mreže. Predstavljani su osnovni algoritmi učenja neuralnih mreža, proces treniranja neuralne mreže, kao i analiza performansi mreže. Ovo poglavlje je od ključnog teorijskog značaja u cilju primene neuralnih mreža na problem digitalne predistorzije koji predstavlja fokus ovog istraživačkog rada.

U petom poglavlju predloženi su različiti modeli neuralnih mreža za primenu u linearizaciji signala kod potpuno povezanog hibridnog *beamforming* mMIMO predajnika (SU FC HBF mMIMO). Predloženi modeli su implementirani u programskom paketu *Matlab*, izvršene su opsežne simulacije i analizirani su dobijeni rezultati. Predloženi NN DPD modeli su analizirani i upoređeni sa stanovišta kompleksnosti, posmatranjem broja koeficijenata neophodnih za realizaciju neuralne mreže i broja FLOP-ova. Izvršena je procena performansi predloženih NN DPD modela, međusobnim poređenjem spektralne gustine snage izlaznog signala, normalizovane srednje kvadratne greške, NMSE, i amplitude vektora greške, EVM.

U šestom poglavlju analizirana je mogućnost primene predloženog RVTDDNN2L DPD modela za linearizaciju signala kod potpuno povezanog hibridnog *beamforming* mMIMO predajnika sa više korisnika (MU FC HBF mMIMO). Predložena su dva tipa arhitekture DPD modela i data je analiza rezultata simulacija predloženih arhitektura u programskom paketu *Matlab*. Izložena je i analizirana kompleksnost i performanse različitih predloženih arhitektura RVTDDNN2L DPD modela, i izvedeni su zaključci o efikasnosti modela.

U sedmom poglavlju predložen je nov proširen RVTDDNN2L DPD model, u cilju postizanja boljih performansi, odnosno u cilju smanjenja normalizovane srednje kvadratne greške i amplitude vektora greške. Predložen model je testiran kroz kompleksne simulacije u programskom paketu *Matlab*. Analizirani su dobijeni rezultati i potvrđena je efikasnost predloženog modela.

U osmom poglavlju su data zaključna razmatranja i finalna analiza rezultata sprovedenog istraživačkog rada, uključujući i predloge za budući istraživački rad u oblasti digitalne predistorzije signala kod mMIMO predajnika.

2. POJAČAVAČI SNAGE

Pojačavač snage (*Power Amplifier* – PA) predstavlja značajnu komponentu u lancu bežičnog predajnika, čija je osnovna uloga povećanje snage signala koji ga pobuđuje, kako bi signal koji se prenosi imao dovoljnu snagu za prenos kroz RF kanal. Istovremeno, pojačavači predstavljaju i glavni izvor distorzije signala, i na taj način utiču na smanjenje efikasnosti prenosa. U ovom poglavlju prikazani su osnovni parametri pojačavača snage, njihove nelinearne transfer karakteristike, kao i tehnike linearizacije pojačavača snage čiji je cilj smanjenje izobličenja na izlazu pojačavača snage uz postizanje energetske efikasnosti. Posebno je analizirana digitalna predistorzija širokopojasnih signala.

2.1 Parametri pojačavača

Idealni pojačavač bi trebalo da ima linearnu transfer karakteristiku, tj. trebalo bi da su ulazni i izlazni napon povezani sledećom relacijom:

$$V_{OUT}(t) = k_1 \cdot V_{IN}(t), \quad (2.1)$$

gde je: k_1 – konstanta pojačanja napona pojačavača.

Realni pojačavač ima transfer karakteristiku koja se razlikuje od linearne po tome što postoji oblast saturacije, odnosno zasićenja, u kojoj pri porastu ulaznog napona izlazni napon ne raste ili veoma malo raste.

2.1.1 Pojačanje i propusni opseg

Jedan od osnovnih parametara pojačavača je njegovo pojačanje snage (*gain*), koje se definiše kao odnos izlazne i ulazne snage pojačavača. Izražava se u decibelima (dB) i dato je sledećom relacijom [32]:

$$G = 10 \log \frac{P_{OUT}}{P_{IN}}, \quad (2.2)$$

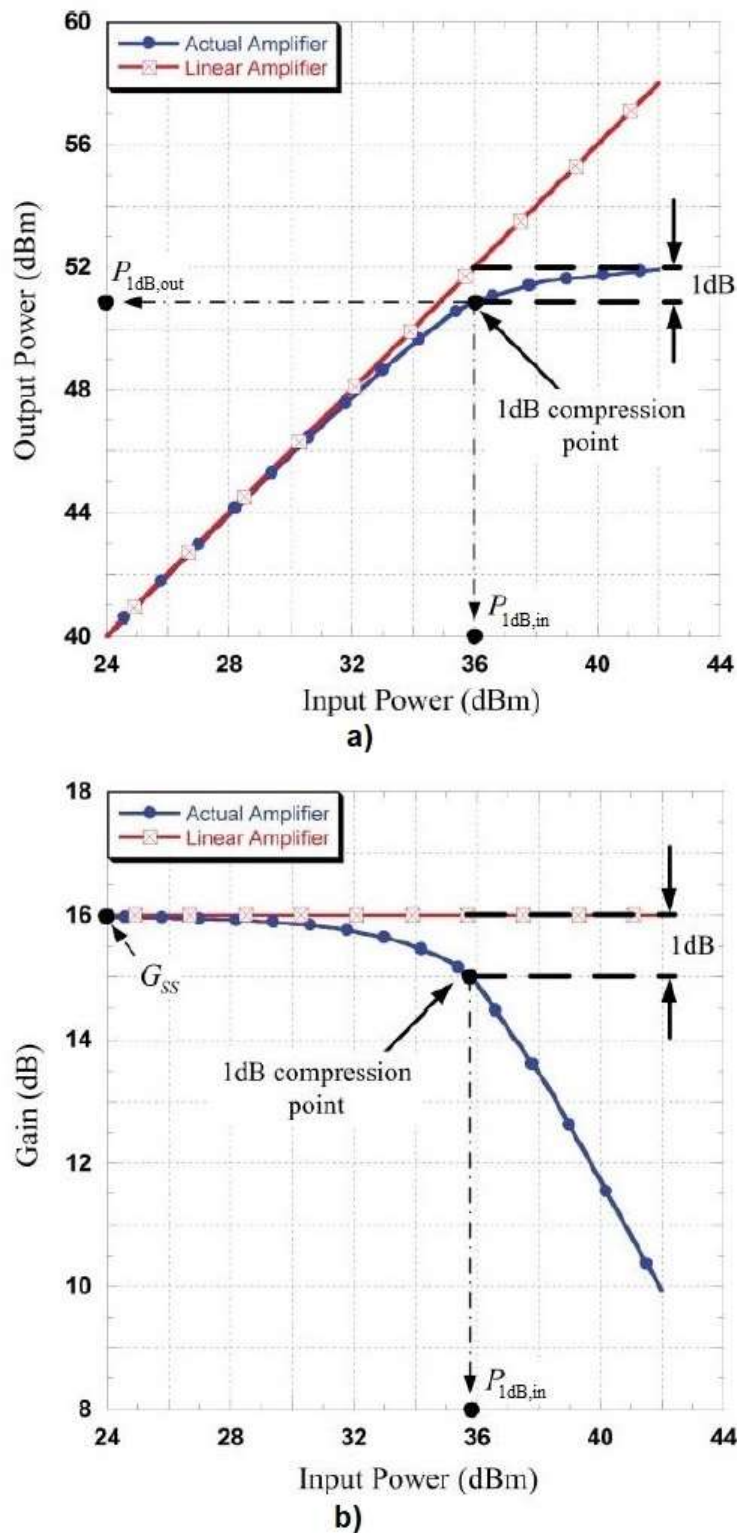
gde su: P_{IN} i P_{OUT} – ulazna i izlazna snaga pojačavača, respektivno.

Propusni opseg pojačavača predstavlja frekvencijski opseg u kom pojačavač ima zadovoljavajuće performanse. Najčešće se definiše kao razlika frekvencija, gornje i donje, pri kojima pojačanje snage opadne na polovinu svoje vršne vrednosti, odnosno za 3 dB.

2.1.2 Tačka kompresije IP1dB i IP3

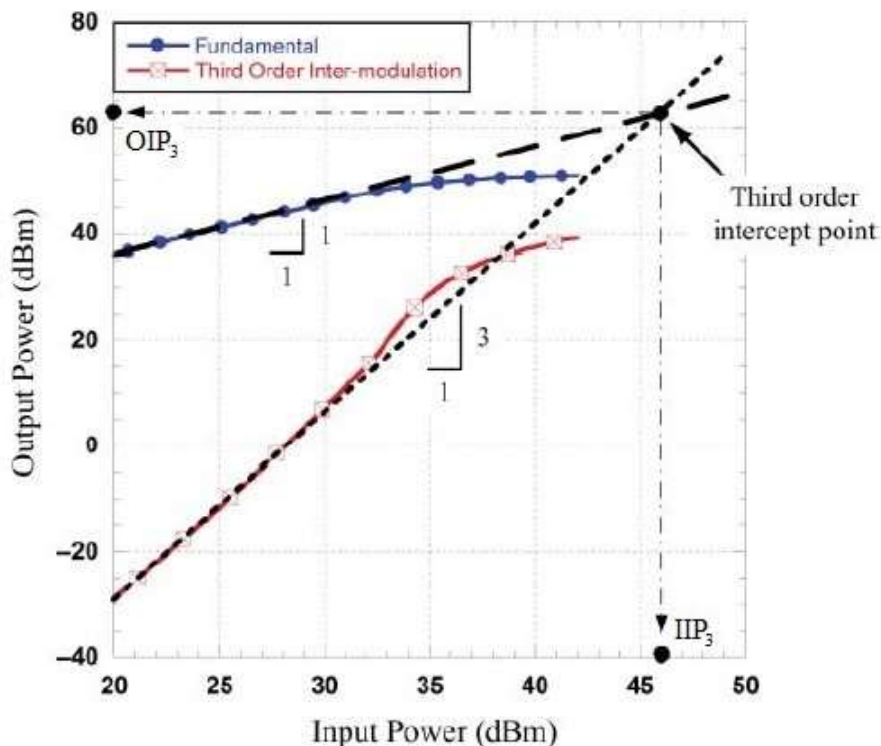
Parametri kojima se opisuje nelinearnost pojačavača su: tačka kompresije od 1 dB (*1 dB Compression Point* – P_{1dB}) i tačka preseka trećeg reda (*Third Order Intercept Point* – IP3).

Po definiciji P_{1dB} je izlazna snaga pojačavača pri kojoj pojačanje snage odstupa od pojačanja za male signale za 1 dB, tj. to je tačka na transfer karakteristici pojačavača, u kojoj je izlazna snaga pojačavača za 1 dB manja od izlazne snage kada bi pojačanje bilo konstantno. Ovo je ilustrovano na slici 2.1.



Slika 2.1 – Tačka kompresije 1 dB: a) karakteristika izlazne snage; b) karakteristika pojačanja [33].

IP3 je teoretska tačka koja predstavlja mesto preseka prave koja predstavlja željenu linearnu karakteristiku PA sa pravom koja predstavlja intermodulacione smetnje trećeg reda kada se na ulaz pojačavača dovedu dva signala na različitim frekvencijama. Kada se odnosi na ulaznu snagu označava se sa IIP3 (*Third Order Input Intercept Point*), a kada se odnosi na izlaznu snagu označava se sa OIP3 (*Third Order Output Intercept Point*) [33]. Ovo je ilustrovano na slici 2.2.



Slika 2.2 – Third Order Intercept Point [33].

2.1.3 Back-off i PAPR

Sledeći bitni parametri pojačavača su *back-off* i *Peak-to-Average Power Ratio* (PAPR).

Back-off predstavlja meru udaljenosti izlazne snage od izlazne snage saturacije, i sa njegovim povećanjem se povećava i linearnost pojačavača, i obrnuto. Postoje tri tipa *back-off*-a: *Input Back-Off* (IBO), *Output Back-Off* (OBO) i *Peak Back-Off* (PBO) [34]-[35].

IBO predstavlja odnos ulazne snage saturacije i srednje ulazne snage, i opisuje se sledećom relacijom:

$$IBO[dB] = 10 \log \frac{P_{i,sat}}{P_{i,mean}} = P_{i,sat}[dBm] - P_{i,mean}[dBm], \quad (2.3)$$

gde su: $P_{i,sat}$ i $P_{i,mean}$ – snaga saturacije i srednja snaga signala na ulazu pojačavača, respektivno.

OBO predstavlja odnos izlazne snage saturacije i srednje izlazne snage, i opisuje se sledećom relacijom:

$$OBO[dB] = 10 \log \frac{P_{o,sat}}{P_{o,mean}} = P_{o,sat}[dBm] - P_{o,mean}[dBm],$$

(2.4)

gde su: $P_{o,sat}$ i $P_{o,mean}$ – snaga saturacije i srednja snaga signala na izlazu pojačavača, respektivno.

PBO predstavlja odnos izlazne snage saturacije i vršne izlazne snage, i opisuje se sledećom relacijom:

$$PBO[dB] = 10 \log \frac{P_{o,sat}}{P_{o,peak}} = P_{o,sat}[dBm] - P_{o,peak}[dBm], \quad (2.5)$$

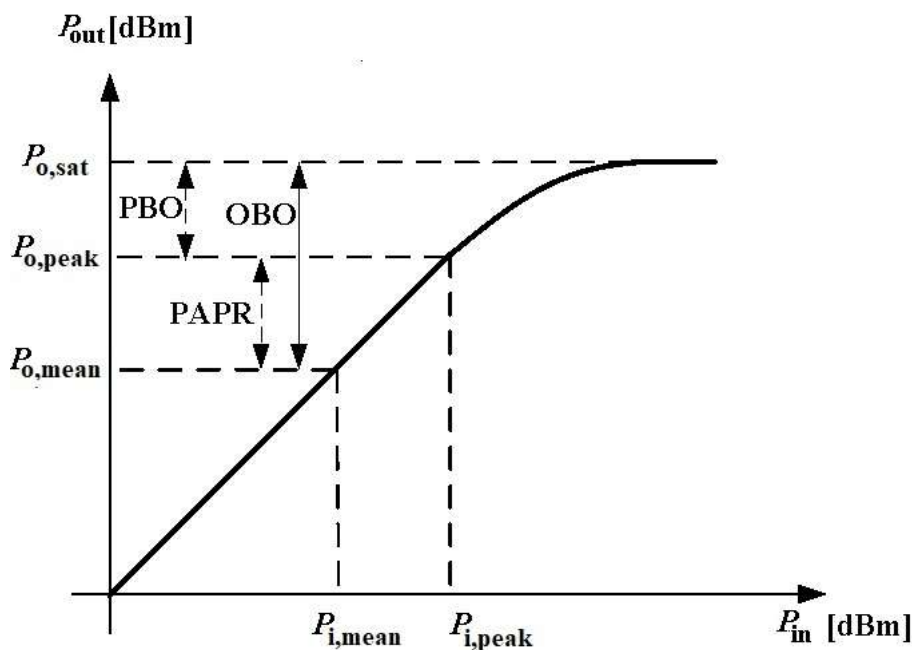
gde je: $P_{o,peak}$ – vršna snaga signala na izlazu pojačavača.

PAPR predstavlja odnos između vršne i srednje snage signala. Naziva se još i *crest* faktor, i dat je sledećom relacijom:

$$PAPR[dB] = 10 \log \frac{P_{peak}}{P_{mean}} = OBO - PBO, \quad (2.6)$$

gde su: P_{peak} i P_{mean} – vršna i srednja snaga signala, respektivno.

Na slici 2.3 je ilustrovan veza između OBO, PBO i PAPR.



Slika 2.3 – Odnos između OBO, PBO i PAPR.

2.1.4 Efikasnost

Sposobnost sistema da transformiše datu ulaznu snagu u korisnu izlaznu snagu naziva se energetska efikasnost i veoma je bitan parametar u svim sistema, a posebno u mobilnim sistemima nove generacije. Kako je pojačavač najveći potrošač snage u predajniku, on predstavlja dominantnu komponentu u određivanju ukupne energetske efikasnosti predajnika. U literaturi postoje tri definicije efikasnosti pojačavača snage: totalna efikasnost, *drain efficiency* i *Power Added Efficiency* (PAE).

Totalna efikasnost je definisana sledećom relacijom:

$$\eta_t = \frac{P_{\text{out}}}{P_{\text{DC}} + P_{\text{in}}}, \quad (2.7)$$

gde su: P_{out} , P_{DC} i P_{in} – snaga na izlazu pojačavača, *Direct Current* (DC) i RF snaga na ulazu pojačavača, respektivno.

Drain efficiency je definisana sledećom relacijom:

$$\eta_D = \frac{P_{\text{RFDrain}}}{P_{\text{DCDrain}}}, \quad (2.8)$$

gde su: P_{RFDrain} i P_{DCDrain} – DC i RF snaga na *drain* nivou tranzistora, respektivno.

PAE je najčešće korišćena efikasnost pojačavača, predstavlja količnik dodatne snage koju obezbeđuje pojačavač (razlika između RF izlazne i RF ulazne snage) i DC ulazne snage, i data je sledećom relacijom:

$$PAE = \frac{P_{\text{out}} - P_{\text{in}}}{P_{\text{DC}}}, \quad (2.9)$$

gde su: P_{out} , P_{in} i P_{DC} – snaga na izlazu pojačavača, RF i DC snaga na ulazu pojačavača, respektivno.

Efikasnost pojačavača raste sa porastom RF snage i maksimalna je kada pojačavač radi blizu saturacije, što za posledicu ima nelinearnu distorziju na izlazu pojačavača.

2.1.5 AM/AM i AM/PM karakteristike

Amplitude Modulation to Amplitude Modulation (AM/AM) karakteristika pojačavača predstavlja zavisnost amplitude izlaznog signala pojačavača od amplitude ulaznog signala pojačavača. Pomoću AM/AM karakteristike opisuje se kompresija anvelope signala u funkciji amplitude ulaznog signala, a njena distorzija je posledica nelinearnosti pojačavača.

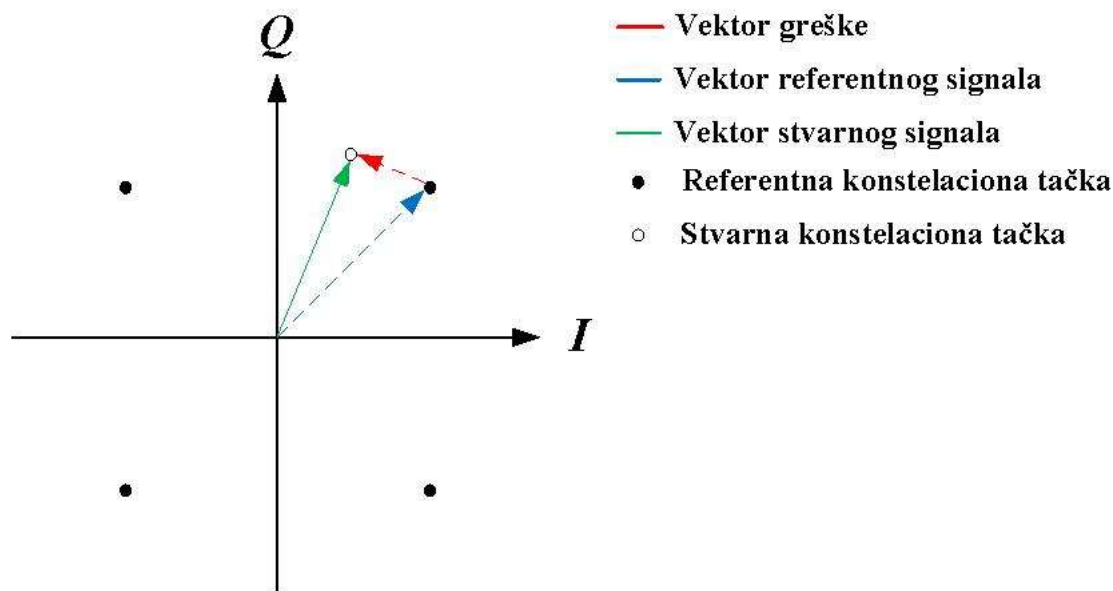
Amplitude Modulation to Phase Modulation (AM/PM) karakteristika pojačavača predstavlja zavisnost faze izlaznog signala pojačavača od amplitude ulaznog signala pojačavača. Pomoću AM/PM karakteristike opisuje se pomeraj faze izlaznog signala u funkciji ulaznog signala, a njena distorzija je posledica memorijskih efekata.

2.2 Parametri kvaliteta signala

Osnovni zadatak pojačavača je linearno pojačanje ulaznog signala do potrebnog nivoa izlazne snage, kako bi se prevazišli gubici do kojih dolazi pri prenosu signala kroz propagacioni medijum, pri čemu se teži postizanju maksimalne energetske efikasnosti. Nelinearnost koju unosi pojačavač pri radu možemo klasifikovati kao: statičku nelinearnost i memorijske efekte. Statička nelinearnost uzrokuje širenje spektra signala u frekvencijskom domenu i rotaciju i kompresiju konstelacije u vremenskom domenu. Memorijski efekti, poznati i kao dinamička distorzija, rezultuju asimetrijom spektra u frekvencijskom domenu i disperzijom konstelacija u vremenskom domenu, i mogu biti električni i termički [36].

2.2.1 EVM

Amplituda vektora greške (*Error Vector Magnitude* – EVM) predstavlja meru nelinearne distorzije u vremenskom domenu, kojom se određuje razlika između referentne konstelacione tačke, koja bi trebalo da se dobije u odsustvu distorzije, i stvarne konstelacione tačke, koja se dobija u prisustvu distorzije. Na slici 2.4 grafički je prikazan EVM u konstelacionom domenu.



Slika 2.4 – Grafički prikaz EVM u konstelacionom domenu.

EVM se definiše kao odnos snage vektora greške i snage referentnog vektora povezanog sa idealnom konstelacijom signala. Izražava se u dB i dat je sledećom relacijom:

$$EVM = 10 \log \frac{P_{\text{error}}}{P_{\text{ideal}}} = 10 \log \left(\text{mean} \left(\frac{(I_{\text{actual}} - I_{\text{ideal}})^2 + (Q_{\text{actual}} - Q_{\text{ideal}})^2}{I_{\text{ideal}}^2 + Q_{\text{ideal}}^2} \right) \right) \quad (2.10)$$

ili u procentima:

$$EVM(\%) = \sqrt{\frac{P_{\text{error}}}{P_{\text{ideal}}}} * 100\%, \quad (2.11)$$

gde su: P_{error} , P_{ideal} , I_{ideal} , I_{actual} , Q_{ideal} i Q_{actual} – snaga vektora greške, snaga referentnog vektora povezanog sa idealnom konstelacijom signala, komponenta u fazi (*in-phase*) idealnog izlaznog signala, komponenta u fazi (*in-phase*) izmerenog izlaznog signala, kvadratura komponenta (*quadrature*) idealnog izlaznog signala i kvadratura komponenta (*quadrature*) izmerenog izlaznog signala, respektivno.

2.2.2 ACPR

Odnos snage susednog kanala (*Adjacent Channel Power Ratio* – ACPR) predstavlja meru nelinearne distorzije predajnika kojom se određuje širenje spektra u susednim kanalima, odnosno nivo susednokanalne interferencije. Definiše se kao odnos snage u susednom opsegu i snage u glavnom opsegu signala:

$$ACPR = 10 \log \frac{P_{adj}}{P_{signal}}, \quad (2.12)$$


gde su: P_{adj} i P_{signal} – neželjeni nivo snage korisnog signala u susednom kanalu i snaga korisnog signala, respektivno.

2.3 Tehnike linearizacije pojačavača

Energetska efikasnost pojačavača je maksimalna kada pojačavač radi blizu oblasti zasićenja, što za posledicu ima distorziju signala na izlazu pojačavača. Da bi se proširilo linearno ponašanje pojačavača u oblasti visoke efikasnosti, u literaturi su predložene različite tehnike linearizacije [16], [32]-[40]. Neke od tehnika linearizacije pojačavača su: *feedback*, *feedforward*, *Linear Amplification using Nonlinear Components (LINC)*, predistorzija (*predistortion*),...

2.3.1 Feedback tehnika linearizacije

Kod *feedback* tehnike linearizacije vrši se modifikacija ulaznog signala, dovođenjem izlaznog signala sa pojačavača putem povratne petlje na ulaz u pojačavač. Trenutni izlazni signal služi za prilagođenje sledećeg ulaznog signala, tako što se vrši poređenje izlaznog signala sa željenim izlaznim signalom i određuje se signal greške koji se zatim oduzima od sledećeg ulaznog signala. Osnovni problem primene ove tehnike kod širokopojasnih sistema jeste u nestabilnosti povratne petlje, tj. javljaju se problemi sa kašnjenjem petlje. Blok šema *feedback* tehnike linearizacije data je na slici 2.5.



Slika 2.5 – Blok šema *feedback* tehnike linearizacije.

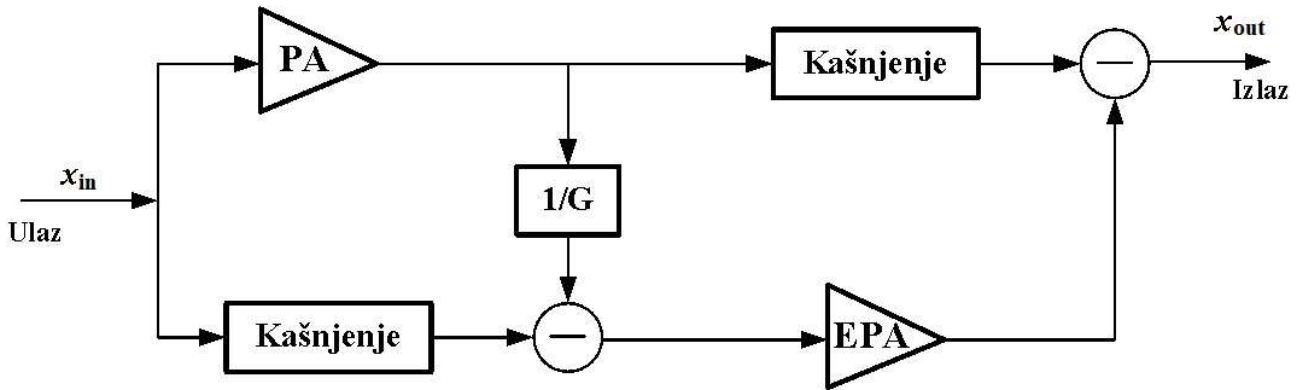
2.3.2 Feedforward tehnika linearizacije

Kod *feedforward* tehnike linearizacije vrši se korekcija signala na izlazu iz pojačavača i stoga ne dolazi do problema nestabilnosti petlje. Ulazni signal se deli na glavnu granu, u kojoj se signal pojačava, i granu u kojoj se vrši obrada izobličenja koje unosi pojačavač iz glavne grane. Generiše se signal greške, koji predstavlja razliku skalirane vrednosti izlaznog signala iz pojačavača i zakašnjenog ulaznog signala. Signal greške se zatim prolaskom kroz *Error Power Amplifier (EPA)* pojačava na originalni nivo na kom je bio signal na izlazu iz glavnog pojačavača snage i zatim se oduzima od zakašnjenog izlaza iz pojačavača snage. Problemi koji se javljaju su:

- uticaj glavnog pojačavača i pojačavača greške na ukupnu efikasnost,

- nelinearnost koju unosi pojačavač greške,
- nesavršenost u praćenju pojačanja i faze, tj. nepoklapanje pojačanja glavnog pojačavača i pojačavača greške,
- nepoklapanje elemenata za kašnjenje u glavnoj grani i grani za obradu izobličenja.

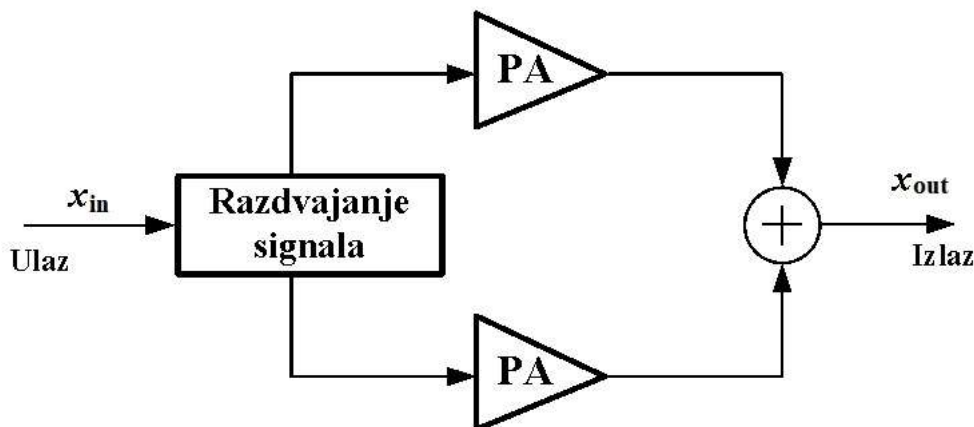
Blok šema *feedforward* tehnike linearizacije data je na slici 2.6.



Slika 2.6 – Blok šema *feedforward* tehnike linearizacije.

2.3.3 LINC tehnika linearizacije

Kod LINC tehnike linearizacije se ulazni signal razdvaja na dva signala konstantne anvelope, čija fazna razlika sadrži informaciju o amplitudi. Ova dva signala se zatim pojačavaju sa dva pojačavača istih karakteristika i zatim se kombinuju kako bi se dobio krajnji izlazni signal. Najveći problem u implementaciji je kako izvršiti razdvajanje i sumiranje signala bez gubitaka. Blok šema LINC tehnike linearizacije data je na slici 2.7.

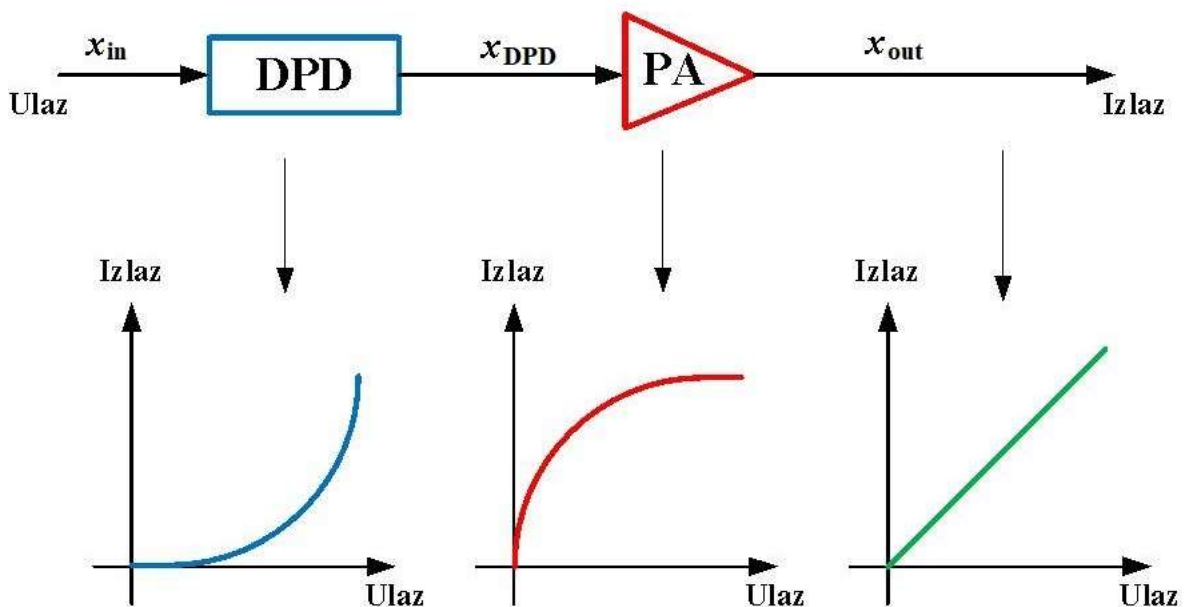


Slika 2.7 – Blok šema LINC tehnike linearizacije.

2.3.4 Predistorzija

Osnovni princip tehnike predistorzije je uvođenje dodatnog bloka pre pojačavača, koji se naziva predistorter i čija je nelinearna transfer funkcija inverzna transfer funkciji pojačavača, tako da kaskadna veza predistortera i pojačavača ima linearan odziv. U zavisnosti od načina realizacije predistortera, tehnike predistorzije se dele na: analogne (*Analog Radio Frequency Predistortion – ARFPD*) i digitalne (*Digital Predistortion – DPD*). DPD je bolja, jer može da isprati promene parametara pojačavača koje su posledica promene temperaturnih uslova, starenja komponenti,... Može se u potpunosti implementirati pomoću digitalnih procesora (*Digital Signal Processing – DSP*), čime se omogućava lako ažuriranje funkcije predistorzije, tako da predstavlja najefikasniju i najperspektivniju tehniku linearizacije za buduće komunikacione sisteme [36].

Moguće je komplementarnu nelinearnu funkciju uvesti i nakon pojačavača, tj. umesto predistortera uvesti postdistorter. U tom slučaju se obrada signala vrši pri visokim vrednostima snage, što rezultuje velikom potrošnjom energije i smanjuje ukupnu efikasnost sistema [39]. Blok šema DPD tehnike linearizacije data je na slici 2.8.



Slika 2.8 – Blok šema DPD tehnike linearizacije.

2.4 Modelovanje ponašanja pojačavača

Ključan korak u digitalnoj predistorziji predstavlja modelovanje ponašanja (*behavioural modeling*), kojim se određuje ponašanje nelinearne komponente sistema. Osnovna ideja modelovanja ponašanja je da se nelinearna komponenta, koja se naziva još i *Device Under Test (DUT)*, posmatra kao crna kutija, i da se pronađe matematička formulacija veze između ulaza i izlaza DUT-a [41]. Značaj ovakvog pristupa je u tome što nije potrebno nikakvo poznavanje fizičke strukture i funkcionalnosti RF komponente. Osim toga, značaj modelovanja ponašanja je i u tome što se predistorzija može posmatrati kao problem modelovanja ponašanja. Naime, sinteza funkcije predistorzije je analogna modelovanju inverzne funkcije pojačavača. Performanse modelovanja ponašanja zavise od dva aspekta: posmatranja (*observation*) i formulacije (*formulation*). Posmatranje podrazumeva tačno određivanje signala na ulazu i izlazu DUT-a. Formulacija

predstavlja pronalaženje odgovarajuće matematičke formule koja opisuje značajne interakcije između signala na ulazu i izlazu DUT-a.

U literaturi su predstavljeni različiti matematički modeli kojima se modeluje ponašanje pojačavača i formira funkcija predistorzije, koji se mogu podeliti u tri grupe:


- modeli zasnovani na tabeli za traženje (*Look-Up Table – LUT*),
- polinomijalni modeli,
- modeli zasnovani na neuralnim mrežama (*Neural Network – NN*).

2.4.1 LUT model

LUT model [41] je osnovni model ponašanja pojačavača bez memorije. Izlazni signal LUT modela dat je sledećom relacijom:

$$x_{\text{out}}(n) = G(|x_{\text{in}}(n)|) \cdot x_{\text{in}}(n), \quad (2.13)$$

gde su: x_{in} i x_{out} – talasni oblici ulaznog i izlaznog signala, respektivno. $G(x_{\text{in}}(n))$ je trenutno kompleksno pojačanje DUT-a, čije se vrednosti čuvaju u dve *look-up* tabele. Blok šema LUT modela prikazana je na slici 2.9.



Slika 2.9 – Blok šema LUT modela.

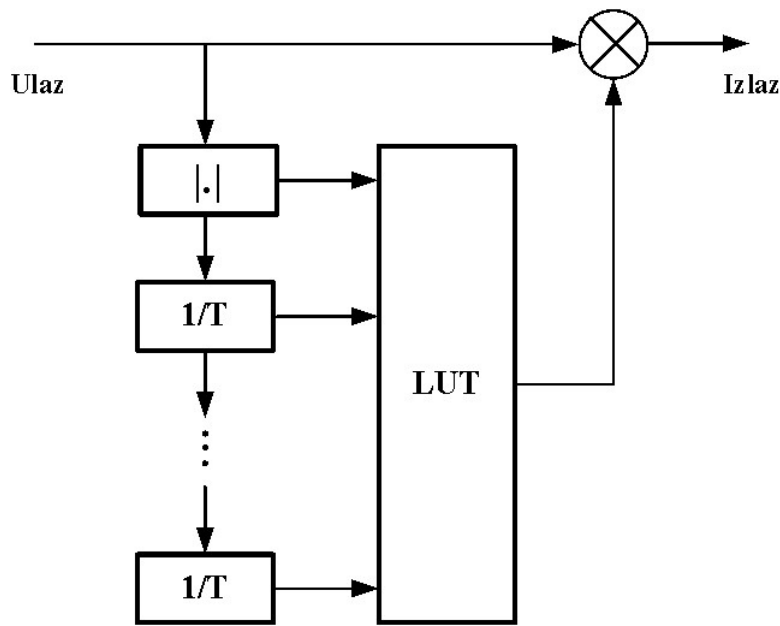
Ugnežđeni LUT model [41] predstavlja poboljšanje konvencionalnog LUT modela, uključivanjem modelovanja memorijskih efekata. Ovo je postignuto time što trenutno pojačanje DUT-a više nije funkcija samo trenutnog ulaznog odbiraka $x(n)$, već i $M - 1$ prethodnih ulaznih odbiraka $[x(n - 1), x(n - 2), \dots, x(n - M)]$, gde je M dubina memorije DUT-a. Sada je veličina LUT-a K^{M+1} , gde je K broj zahtevanih mesta u LUT modelu bez memorije. Izlazni signal dat je sledećom relacijom:

$$x_{\text{out}}(n) = G(|X_{\text{in}}(n)|) \cdot x_{\text{in}}(n), \quad (2.14)$$

gde je: $G(X_{\text{in}}(n))$ trenutno kompleksno pojačanje DUT-a. $X_{\text{in}}(n)$ je ulazni vektor koji sadrži trenutni i $M - 1$ prethodnih ulaznih odbiraka i definiše se sledećom relacijom:

$$X_{\text{in}}(n) = [x_{\text{in}}(n), x_{\text{in}}(n - 1), \dots, x_{\text{in}}(n - M)]. \quad (2.15)$$

Blok šema ugnežđenog LUT modela prikazana je na slici 2.10.




Slika 2.10 – Blok šema ugnježdenog LUT modela.

2.4.2 Volterra model

Volterra model [41] je najopštiji model za dinamičke nelinearne sisteme. Izlazni signal je dat sledećom relacijom:

$$x_{\text{out}}(n) = \sum_{k=1}^K \sum_{i_1=0}^M \dots \sum_{i_p=0}^M h_p(i_1, \dots, i_p) \prod_{j=1}^k x_{\text{in}}(n - i_j), \quad (2.16)$$

gde su: $h_p(i_1, \dots, i_p)$, K , M - parametri Volterra modela, red nelinearnosti i dubina memorije, respektivno. Blok šema Volterra modela prikazana je na slici 2.11.



Slika 2.11 – Blok šema Volterra modela.

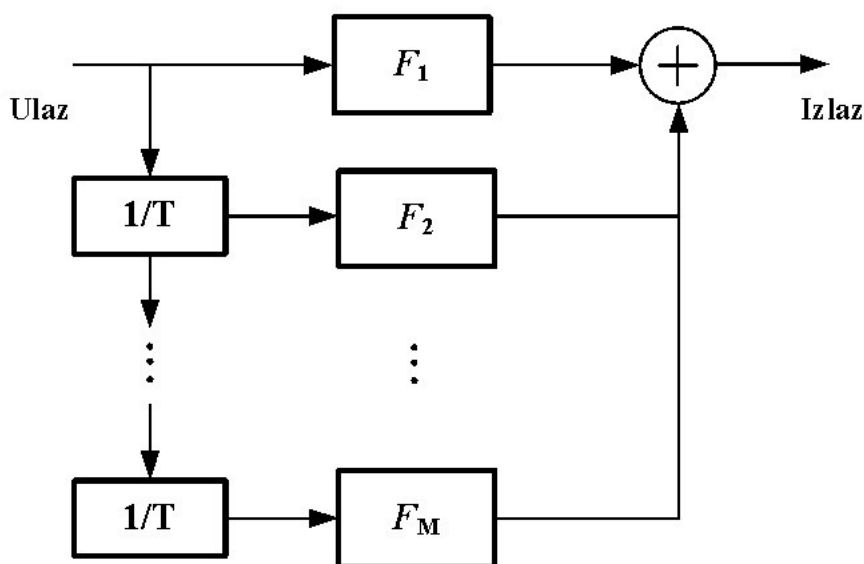
Broj parametara *Volterra* modela se drastično povećava sa povećanjem reda nelinearnosti i dubine memorije, što ograničava primenu ovog modela na slabo nelinearne sisteme sa niskim redom nelinearnosti. U literaturi je predloženo nekoliko tehnika za smanjenje kompleksnosti *Volterra* modela, među kojima su tehnike odsecanja (*pruning techniques*) [42] i tehnike smanjenja dinamičkog odstupanja (*dynamic deviation reduction technique*) [43].

2.4.3 Memory Polynomial model

Memory Polynomial (MP) model [41] je najčešće korišćen model za modelovanje ponašanja i digitalnu predistorziju pojačavača sa memorijskim efektom, i odgovara redukciji *Volterra* modela u kojoj su zadržani samo dijagonalni članovi. Izlazni signal je dat sledećom relacijom:

$$x_{\text{out}}(n) = \sum_{m=0}^M \sum_{k=1}^K a_{mk} \cdot x_{\text{in}}(n-m) \cdot |x_{\text{in}}(n-m)|^{k-1}, \quad (2.17)$$

gde su: a_{mk} , K , M - parametri modela, red nelinearnosti i dubina memorije, respektivno. Blok šema MP modela prikazana je na slici 2.12.



Slika 2.12 – Blok šema MP modela.

U literaturi je predloženo nekoliko varijacija MP modela, među kojima su: *Envelope* MP model [41], ortogonalni MP model [44] i generalizovani MP model [45].

Envelope MP model predstavlja kombinaciju MP modela i ugneždenog LUT modela, pri čemu je izlazni signal dat sledećom relacijom:

$$x_{\text{out}}(n) = \sum_{m=0}^M \sum_{k=1}^K a_{mk} \cdot x_{\text{in}}(n) \cdot |x_{\text{in}}(n-m)|^{k-1}, \quad (2.18)$$

gde su: a_{mk} , K , M - parametri modela, red nelinearnosti i dubina memorije, respektivno. Izdvajanjem trenutnog kompleksnog pojačanja:

$$G(X_{in}(n)) = \sum_{m=0}^M \sum_{k=1}^K a_{mk} \cdot |x_{in}(n-m)|^{k-1}, \quad (2.19)$$

relacija (2.17) svodi se na ugnežđen LUT model.

Kod generalizovanog MP modela su uvedeni unakrsni članovi koji su rezultat kombinovanja trenutnog kompleksnog signala sa komponentama koje prednjače (*leading terms*) i komponentama koje kasne (*lagging terms*). Kao rezultat, dobija se izlazni signal dat sledećom relacijom:

$$\begin{aligned} x_{out}(n) = & \sum_{k=0}^{K_a-1} \sum_{l=0}^{L_a-1} a_{kl} \cdot x_{in}(n-l) \cdot |x_{in}(n-l)|^k \\ & + \sum_{k=1}^{K_b} \sum_{l=0}^{L_b-1} \sum_{m=1}^{M_b} b_{klm} \cdot x_{in}(n-l) \cdot |x_{in}(n-l-m)|^k \\ & + \sum_{k=1}^{K_c} \sum_{l=0}^{L_c-1} \sum_{m=1}^{M_c} c_{klm} \cdot x_{in}(n-l) \cdot |x_{in}(n-l+m)|^k, \end{aligned} \quad (2.20)$$

gde su: K_a, L_a – broj koeficijenata poravnatog signala i envelope, K_b, L_b, M_b – broj koeficijenata signala i zakasnele envelope, K_c, L_c, M_c – broj koeficijenata signala i envelope koja prednjači.

2.4.4 Wiener model


Wiener model [41] se sastoji od dva bloka: linearnog filtra konačnog impulsnog odziva (*Finite Impulse Response – FIR*), za kojim sledi statička nelinearna funkcija bez memorije. Izlazni signal je dat sledećom relacijom:

$$x_{out}(n) = G(|x_1(n)|) \cdot x_1(n), \quad (2.21)$$

gde je: $G(|x_1(n)|)$ – funkcija kompleksnog trenutnog pojačanja bez memorije implementirana pomoću LUT modela. Izlaz FIR filtra $x_1(n)$ dat je sledećom relacijom:

$$x_1(n) = \sum_{j=0}^M h(j) \cdot x_{in}(n-j), \quad (2.22)$$

pri čemu je: $h(j)$ – impulсни odziv FIR filtra, a M dubina memorije. Blok šema *Wiener* modela prikazana je na slici 2.13. Kod ovog modela se u prvom koraku određuje statička nelinearna funkcija (LUT), a zatim se na osnovu ulaznog i izlaznog signala iz FIR filtra određuju koeficijenti filtra.




Slika 2.13 – Blok šema *Wiener* modela.

Linearni FIR filter u *Wiener* modelu uzima u obzir frekvencijski odziv u okolini frekvencije nosioca (linearna distorzija), ali ne i izvore nelinearne distorzije parnog reda. Zato nije dovoljno da se ova slaba nelinearnost modeluje linearnim filtrom, i kod uvećanog *Wiener* (*Augmented Wiener*) modela [41] se dodaje paralelna grana FIR filtru. U paralelnoj grani, ulazni signal $x_{in}(n)$ pomnožen svojom amplitudom $|x_{in}(n)|$ se dovodi na drugi FIR filter. Na ovaj način, linearan filter kod konvencionalnog *Wiener* modela je zamenjen sa slabo nelinearnim dinamičkim FIR filtrom, a članovi drugog reda su uključeni u dinamički model memorijskih efekata, kako bi njihovo modelovanje bilo tačnije. Izlazni signal je dat relacijom (2.21), dok je međusignal $x_1(n)$ dat sledećom relacijom:

$$x_1(n) = \sum_{j_1=0}^{M_1} h_1(j_1) \cdot x_{in}(n - j_1) + \sum_{j_2=0}^{M_2} h_2(j_2) \cdot x_{in}(n - j_2) \cdot |x_{in}(n - j_2)|, \quad (2.23)$$

pri čemu su: $h_1(j_1)$, $h_2(j_2)$ – impulsni odzivi filtera FIR1 i FIR2, respektivno, a M_1 i M_2 – dubine memorije prvog i drugog filtera, respektivno. Blok šema uvećanog *Wiener* modela prikazana je na slici 2.14. Identifikacija parametara uvećanog *Wiener* modela se radi u dva koraka, slično kao kod klasičnog *Wiener* modela.



Slika 2.14 – Blok šema uvećanog *Wiener* modela.

2.4.5 *Hammerstein* model

Hammerstein model [41] se, takođe, sastoji od dva bloka: podsistema sa statičkom nelinearnošću bez memorije, za kojim sledi podsistem sa dinamičkom linearnošću. Izlazni signal je dat sledećom relacijom:


$$x_{out}(n) = \sum_{j=0}^M h(j) \cdot x_1(n - j), \quad (2.24)$$

gde je: $h(j)$ – impulsni odzivi FIR filtra, M – dubina memorije, a $x_1(n)$ – izlaz LUT bloka dat sledećom relacijom:

$$x_1(n) = G(|x_{in}(n)|) \cdot x_{in}(n), \quad (2.25)$$

pri čemu je: G – funkcija kompleksnog trenutnog pojačanja bez memorije implementirana pomoću LUT modela. Blok šema *Hammerstein* modela prikazana je na slici 2.15. Identifikacija parametara *Hammerstein* modela je slična kao kod *Wiener* modela, prvo se identifikuje LUT model, a zatim

koeficijenti filtra. Može se primetiti da *Hammerstein* i *Wiener* modeli mogu međusobno da formiraju inverzne strukture, ako njihovi linearni filtri imaju stabilne inverzije i ako su njihove nelinearne polinomijalne funkcije inverzne jedan-na-jedan u opsegu od interesa.




Slika 2.15 – Blok šema Hammerstein modela.

Kao i kod klasičnog *Wiener* modela, klasičan *Hammerstein* model koriguje samo linearnu distorziju, ali ne i izvore nelinearne distorzije parnog reda. Zato dinamički FIR filter kod uvećanog *Hammerstein* modela [41], kao i kod uvećanog *Wiener* modela, ima dodatnu paralelnu granu koja se dodaje linearnom FIR filtru. U ovoj paralelnoj grani, ulazni signal $x_{in}(n)$ se množi sa svojom amplitudom $|x_{in}(n)|$ da bi se generisala distorzija drugog reda koja će biti primenjena na drugi filter. Izlazni signal je dat sledećom relacijom:

$$x_1(n) = \sum_{j_1=0}^{M_1} h_1(j_1) \cdot x_1(n - j_1) + \sum_{j_2=0}^{M_2} h_2(j_2) \cdot x_1(n - j_2) \cdot |x_1(n - j_2)|, \quad (2.26)$$

gde su: $h_1(j_1)$, $h_2(j_2)$ – impulsi odzivi filtera FIR1 i FIR2, respektivno, M_1 i M_2 – dubine memorije prvog i drugog filtera, respektivno, a $x_1(n)$ – izlaz LUT bloka dat relacijom (2.25). Blok šema uvećanog *Hammerstein* modela prikazana je na slici 2.16. Identifikacija parametara uvećanog *Hammerstein* modela se radi u dva koraka, slično kao kod klasičnog *Hammerstein* modela.



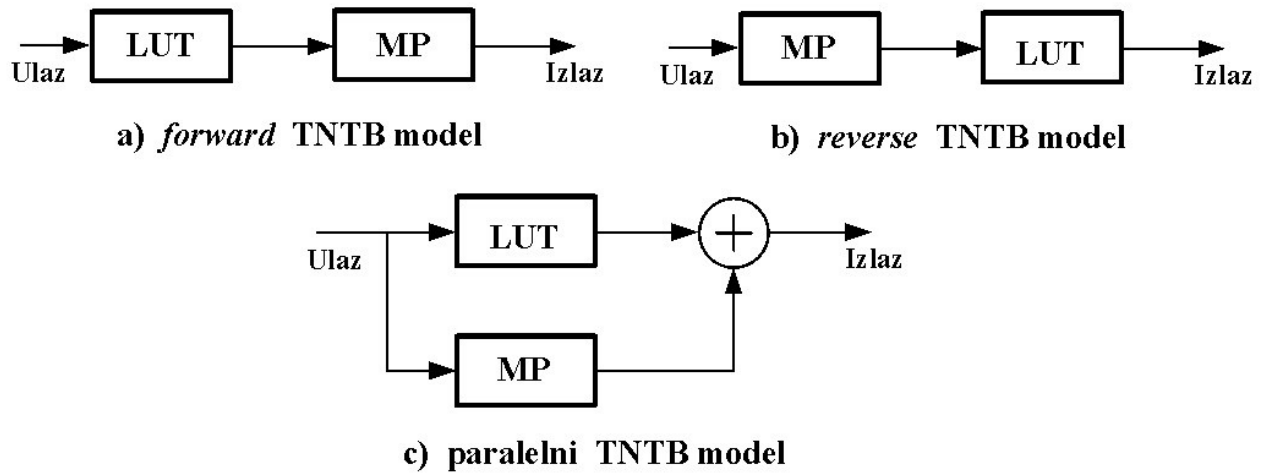
Slika 2.16 – Blok šema uvećanog Hammerstein modela.

2.4.6 Twin Nonlinear Two-Box modeli

Twin Nonlinear Two-Box (TNTB) modeli [41] pripadaju klasi modela sa dva bloka, i sastoje se od statičke nelinearne funkcije bazirane na LUT modelu i dinamičke MP nelinearne funkcije. U zavisnosti od konfiguracije, tj. rasporeda ovih blokova, razlikuju se:

- *forward* model (LUT se primenjuje pre MP funkcije),
- *reverse* model (MP funkcija se primenjuje pre LUT modela),
- paralelni model (LUT i MP funkcija se primenjuju istovremeno na ulazni signal).

Za svaki od ovih modela, zavisnost izlaznog signala od ulaznog se izvodi kao odgovarajuća kombinacija jednakosti (2.13) i (2.17). Blok šeme TNTB modela prikazane su na slici 2.17.



Slika 2.17 – Blok šema TNTB modela: a) forward; b) reverse; c) paralelni.

2.5 Procena performansi modela

Za utvrđivanje tačnosti modelovanja ponašanja pojačavača koriste se različite metrike u vremenskom i frekvencijskom domenu. Najčešće korišćene metrike su srednja kvadratna greška (*Mean Squared Error – MSE*), normalizovana srednja kvadratna greška (*Normalised Mean Squared Error – NMSE*) i odnos snage susednog kanala (*Adjacent Channel Power Ratio – ACPR*).

2.5.1 MSE

Srednja kvadratna greška (*Mean Squared Error – MSE*) predstavlja metriku u vremenskom domenu kojom se vrši procena tačnosti modelovanja ponašanja predajnika. Izražava se u dB i data je sledećom relacijom:

$$MSE = 10 \log \left(\frac{1}{K} \sum_{n=1}^K |y_{\text{meas}}(n) - y_{\text{est}}(n)|^2 \right), \quad (2.27)$$

gde su: y_{meas} i y_{est} – izmereni i procenjeni talasni oblici izlaznog signala, respektivno, K – broj odbiraka izlaznog talasnog oblika signala.

2.5.2 NMSE

Da bi mogli da se porede sistemi sa različitim nivoima snage, uvedena je normalizovana srednja kvadratna greška (*Normalised Mean Squared Error – NMSE*) koja se računa po sledećoj formuli:

$$NMSE = 10 \log \left(\frac{\sum_{n=1}^K |y_{\text{meas}}(n) - y_{\text{est}}(n)|^2}{\sum_{n=1}^K |y_{\text{meas}}(n)|^2} \right), \quad (2.28)$$

gde su: y_{meas} i y_{est} – izmereni i procenjeni talasni oblici izlaznog signala, respektivno, K – broj odbiraka izlaznog talasnog oblika signala.

2.5.3 ACPR

Odnos snage susednog kanala (*Adjacent Channel Power Ratio* – ACPR) predstavlja metriku u frekvencijskom domenu kojom se meri količina snage koja “iscuri” u susedni kanal. Ova vrednost predstavlja meru spektralnog širenja signala na susedne, bočne kanale. Definiše se kao odnos snage signala u susednom kanalu i snage signala u glavnom kanalu, i to za oba bočna kanala, levi i desni, korišćenjem sledećih formula:

$$ACPR_{\text{left}} = \frac{\int_{f_c - \Delta f - \frac{B}{2}}^{f_c - \Delta f + \frac{B}{2}} PSD(f) df}{\int_{f_c - \frac{B}{2}}^{f_c + \frac{B}{2}} PSD(f) df}, \quad (2.29)$$

$$ACPR_{\text{right}} = \frac{\int_{f_c + \Delta f - \frac{B}{2}}^{f_c + \Delta f + \frac{B}{2}} PSD(f) df}{\int_{f_c - \frac{B}{2}}^{f_c + \frac{B}{2}} PSD(f) df}, \quad (2.30)$$

gde je: f_c – centralna frekvencija kanala, Δf – frekvencijski pomeraj susednog kanala, B – širina propusnog opsega signala, $PSD(f)$ – spektralna gustina snage signala.

U literaturi se koristi i ukupna vrednost ACPR, definisana kao odnos ukupne snage u oba susedna kanala i snage u glavnom kanalu:

$$ACPR = \frac{\int_{f_c - \Delta f - \frac{B}{2}}^{f_c - \Delta f + \frac{B}{2}} PSD(f) df + \int_{f_c + \Delta f - \frac{B}{2}}^{f_c + \Delta f + \frac{B}{2}} PSD(f) df}{\int_{f_c - \frac{B}{2}}^{f_c + \frac{B}{2}} PSD(f) df}. \quad (2.31)$$

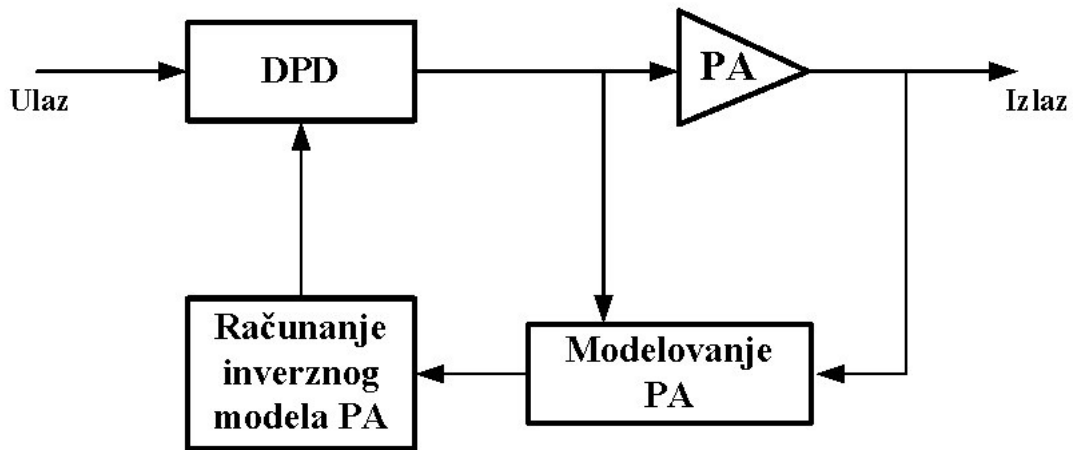
2.6 Određivanje koeficijenata DPD modela

U literaturi je predloženo više različitih pristupa za određivanje koeficijenata digitalnog predistortera. Većina njih se zasniva na nekoj od sledeće dve metode:

- metoda direktnog učenja (*Direct Learning Architecture* – DLA),
- metoda indirektnog učenja (*Indirect Learning Architecture* – ILA).

2.6.1 DLA metoda

Kod DLA metoda [34] se prvo određuje model pojačavača, a zatim se funkcija predistortera računa inverzijom modela pojačavača. Blok šema DLA metode je prikazana na slici 2.18.

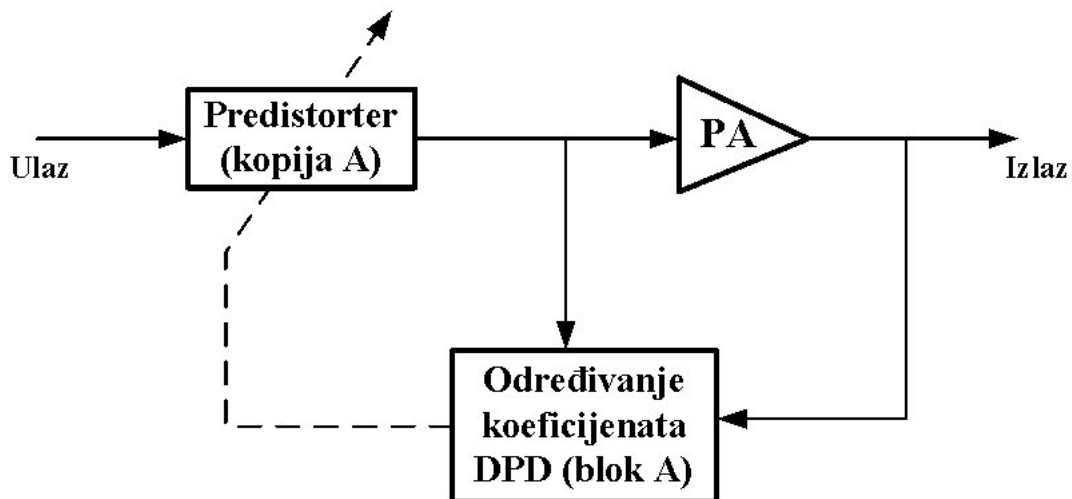


Slika 2.18 – Blok šema DLA metode.

DLA metoda pokazuje dobre performanse, međutim ima veliku računsku kompleksnost i sporo konvergira.

2.6.2 ILA metoda

Kako bi se smanjila kompleksnost DLA metoda, razvijen je ILA metod, kod koga se koeficijenti direktno određuju na osnovu izlaznih i ulaznih signala u pojačavač, a zatim se tako određeni koeficijenti kopiraju u predistorter [34]. Prednost ILA je što nije potrebna pretpostavka modela pojačavača, estimacija njegovih parametara i inverzna konstrukcija. Blok šema ILA metode je prikazana na slici 2.19. Na osnovu ulaznog i izlaznog signala pojačavača, određuju se parametri bloka A. Kako predistorter predstavlja kopiju funkcije bloka A, određivanjem njegove funkcije dolazi se i do funkcije predistorzije.



Slika 2.19 – Blok šema ILA metode.

2.7 Procena kompleksnosti DPD modela

Kako bi se ocenila efikasnost određenog modela, nije dovoljno samo uzeti u obzir njegove performanse, već je potrebno odrediti i kompleksnost modela pri kojoj se te performanse dostižu. Najjednostavnija procena kompleksnosti modela može se izvršiti razmatranjem broja neophodnih koeficijenata za matematičko predstavljanje modela. Drugi pristup je procena računarske kompleksnosti modela, koja se može izvršiti na osnovu broja FLOP-ova (*FLOating point Operations Per Second*). Ovaj broj predstavlja meru za broj i tip računarskih operacija, i stoga predstavlja relevantan parametar za predstavljanje kompleksnosti i poređenje različitih modela. Potreban broj FLOP-ova za određene računarske operacije prikazan je u tabeli 2.1 [46].

Tabela 2.1 – Potreban broj FLOP-ova za određene računarske operacije [46].

Operacija	Broj FLOP-ova
Konjugovanje	0
Kašnjenje	0
Sabiranje realnih brojeva	1
Množenje realnih brojeva	1
Sabiranje kompleksnih brojeva	2
Množenje kompleksnog i realnog broja	2
$ \cdot ^2$	3
Množenje kompleksnih brojeva	6

2.8 DPD modeli sa ograničenom širinom propusnog opsega

Kako bi se kompenzovala distorzija signala usled širenja spektra, potrebno je da širina propusnog opsega kod DPD sistema bude minimum pet puta veća od širine signala koji se prenosi. Razlog za to leži u činjenici da većina signala koji se analiziraju u bloku za predistorziju, pored osnovne komponente sadrži i intermodulacione proizvode trećeg i petog reda [41]. Ovo ne predstavlja problem kada se posmatraju uskopojasni signali. Međutim, kod širokopojasnih signala koji se prenose u mobilnim sistemima nove generacije, javlja se potreba za korišćenjem A/D konvertora sa velikim brzinama odabiranja. Primera radi, za signal širine 500 MHz, zahtevana širina propusnog opsega je 2500 MHz, što uz vrednost *roll-of* faktora od 0.28, dovodi do brzine odabiranja konvertora od 3200 Msps [47]. Ovakvi konvertori su izuzetno skupi i predstavljaju energetska neisplativo rešenje. Veliki broj istraživača se posvetio problemu realizacije širokopojasnog DPD modela sa A/D konvertorom male brzine (*low-speed A/D converter*) i u literaturi postoji veliki broj radova koji se bave ovom problematikom [47]-[61].

Kod prvog predloženog *band-limited* DPD modela, *band-limiting* funkcija je ubačena u *Volterra* operator u DPD modelu [48]-[49]. Za realizaciju *band-limiting* funkcije korišćen je *low-pass complex equiripple* FIR filter propusnog opsega 40 MHz. Prikazana teorijska analiza i eksperimentalni rezultati pokazali su da se primenom predložene tehnike značajno poboljšavaju performanse sistema, smanjuju troškovi implementacije i eliminišu ograničenja vezana za propusni opseg sistema. Zatim je usledio niz radova u kojima je primenjeno ograničavanje širine propusnog opsega na različite modele DPD sistema. U [52] je predložen metod određivanja DPD koeficijenata metodom direktnog učenja sa ograničenom širinom propusnog opsega u povratnoj grani; u [53] je

predstavljen DPD model sa ograničenom širinom propusnog opsega u povratnoj grani, kod koga se za određivanje parametara pojačavača koristi MP model; dok je u [54] za određivanje parametara pojačavača u DPD modelu sa ograničenom širinom opsega u povratnoj grani korišćen *Parallel Twin Nonlinear Two-Box* (PTNTB) model i algoritam indirektnog učenja. Rezultati dobijeni u [55], gde je korišćena spektralna ekstrapolacija signala sa ograničenom širinom propusnog opsega u povratnoj grani, pokazali su da širina propusnog opsega u povratnoj grani može da bude i manja od širine signala i da se i dalje dobiju zadovoljavajuće performanse sistema. Dalje smanjenje brzine odabiranja uz zadržavanje dobrih performansi, u odnosu na metod spektralne ekstrapolacije, postignut je korišćenjem metoda sa smanjenom brzinom odabiranja zasnovanog na slučajnoj demodulaciji (*Random Demodulation based Reduced Sampling rate* – RDRS) za modelovanje i linearizaciju pojačavača u [56]. Značajna karakteristika ove metode je što se množenjem signala pseudoslučajnom sekvencom u vremenskom domenu, signal širi preko celog spektra, tako da svaka tačka na frekvencijskoj osi sadrži sve informacije o signalu, tako da je za vraćanje signala dovoljno koristiti veoma mali deo spektra.

Za poboljšanje linearizacije ultraširokopojasnih *mmWave* pojačavača, predložen je DPD model koji koristi skup linearnih *piecewise* segmenata za opis nelinearnih karakteristika pojačavača, kojim su operatori višeg reda zamenjeni sa nekoliko operatora nižeg reda [47]. Pored ovog modela, predložen je i *bandlimited* DPD model sa *band-switching* arhitekturom u povratnoj grani i ažuriranom procedurom linearizacije širokopojasnog 5G *mmWave* pojačavača [59]. Za linearizaciju širokopojasnih pojačavača u *concurrent dual-band* predajnicima, predložen je dvodimenzionalni *band-limited* DPD model [58]. Takođe je analizirana i mogućnost primene *bandlimited* DPD modela za mMIMO predajnike [60].

Uporedni prikaz performansi i kompleksnosti predloženih metoda dat je u tabeli 2.2, gde je P – red nelinearnosti, M – dubina memorije, K – dužina *band-limiting* funkcije modela, K_a i K_b – red nelinearnosti statičkog nelinearnog modela i MP modela, N – broj "*piecewise*" segmenata, N_s – broj odbiraka u svakoj sekvenci, A – dužina glavnih odbiraka [62].

Tabela 2.2 – Performanse i kompleksnost band-limited DPD modela [62].

Referenca	Signal	Širina signala [MHz]	PAPR [dB]	Širina propusnog opsega sistema [MHz]	ACPR [dBc]	NMSE [dB]	Kompleksnost modela
[46]	LTE sa 4 nosioca	80	7.5	144	-47.64 / -47.47	-34.63	$2 \cdot (4 \cdot N \cdot M + 10 \cdot N + 1)$
	CA LTE sa 4 nosioca	320	7.5	576	-42.92 / -45.04	-30.13	
[48]	WCDMA sa 4 nosioca	20	6.5	40	-60.44 / -60.40	-45.83	$K \cdot \left((M+1) \cdot \frac{P+1}{2} - 1 \right) + 3 \cdot K \cdot \left(M \cdot \frac{P-1}{2} - 1 \right) + 3$
	LTE-A sa 5 nosioca	100	7.8	140	-51.02 / -52.22	-41.66	
	LTE-A sa 3 nosioca	60	7.7	140	-52.57 / -53.44	-41.94	
	LTE-A + UMTS	100	9.2	140	-56.14 / -57.04	-43.53	
[51]	WCDMA sa 2 razmaknuta nosioca	40	-	81.92	-59.60 / -57.73	-	-
[52]	LTE-A sa 5 nosioca	100	-	100	-48	-	$2M \cdot (13P - 7)$
[53]	LTE-A sa 5 nosioca	100	-	140	-48	-	$4 \cdot (3K_a + 4M(K_b - 1) - 3)$
[55]	LTE	20	-	20	-52.61 / -52.39	-45.77	-
[56]	LTE	40	7.0	20	-46.35 / -45.59	-	-
[57]	Dual-band LTE i WCDMA sa 4 nosioca	20	-	40	-52.13 / -51.54 (lower) -51.15 / -50.53 (upper)	-44.46 (lower) -43.36 (upper)	-
[58]	256 QAM OFDM	800	7.6	800	-43.6 / -42	-	-
[59]	LTE	50	7.6	60	-65.16 / -64.82	-52.85	-
[60]	5G NR sub-6GHz	100	9.1	150	-	-35.26	$2 \cdot (4 \cdot N \cdot M + 10 \cdot N + 1)$
	5G NR mmWave	400	9	600	-	-32.35	
	28GHz	800	9	1200	-	-29.52	

3. MIMO

Od prvih komunikacionih sistema pa sve do najnovijih bežičnih komunikacionih sistema, posebna pažnja se posvećivala što efikasnijem prenosu informacija od predajnika do prijemnika. Ovo je postalo posebno značajno sa sve rasprostranjenijim zahtevima za prenosom sve veće količine informacija putem mobilnih mreža u poslednjih par decenija. Zbog mogućnosti za značajno povećanje kapaciteta, pri čemu se ne zahteva povećanje propusnog opsega, *Multiple Input Multiple Output* (MIMO) tehnologija je privukla veliko interesovanje stručne javnosti [6]-[9], [12], [32], [63]-[68]. Osnovni princip MIMO tehnologije je korišćenje višestrukih antenskih nizova ili antena i na predajnoj i na prijemnoj strani za istovremeno slanje i prijem više signala preko istog radio kanala. Signali na predaji i na prijemu, koji propagiraju različitim putanjama (*multipath propagation*), kombinuju se tako da se smanje greške i poveća kapacitet sistema. Dok je kod tradicionalnih *Single Input Single Output* (SISO) sistema višestruko prostiranje signala predstavljalo problem, i težilo se eliminisanju efekata višestrukog prostiranja, kod MIMO sistema je višestruko prostiranje jedna od njenih najznačajnijih osobina. Primena MIMO tehnologije za poboljšanje performansi bežičnih komunikacionih sistema standardizovana je još sa uvođenjem bežičnih mreža treće generacije (3G). U ovom poglavlju dat je opis MIMO sistema, uključujući i opis karakteristika propagacionog RF kanala, kao i različitih matematičkih modela kanala, uz poseban osvrt na tehniku hibridnog *beamforming*-a i matematičke algoritme za određivanje koeficijenata hibridnog *beamforming*-a. Analiziran je problem digitalne predistorzije signala kod MIMO sistema i opisani su neki od postojećih DPD modela za linearizaciju signala kod MIMO predajnika.

3.1 Radio kanal i mehanizmi prostiranja radio signala

Za razumevanje principa MIMO tehnologije i načina na koji se postiže poboljšanje performansi bežičnih sistema, neophodno je razumeti osnovne fizičke pojave do kojih dolazi pri prostiranju radio talasa kroz fizički medijum, odnosno radio-frekvencijski (RF) kanal. Tri osnovna mehanizma koji utiču na prostiranje radio talasa su:

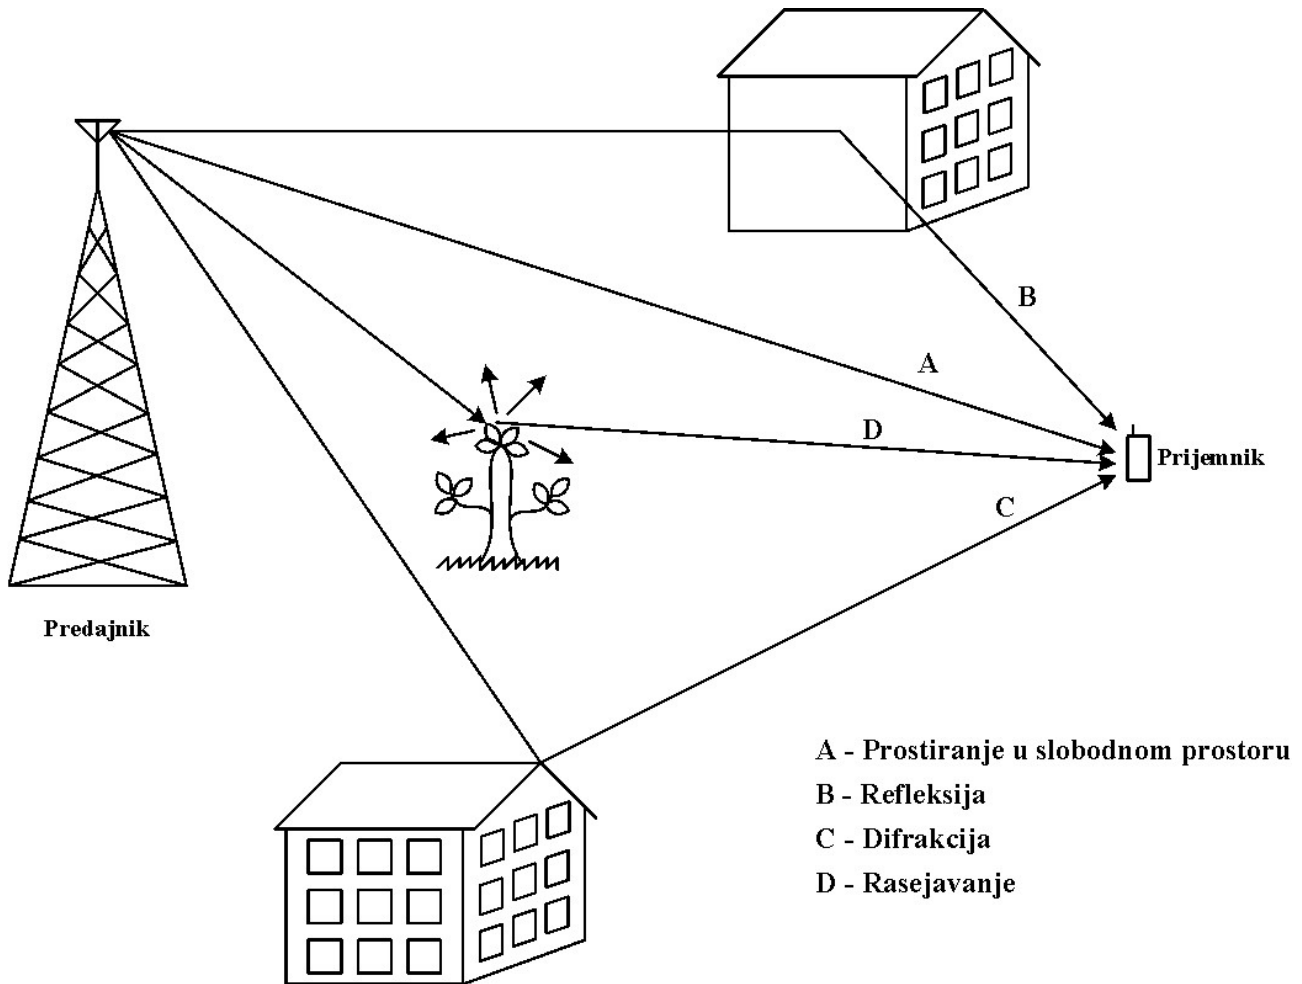
- refleksija,
- difrakcija,
- rasejanje (*scattering*).

Refleksija se dešava kada radio talas naiđe na i odbije se od objekta čija je dimenzija znatno veća u odnosu na talasnu dužinu signala, kao što su na primer veliki i glatki zidovi.

Difrakcija se dešava kada radio talas naiđe na prepreku oštih ivica, pri čemu dolazi do pojave prividnog skretanja talasa, odnosno oslabljen radio signal nastavlja prostiranje u novim pravcima. Na ovaj način moguće je preneti signal od predajnika do prijemnika sa kojim ne postoji direktna optička vidljivost.

Rasejanje se dešava kada radio talas naiđe na veliki broj prepreka čije su dimenzije manje ili istog reda veličine u odnosu na talasnu dužinu signala, i tada dolazi do rasipanja reflektovanog talasa u više pravaca.

Navedene fizičke pojave dovode do višestrukog (*multipath*) prostiranja signala, odnosno radio signali od predajnika do prijemnika dolaze prostiranjem po više različitih putanja, što je ilustrovano na slici 3.1.



Slika 3.1 – Višestruko prostiranje signala.

Usled višestrukog prostiranja signala, na prijemu dolazi do kašnjenja pojedinih komponenti, što rezultuje u disperziji prijemnog signala u vremenu, kao i do promena amplitude primljenog signala, što utiče na degradaciju odnosa signal/šum (S/N – *Signal-to-Noise*) na prijemu. Ove promene se jednim imenom nazivaju *multipath* fading.

Rezultujući signal na prijemu se formira superpozicijom radio talasa pristiglih različitim putanjama, odnosno matematički gledano prijemni signal predstavlja sumu N *multipath* komponenti:

$$r(t) = \sum_{i=1}^N \beta_i s_0(t - \tau_i), \quad (3.1)$$


gde je: $r(t)$ – ukupan primljeni signal, β_i – slabljenje primljenog signala po i -toj putanji, τ_i – kašnjenje primljenog signala po i -toj putanji, s_0 – deterministički signal koji se prenosi radio kanalom:

$$s_0(t) = A_0 \exp[j(2\pi f_0 t + \phi_0)]. \quad (3.2)$$

Svaku putanju karakteriše jedinstveno slabljenje i vremensko kašnjenje, koje se ogleda u promeni amplitude i faze primljenog signala. Kada su dva primljena signala u fazi dolazi do njihovog sabiranja, odnosno efekat višestrukog prostiranja signala je pozitivan. Sa druge strane, ukoliko primljeni signali nisu u fazi, dolazi do međusobnog poništavanja i degradacije primljenog signala. MIMO sistemi se projektuju tako da se iskoriste pozitivni efekti višestrukog prostiranja signala.

3.2 Opis MIMO sistema

Konvencionalna definicija MIMO sistema podrazumeva korišćenje više antenskih elemenata na predaji i prijemu. Blok šema MIMO sistema sa N_T predajnih antena i N_R prijemnih antena, prikazana je na slici 3.2.



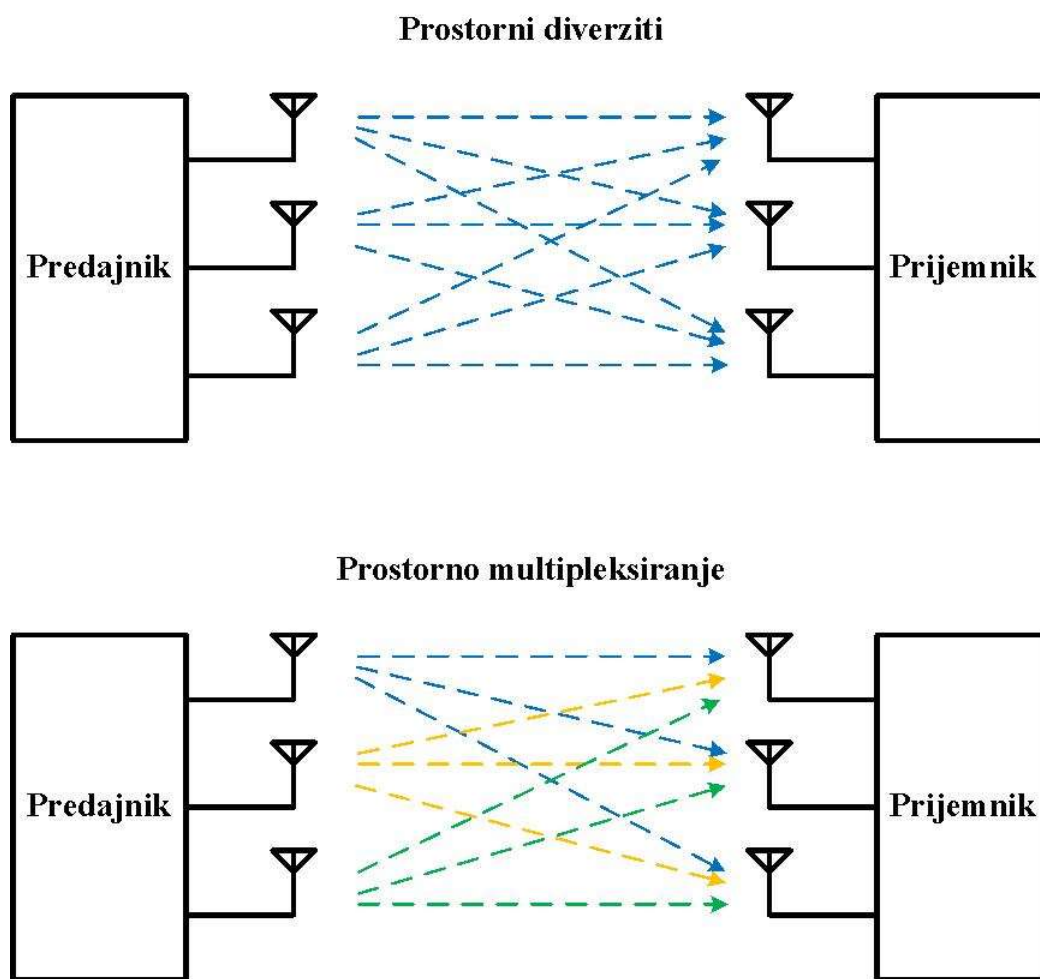
Slika 3.2 – Blok šema MIMO sistema.

Poboljšanje performansi kod MIMO bežičnih sistema, u odnosu na klasične SISO sisteme sa jednom predajnom i jednom prijemnom antenom, omogućeno je primenom sledećih višiantenskih tehnika:

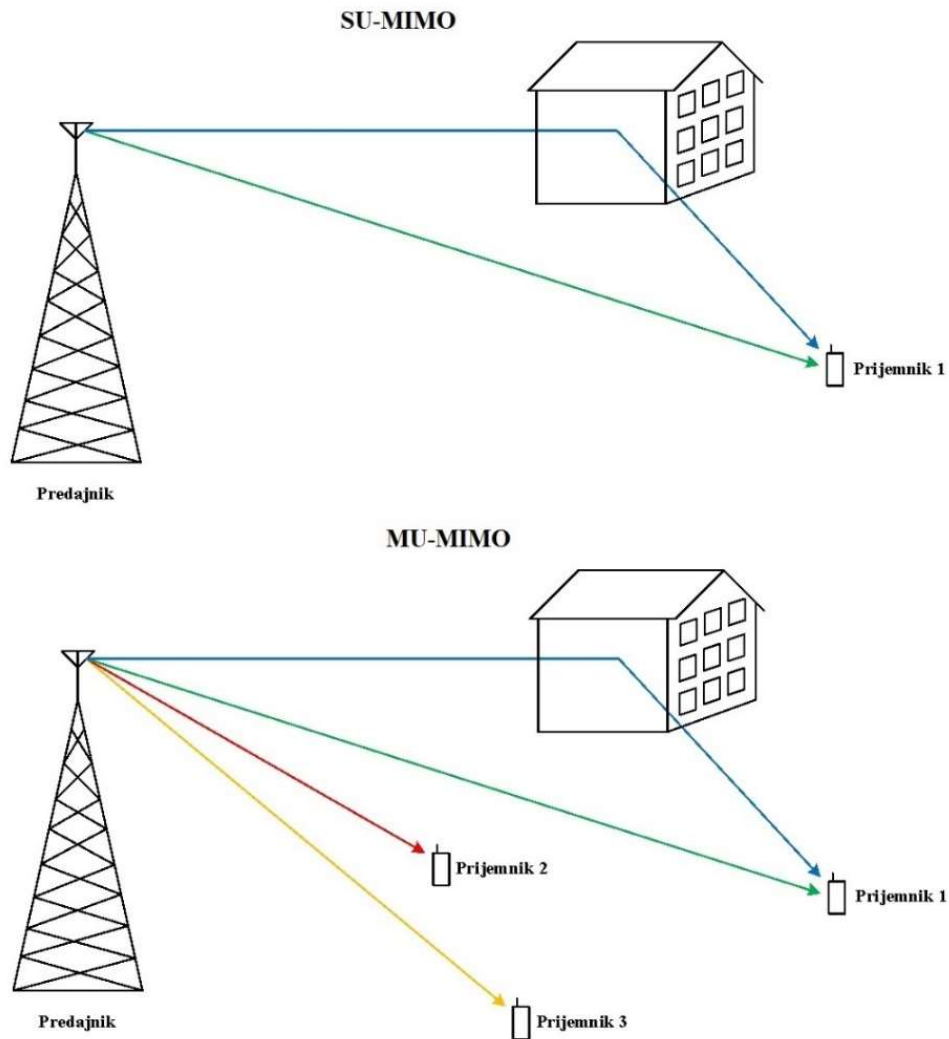
- Prostorni diverziti (*spatial diversity*) – Ista informacija se prenosi različitim putanjama, tj. između različitih parova predajnih i prijemnih antena, tako da na prijemu postoji više različitih nezavisno oslabljenih replika signala, čime se povećava pouzdanost sistema.
- Prostorno multipleksiranje (*spatial multiplexing*) – Više nezavisnih nizova podataka se istovremeno šalje preko više različitih antena, čime se povećava kapacitet sistema.

- Oblikovanje i usmeravanje snopa (*beamforming*) – Više različitih antena se koristi u cilju formiranja dijagrama zračenja antene koji će što više energije usmeriti ka prijemniku željenog korisnika, uz što manje rasipanje energije signala u pravcima ostalih korisnika, čime se smanjuje interferencija ka drugim korisnicima i povećava odnos signal/šum (*Signal-to-Noise Ratio* – SNR).

Na slici 3.3 ilustrovani su principi tehnika prostornog diverzitija i prostornog multipleksiranja, dok je na slici 3.4 prikazana tehnika *beamforming*-a za MIMO sistem koji resurse koristi da u jednom trenutku opslužuje jednog korisnika, tzv. *Single-User* (SU-MIMO), i za MIMO sistem za više korisnika, tzv. *Multi-User* (MU-MIMO). Kod MU-MIMO sistema, poboljšanje spektralne efikasnosti se postiže time što bazna stanica (*Base Station* – BS) može istovremeno komunicirati sa više korisnika koristeći iste vremensko-frekvencijske resurse, i što se višestruki nizovi podataka mogu poslati između bazne stanice i svakog korisnika.



Slika 3.3 – Prostorni diverziti i prostorno multipleksiranje kod MIMO sistema.



Slika 3.4 – Beamforming kod SU-MIMO i MU-MIMO sistema.

Prostorni diverziteti je relativno jednostavna i široko rasprostranjena tehnika za smanjenje uticaja fedinga i poboljšanje performansi u mobilnim komunikacionim sistemima. Da bi se realizovao prostorni diverziteti neophodno je da diverziteti antene budu međusobno razmaknute tako da se postigne statička nezavisnost primljenih signala, odnosno da signali budu međusobno nekorelisani. U praksi obično postoji izvestan stepen korelacije, ali se teži njegovom smanjenju. Što je manji koeficijent korelacije, to je veći dobitak koji se postiže primenom diverziteti tehnike. Prostorni diverziteti se može realizovati kada na predajnoj strani ne postoji informacija o stanju kanala (*Channel State Information – CSI*), s tim što se koristi odgovarajuće kodiranje predajnog signala. Najčešće korišćeno kodiranje je *Alamouti Space-Time Block Code (STBC)*. Na prijemu se koristi odgovarajuće kombinovanje primljenih signala, kako bi se povećala ukupna snaga primljenog signala. Najjednostavniji model prostornog diverzitetija na prijemu koristi prosti odlučivač, koji vrši izbor najboljeg signala, odnosno uvek se koristi onaj par predajne i prijemne antene koji daje signal najveće snage. Na ovaj način se za MIMO sistem sa N_T predajnih antena i N_R prijernih antena smanjuje verovatnoća otkaza sistema usled fedinga za faktor $N_T \cdot N_R$, odnosno povećava se pouzdanost sistema.

Prostorno multipleksiranje je tehnika kojom se omogućava istovremeni prenos više nezavisnih signala preko jednog radio kanala, korišćenjem više antena na predajnoj i prijernoj strani. Pri tom prijernik mora demultipleksirati, odnosno odvojiti pojedinačne signale, odnosno različite nizove podataka, iz primljenog signala koji predstavlja sumu svih poslatih različitih

signala. Prostorno multipleksiranje, kao i prostorni diverziteti, može se realizovati bez postojanja informacija o stanju kanala na predajnoj strani. Primenom prostornog multipleksiranja kod MIMO sistem sa N_T predajnih antena i N_R prijemnih antena, ostvaruje se povećanje kapaciteta reda $\min(N_T, N_R)$, bez povećanja frekvencijskog opsega.

Za razliku od prostornog diverzitija i prostornog multipleksiranja, za primenu *beamforming* tehnike, neophodno je postojanje informacije o stanju kanala na predajnoj strani. Primenom višestrukih međusobno bliskih antenskih elemenata, obično razmaknutih za polovinu talasne dužine, koji emituju isti signal, vrši se formiranje snopa u odgovarajućem željenom pravcu. Korišćenjem odgovarajućih tehnika obrade signala, antenski elementi se usmeravaju tako da se u određenom pravcu postigne konstruktivna interferencija signala, odnosno formira se tzv. glavni lob, dok se u ostalim pravcima teži destruktivnoj interferenciji, odnosno smanjenju tzv. bočnih lobova. Pri tom, što je više antenskih elemenata, to je uži formiran snop, odnosno glavni lob, dok su bočni lobovi manji, odnosno gubitak energije u neželjenim pravcima se smanjuje.

Generalno nije moguće koristiti prednosti svih prethodno nabrojanih višeantenskih tehnika, već se u zavisnosti od situacije, odnosno od potreba sistema, koristi odgovarajuća tehnika.

Matematički model MIMO sistema može se opisati sledećom relacijom:

$$\mathbf{y}(t) = \mathbf{H}\mathbf{x}(t) + \mathbf{n}(t), \quad (3.3)$$

gde je: $\mathbf{y}(t)$ – vektor prijemnog signala, $\mathbf{x}(t)$ – vektor predajnog signala, $\mathbf{n}(t)$ – vektor aditivnog belog Gausovog šuma, \mathbf{H} – kanalna matrica dimenzija $N_T \times N_R$:

$$\mathbf{H} = \begin{bmatrix} \mathbf{h}_{1,1} & \cdots & \mathbf{h}_{1,N_T} \\ \vdots & \ddots & \vdots \\ \mathbf{h}_{N_R,1} & \cdots & \mathbf{h}_{N_R,N_T} \end{bmatrix}, \quad (3.4)$$

čiji su elementi vremenski promenljive, kompleksne slučajne veličine date sa:

$$h_{r,t} = a_{r,t} \cdot e^{j\theta_{r,t}}, \quad r = 1, \dots, N_R, \quad t = 1, \dots, N_T, \quad (3.5)$$

pri čemu su: $a_{r,t}$ i $\theta_{r,t}$ – anvelopa i faza fadinga između t -te predajne i r -te prijemne antene.

Na sličan način može se formulisati i model MU-MIMO kanala, sa K korisnika:

$$\mathbf{y}(t) = \sum_{k=1}^K \mathbf{H}_k \mathbf{x}_k(t) + \mathbf{n}(t), \quad (3.6)$$

gde je: $\mathbf{y}(t)$ – vektor prijemnog signala, $\mathbf{x}_k(t)$ – vektor predajnog signala k -tog korisnika, $\mathbf{n}(t)$ – vektor aditivnog belog Gausovog šuma, \mathbf{H}_k – kanalna matrica k -tog korisnika, $\mathbf{H} = [\mathbf{H}_1 \quad \cdots \quad \mathbf{H}_K]$.

Elementi kanalne matrice zavise od propagacionih uslova u kanalu i stoga je veoma značajno poznavanje realističnog modela kanala koji u obzir uzima fizičke pojave do kojih dolazi pri prostiranju signala.

MIMO kanal možemo posmatrati kao skup potkanala od svake predajne do svake prijemne antene. Kako bi se omogućila optimalna podela snage po potkanalima potrebno je da postoji informacija o stanju kanala - CSI na predajnoj strani. Ukoliko to nije slučaj, obično se primenjuje ravnomerna podela snage, tj. signali sa svih N_T predajnih antena se emituju jednakim snagama.

Kapacitet MIMO kanala je približno linearno zavisen od broja antena na predaji i prijemu, i dat je sledećom relacijom [69]:

$$C_{\text{MIMO}} = BM \log_2(1 + \text{SNR}), \quad (3.7)$$

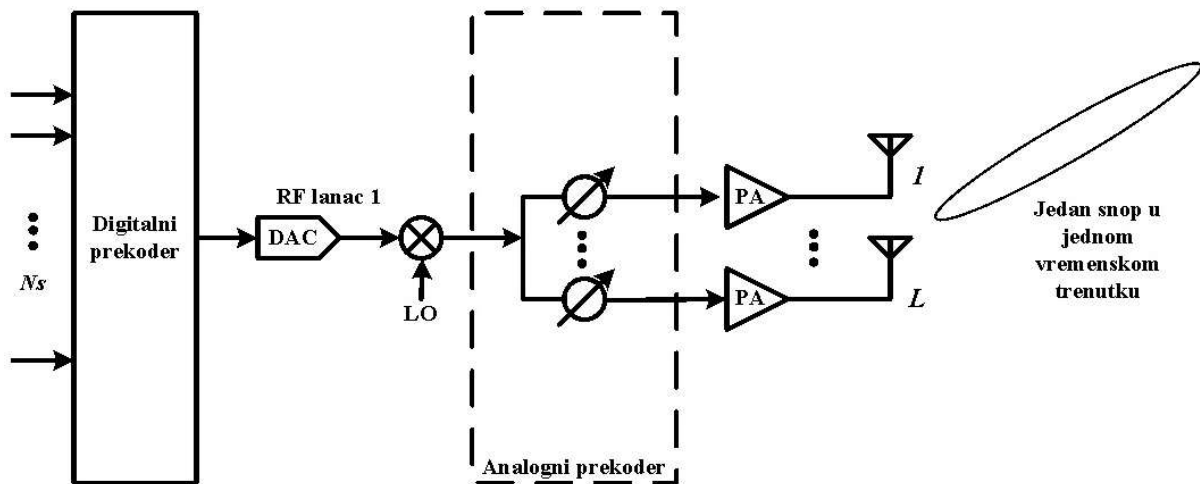
gde je: B – širina kanala, SNR (*Signal-to-Noise Ratio*) – odnos snage signala i snage šuma na ulazu u prijemnik, M – broj antena, pri čemu se za slučaj da je broj antena na predaji i prijemu različit računa kao $M = \min(N_T, N_R)$.

Sa povećanjem broja antena povećavaju se prednosti tradicionalnih MIMO sistema i sve više se govori o *massive* MIMO (mMIMO) sistemima. Iako nije preciziran broj antena koji predstavlja granicu između klasičnog MIMO i mMIMO sistema, obično se smatra da mMIMO sistemi imaju obično desetine, stotine, pa čak i hiljade antena u jednom nizu. Dodatne antene drastično povećavaju energetska efikasnost sistema jer se energija zračenja fokusira u manje oblasti u prostoru prema ciljanom korisniku. Osim toga prednost mMIMO sistema se ogleda i u korišćenju jeftinih komponenti male snage, smanjenju kašnjenja, pojednostavljenju *Media Access Control* (MAC) sloja i robusnosti u odnosu na namerna ometanja [7].

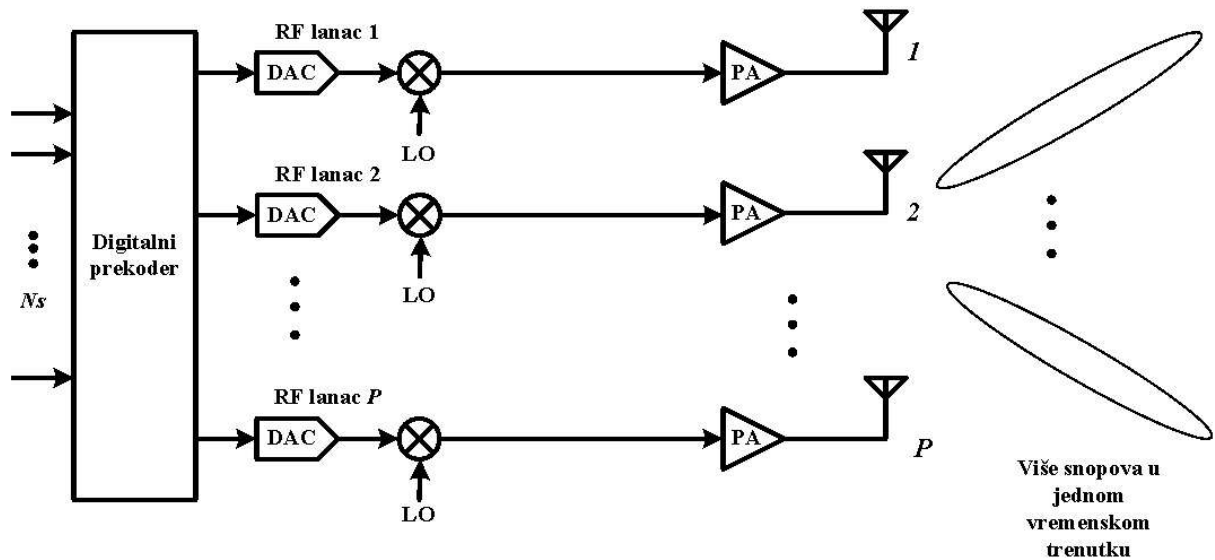
3.3 Hibridni beamforming

Osnovni princip *beamforming*-a sastoji se u promeni faze i amplitude signala svakog antenskog elementa, tako da se njihovim sumiranjem formira snop u željenom pravcu. Na osnovu načina realizacije *beamforming*-a razlikuju se tri tipa *beamforming*-a, prikazana na slici 3.5:

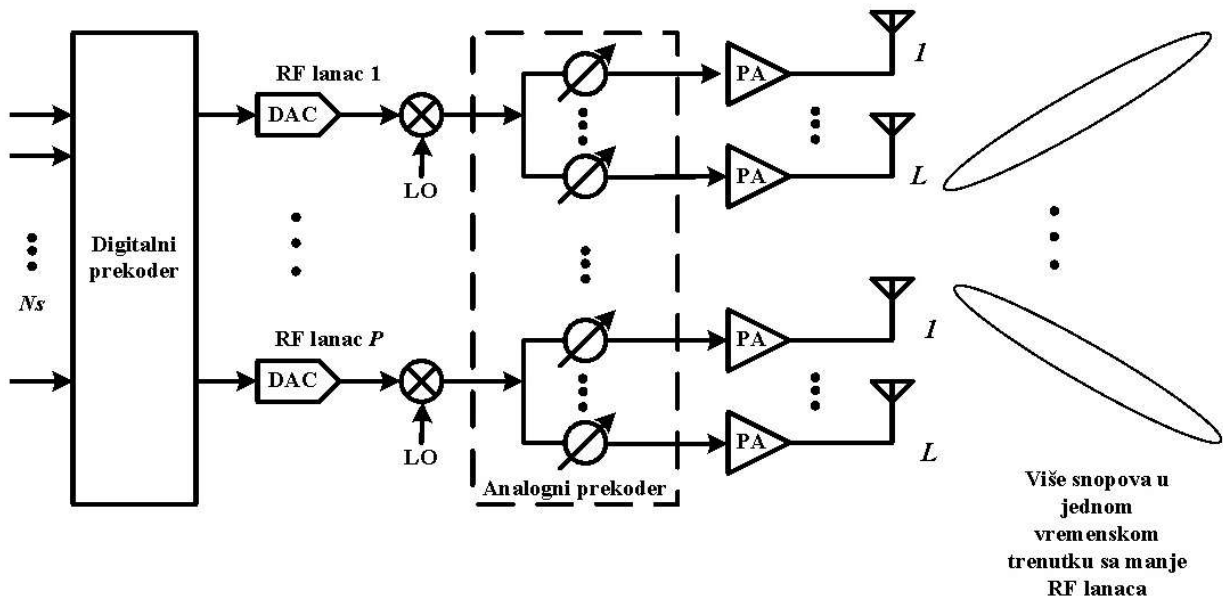
- analogni *beamforming*,
- digitalni *beamforming*,
- hibridni *beamforming*.



a) analogni *beamforming*



b) digitalni beamforming



c) hibridni beamforming

Slika 3.5 – Tipovi beamforming-a: a) analogni; b) digitalni; c) hibridni.

Kod analognog beamforming-a, formiranje snopa se vrši u analognom domenu, primenom faznih pomerača. Ulazni signal u osnovnom opsegu se moduliše, zatim se korišćenjem jednog RF lanca dovodi na niz analognih faznih pomerača, sa kojih se zatim signali vode na pojedinačne antenske elemente. Fazni pomerači vrše promenu faze signala pre dovođenja signala na antenski element, pri čemu fazni pomak između signala poslatih ka svakom antenskom elementu određuje pravac emitovanja zraka. Ukoliko je ulazni signal u RF domenu $x(t)$, izlazni signal iz n -tog faznog pomerača dat je sa:

$$y_n(t) = x(t)e^{j\theta_n}, \quad (3.8)$$

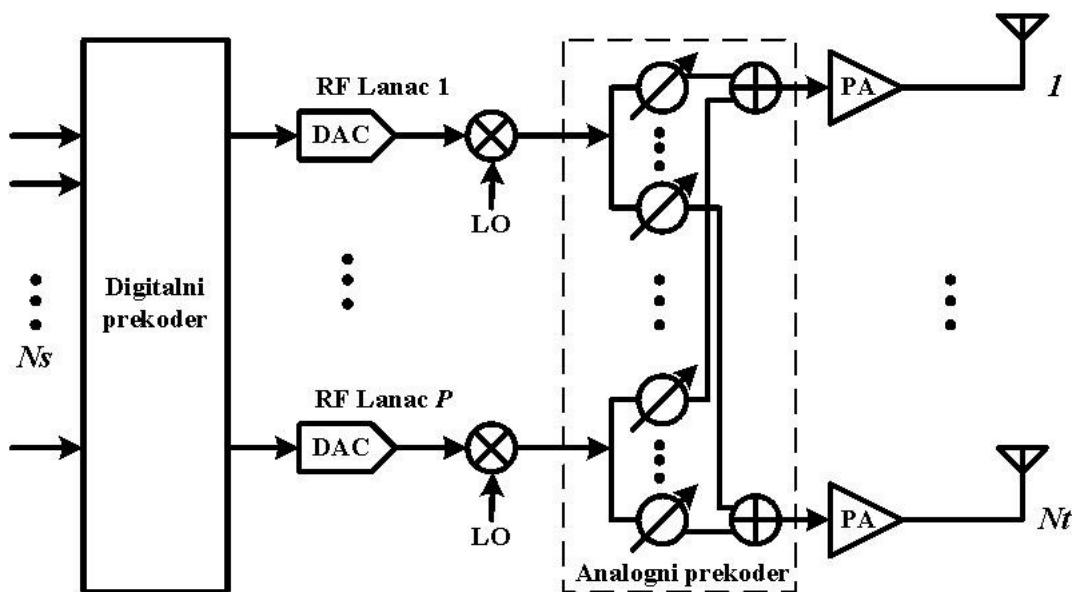
pri čemu je: θ_1 – fazni pomak koji unosi prvi pomerač u nizu, a $\theta_n = n\theta_1$. Glavni nedostatak analognog beamforming-a jeste to što omogućava formiranje samo jednog snopa u određenom

vremenskom trenutku, tako da nije moguće opslužiti više korisnika odjednom. Pored toga, fino podešavanje zraka je ograničeno rezolucijom faznih pomerača.

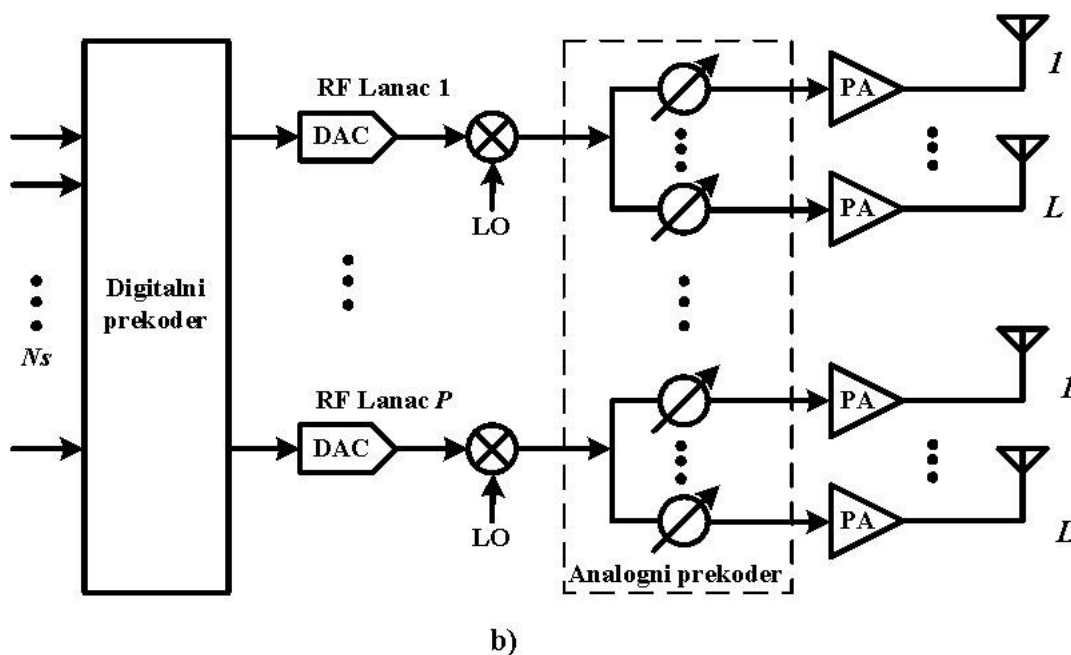
Kod digitalnog *beamforming*-a svaki antenski element je posebnim RF lancem povezan sa procesorom u osnovnom opsegu, pri čemu se prekodiranje vrši u osnovnom opsegu. Kompletna kontrola ugla i amplitude signala na svakoj anteni vrši se u digitalnom domenu, pri čemu se izlazni signal formira pomoću matrice prekodiranja \mathbf{W} koja se formira na osnovu informacija o stanju kanala. Glavni nedostatak digitalnog *beamforming*-a, pri primeni kod mMIMO sistema, jeste složenost hardvera, velika potrošnja energije i cena implementacije, usled postojanja velikog broja RF lanaca, kao i ADC i DAC konvertora.

Kao kompromis između prethodne dve tehnike, predložena je tehnika hibridnog *beamforming*-a (HBF), kod koje je formiranje snopa podeljeno na: digitalni *beamforming* u osnovnom opsegu i analogni *beamforming* u RF domenu. U RF domenu se vrši formiranje snopa, korišćenjem analognih kola kojima se postiže promena faze signala. Istovremeno se korišćenjem digitalnog procesora u osnovnom opsegu vrši prekodiranje signala u cilju postizanja povećanja SNR i smanjenja interferencije. Hibridni *beamforming* u predajniku je realizovan tako što se N_s nizova podataka u digitalnom prekoderu konvertuje u ulazne signale za P RF lanaca, koji se zatim u analognom prekoderu konvertuju u signale koji se šalju na N_T antenskih elemenata. Brojem RF lanaca određen je maksimalan broj nizova podataka koji se mogu istovremeno preneti.

U zavisnosti od načina implementacije hibridnog *beamforming*-a u RF domenu, razlikuju se dva tipa arhitekture HBF MIMO predajnika: potpuno povezana (*Fully Connected* – FC) i delimično povezana (*Subarray* – SA) arhitektura. Blok šeme ova dva tipa arhitekture HBF MIMO predajnika su prikazane na slici 3.6. Kod potpuno povezane HBF arhitekture, svaka antena je povezana na svaki od P RF lanaca, dok je, kod delimično povezane HBF arhitekture, na jedan RF lanac povezan podskup od L antena. Delimično povezana arhitektura ima manju kompleksnost u odnosu na potpuno povezanu arhitekturu. Sa druge strane, prednost potpuno povezane arhitekture je što omogućava veću spektralnu efikasnost u odnosu na delimično povezanu arhitekturu HBF predajnika [70].



a)



Slika 3.6 – Blok šema arhitekture HBF predajnika: a) potpuno povezana; b) delimično povezana.

Matematički, osnovni princip hibridnog *beamforming*-a se može formulisati generisanjem koeficijenata za precodiranje signala, kao kombinacije koeficijenata precodiranja u osnovnom opsegu (F_{BB}) i koeficijenata precodiranja u RF domenu (F_{RF}):

$$F = F_{BB} * F_{RF} . \quad (3.9)$$

Koeficijenti precodiranja u osnovnom opsegu opisuju konvertovanje ulaznih nizova podataka u ulazne signale RF lanaca, dok koeficijenti precodiranja u RF opsegu opisuju konvertovanje signala sa svakog RF lanca u signale koji se zatim vode na antenske elemente. Ispred svakog antenskog elementa se nalazi pojačavač snage, koji dovodi signal na odgovarajući nivo snage pogodan za dalji prenos kroz kanal.

Analogno se u prijemniku generišu koeficijenti za kombinovanje primljenih signala, kao kombinacija koeficijenata za kombinovanje u osnovnom opsegu (W_{BB}) i koeficijenata za kombinovanje u RF domenu (W_{RF}):

$$W = W_{BB} * W_{RF} . \quad (3.10)$$

Ceo proces prenosa signala kroz kanal se matematički može opisati korišćenjem matrica:

$$Y = (X * F * H + N) * W, \quad (3.11)$$

gde je: Y – matrica čiji su elementi nizovi dekodovanih podataka, X – matrica čiji su elementi nizovi ulaznih podataka, H – matrica koja opisuje stanje kanala, N – matrica koja opisuje šum u prijemniku.

Kako je kod potpuno povezane arhitekture svaki od P RF lanaca povezan sa svakim antenskim elementom, kao što se može videti na slici 3.6.a), ukupan broj faznih pomerača je $P \cdot N_T$, a matrica koeficijenata precodovanja u RF domenu F_{RF} je dimenzija $N_T \times P$. Svaka kolona matrice F_{RF} predstavlja fazni pomeraj N_T faznih pomerača u odnosu na odgovarajući RF lanac. Kod delimično povezane arhitekture, prikazane na slici 3.6.b), zbog činjenice da je svaki RF lanac povezan na samo jedan podskup od L antenskih elemenata, matrica F_{RF} se svodi na blok dijagonalnu matricu. Pri tom je ukupan broj faznih pomerača u delimično povezanoj arhitekturi N_T , što znači da je kompleksnost RF *beamformer*-a smanjena P puta.

Cilj je postići što bolju spektralnu efikasnost, odnosno matematički iskazano, naći optimalne koeficijente za prekodovanje i kombinovanje, tako da proizvod $F * H * W'$ bude dijagonalna matrica, kako bi se svaki niz podataka mogao nezavisno rekonstruisati [71]. Problem istovremenog određivanja sve četiri matrice koeficijenata je veoma kompleksan i u literaturi postoji veliki broj predloženih algoritama [72]-[82]. Među raznovrsnim algoritmima izdvajaju se algoritmi koji vrše potragu za ortogonalnim podudaranjem (*Orthogonal Matching Pursuit* – OMP) [72], algoritmi zasnovani na višestrukoj optimizaciji (*Manifold Optimization* – MO) [80], algoritmi zasnovani na kriterijumu minimalne srednje kvadratne greške (*Minimum Mean Squared Error* – MMSE) [81]-[82],...

3.3.1 Spatially Sparse Precoding algoritam

Jedan od predloženih algoritama, efikasno implementiran u programskom paketu *Matlab*, je *Spatially Sparse Precoding* algoritam, predložen u [72], koji vrši potragu za ortogonalnim podudaranjem. Algoritam se sastoji u podeli problema optimizacije na dva optimizaciona problema: određivanje koeficijenata prekodera F_{BB}, F_{RF} i određivanje koeficijenata za kombinovanje W_{BB}, W_{RF} . Kako bi se postigla maksimalna spektralna efikasnost, cilj je maksimizirati međusobnu informaciju dobijenu Gausovom signalizacijom preko kanala:

$$\mathcal{J}(F_{RF}, F_{BB}) = \log_2 \left(\left| I_{N_s} + \frac{\rho}{N_s \sigma_n^2} H F_{RF} F_{BB} F_{BB}^* F_{RF}^* H^* \right| \right), \quad (3.12)$$

pri čemu ρ predstavlja srednju primljenu snagu signala, i u kanalu je prisutan šum normalne raspodele $\mathcal{CN}(0, \sigma_n^2)$.

Problem određivanja koeficijenata prekodera svodi se na traženje maksimuma:

$$(F_{RF}^{\text{opt}}, F_{BB}^{\text{opt}}) = \underset{F_{RF}, F_{BB}}{\text{argmax}} \log_2 \left(\left| I_{N_s} + \frac{\rho}{N_s \sigma_n^2} H F_{RF} F_{BB} F_{BB}^* F_{RF}^* H^* \right| \right). \quad (3.13)$$

Prvi korak je dekompozicija singularne vrednosti (*Singular Value Decomposition* – SVD) kanalne matrice, tj. predstavljanje kanalne matrice u obliku:

$$H = U \Sigma V^*, \quad (3.14)$$

gde je: U – jedinična matrica dimenzija $N_R \times \text{rank}(H)$, Σ – dijagonalna matrica singularnih vrednosti poređanih u opadajućem poretku dimenzija $\text{rank}(H) \times \text{rank}(H)$, V – jedinična matrica dimenzija $N_T \times \text{rank}(H)$. Zatim se definišu matrice Σ i V kao:

$$\Sigma = \begin{bmatrix} \Sigma_1 & 0 \\ 0 & \Sigma_2 \end{bmatrix}, \quad (3.15)$$

$$V = [V_1 \quad V_2], \quad (3.16)$$

pri čemu je Σ_1 dimenzija $N_s \times N_s$, a V_1 je dimenzija $N_T \times N_s$, N_s – broj nizova podataka.

Primenom dekompozicije singularne vrednosti kanalne matrice i uz određene aproksimacije [72], relacija (3.12) se može transformisati u sledeći oblik:

$$\mathcal{J}(F_{RF}, F_{BB}) = \log_2 \left(\left| I_{N_s} + \frac{\rho}{N_s \sigma_n^2} \Sigma_1^2 \right| \right) - (N_s - \|V_1^* F_{RF} F_{BB}\|_F^2). \quad (3.17)$$

Odnosno, problem određivanja koeficijenata prekodera svodi se na traženje minimuma:

$$(\mathbf{F}_{\text{RF}}^{\text{opt}}, \mathbf{F}_{\text{BB}}^{\text{opt}}) = \underset{\mathbf{F}_{\text{RF}}, \mathbf{F}_{\text{BB}}}{\text{argmin}} \|\mathbf{F}_{\text{opt}} - \mathbf{F}_{\text{RF}} \mathbf{F}_{\text{BB}}\|_F. \quad (3.18)$$

Pri ovako definisanim parametrima, optimalni jedinični prekoder za kanalnu matricu \mathbf{H} je $\mathbf{F}_{\text{opt}} = \mathbf{V}_1$. Zatim se definiše i matrica \mathbf{A}_t , dimenzija $N_T \times N_{\text{cl}} N_{\text{ray}}$, koja se sastoji od vektora niza odgovora (*array response vectors*):

$$\mathbf{A}_t = \left[\mathbf{a}_t(\phi_{1,1}^t, \theta_{1,1}^t), \dots, \mathbf{a}_t(\phi_{N_{\text{cl}}, N_{\text{ray}}}^t, \theta_{N_{\text{cl}}, N_{\text{ray}}}^t) \right], \quad (3.19)$$

gde su: N_{cl} i N_{ray} – broj klastera i broj zrakova u svakom klasteru, respektivno.

Algoritam određivanja koeficijenata za prekodovanje $\mathbf{F}_{\text{BB}}, \mathbf{F}_{\text{RF}}$ prikazan je na slici 3.7 [72].

Algorithm 1 Spatially Sparse Precoding via Orthogonal Matching Pursuit

Require: \mathbf{F}_{opt}

- 1: $\mathbf{F}_{\text{RF}} = \text{Empty Matrix}$
- 2: $\mathbf{F}_{\text{res}} = \mathbf{F}_{\text{opt}}$
- 3: **for** $i \leq N_t^{\text{RF}}$ **do**
- 4: $\Psi = \mathbf{A}_t^* \mathbf{F}_{\text{res}}$
- 5: $k = \arg \max_{\ell=1, \dots, N_{\text{cl}} N_{\text{ray}}} (\Psi \Psi^*)_{\ell, \ell}$
- 6: $\mathbf{F}_{\text{RF}} = \left[\mathbf{F}_{\text{RF}} \mid \mathbf{A}_t^{(k)} \right]$
- 7: $\mathbf{F}_{\text{BB}} = (\mathbf{F}_{\text{RF}}^* \mathbf{F}_{\text{RF}})^{-1} \mathbf{F}_{\text{RF}}^* \mathbf{F}_{\text{opt}}$
- 8: $\mathbf{F}_{\text{res}} = \frac{\mathbf{F}_{\text{opt}} - \mathbf{F}_{\text{RF}} \mathbf{F}_{\text{BB}}}{\|\mathbf{F}_{\text{opt}} - \mathbf{F}_{\text{RF}} \mathbf{F}_{\text{BB}}\|_F}$
- 9: **end for**
- 10: $\mathbf{F}_{\text{BB}} = \sqrt{N_s} \frac{\mathbf{F}_{\text{BB}}}{\|\mathbf{F}_{\text{RF}} \mathbf{F}_{\text{BB}}\|_F}$
- 11: **return** $\mathbf{F}_{\text{RF}}, \mathbf{F}_{\text{BB}}$

Slika 3.7 – Spatially Sparse Precoding algoritam za određivanje koeficijenata za prekodovanje [72].

Koeficijenti za kombinovanje ($\mathbf{W}_{\text{BB}}, \mathbf{W}_{\text{RF}}$) se određuju po sličnom principu, tako da se minimizira srednja kvadratna greška (*Mean-Squared-Error – MSE*) između signala koji se prenosi i primljenog signala, \mathbf{E} . Problem određivanja koeficijenata $\mathbf{W}_{\text{BB}}, \mathbf{W}_{\text{RF}}$ se svodi na traženje minimuma:

$$(\mathbf{W}_{\text{RF}}^{\text{opt}}, \mathbf{W}_{\text{BB}}^{\text{opt}}) = \underset{\mathbf{W}_{\text{RF}}, \mathbf{W}_{\text{BB}}}{\text{argmin}} \|\mathbf{E}[\mathbf{y}\mathbf{y}^*]^{1/2} (\mathbf{W}_{\text{MMSE}} - \mathbf{W}_{\text{RF}} \mathbf{W}_{\text{BB}})\|_F, \quad (3.20)$$

U odsustvu bilo kakvih hardverskih ograničenja dobija se optimalno rešenje $\mathbf{W}_{\text{MMSE}}^*$, koje treba razložiti na koeficijente $\mathbf{W}_{\text{BB}}, \mathbf{W}_{\text{RF}}$. Algoritam određivanja koeficijenata za kombinovanje $\mathbf{W}_{\text{BB}}, \mathbf{W}_{\text{RF}}$ prikazan je na slici 3.8 [72].

Algorithm 2 Spatially Sparse MMSE Combining via Orthogonal Matching Pursuit

Require: \mathbf{W}_{MMSE}
 1: $\mathbf{W}_{\text{RF}} = \text{Empty Matrix}$
 2: $\mathbf{W}_{\text{res}} = \mathbf{W}_{\text{MMSE}}$
 3: **for** $i \leq N_r^{\text{RF}}$ **do**
 4: $\Psi = \mathbf{A}_r^* \mathbb{E}[\mathbf{y}\mathbf{y}^*] \mathbf{W}_{\text{res}}$
 5: $k = \arg \max_{\ell=1, \dots, N_{\text{cl}} N_{\text{ray}}} (\Psi \Psi^*)_{\ell, \ell}$
 6: $\mathbf{W}_{\text{RF}} = [\mathbf{W}_{\text{RF}} | \mathbf{A}_r^{(k)}]$
 7: $\mathbf{W}_{\text{BB}} = (\mathbf{W}_{\text{RF}}^* \mathbb{E}[\mathbf{y}\mathbf{y}^*] \mathbf{W}_{\text{RF}})^{-1} \mathbf{W}_{\text{RF}}^* \mathbb{E}[\mathbf{y}\mathbf{y}^*] \mathbf{W}_{\text{MMSE}}$
 8: $\mathbf{W}_{\text{res}} = \frac{\mathbf{W}_{\text{MMSE}} - \mathbf{W}_{\text{RF}} \mathbf{W}_{\text{BB}}}{\|\mathbf{W}_{\text{MMSE}} - \mathbf{W}_{\text{RF}} \mathbf{W}_{\text{BB}}\|_F}$
 9: **end for**
 10: **return** $\mathbf{W}_{\text{RF}}, \mathbf{W}_{\text{BB}}$

Slika 3.8 – Spatially Sparse Precoding algoritam za određivanje koeficijenata za kombinovanje [72].

3.3.2 Algoritam naizmenične minimizacije

Algoritam naizmenične minimizacije [80], zasnovan na višestrukoj optimizaciji, posmatra problem određivanja koeficijenata hibridnog prekodera kao problem faktorizacije matrice. Kao i kod *Spatially Sparse Precoding* algoritma, prvo se vrši određivanje koeficijenata za prekodovanje, a zatim se na analogan način određuju i koeficijenti za kombinovanje. Matematička formulacija problema glasi:

$$\underset{\mathbf{F}_{\text{RF}}, \mathbf{F}_{\text{BB}}}{\text{minimize}} \|\mathbf{F}_{\text{opt}} - \mathbf{F}_{\text{RF}} \mathbf{F}_{\text{BB}}\|, \quad (3.21)$$

gde je: \mathbf{F}_{opt} – matrica optimalnih koeficijenata prekodera, \mathbf{F}_{RF} i \mathbf{F}_{BB} – matrice koeficijenata analognog i digitalnog prekodera koje treba optimizovati.

Zajednička optimizacija ove dve matrice \mathbf{F}_{RF} i \mathbf{F}_{BB} je veoma komplikovana i stoga je problem razdvojen na naizmeničnu optimizaciju, odnosno minimizaciju, svake od matrica. Tako se, po principu naizmenične minimizacije, naizmenično traži optimalno rešenje za \mathbf{F}_{RF} , dok je \mathbf{F}_{BB} fiksirano, i obrnuto traži se optimalno rešenje za \mathbf{F}_{BB} , dok je \mathbf{F}_{RF} fiksirano. Za optimizaciju pojedinačne matrice koristi se u literaturi dobro poznat algoritam konjugovanog gradijenta (*Conjugate Gradient Algorithm*) zasnovan na višestrukoj Rimanovoj (*Riemannian*) optimizaciji. Rimanov gradijent od x je tangenti vektor $\text{grad}f(x)$ dat ortogonalnom projekcijom Euklidskog gradijenta $\nabla f(x)$ na tangenti prostor. Euklidski gradijent funkcije troškova dat je sledećom relacijom:

$$\nabla f(x) = -2(\mathbf{F}_{\text{BB}}^* \otimes \mathbf{I}_{N_T})[\text{vec}(\mathbf{F}_{\text{opt}}) - (\mathbf{F}_{\text{BB}}^T \otimes \mathbf{I}_{N_T})x]. \quad (3.22)$$

Ovaj algoritam, zasnovan na višestrukoj optimizaciji, je vremenski dugotrajan i potrebno je dalje istraživanje po pitanju analize njegove konvergencije i optimizacije.

3.3.3 MMSE algoritam

Osnovna ideja MMSE algoritma [81] je pronalaženje vrednosti koeficijenata prekodiranja i kombinovanja za koje je srednja snaga signala greške minimalna, odnosno:

$$\underset{F_{RF}, F_{BB}, W_{RF}, W_{BB}}{\text{minimize}} \text{MSE}. \quad (3.23)$$

Srednja kvadratna greška definiše se u odnosu na referentni signal $s(t)$:

$$\text{MSE} = E\{|e(t)|^2\} = E\{\|W_{BB}^H W_{RF}^H H F_{RF}^H F_{BB}^H \mathbf{x} + W_{BB}^H W_{RF}^H \mathbf{n} - \mathbf{s}\|^2\}, \quad (3.24)$$

gde je \mathbf{n} – vektor šuma, F_{BB}, F_{RF} – koeficijenti prekodera, W_{BB}, W_{RF} – koeficijenti bloka za kombinovanje, H – kanalna matrica.

3.4 Model kanala

Kako je za određivanje koeficijenata *beamforming*-a potrebno poznavanje CSI na predajnoj strani, može se zaključiti da performanse mMIMO sistema koji koristi hibridni *beamforming* u velikoj meri zavise od modela kanala koji se koristi. Stoga modeli radio kanala moraju da pruže sve neophodne informacije o karakteristikama kanala, dok sa druge strane trebaju da budu relativno jednostavni za implementaciju i primenu u simulacijama, kako ne bi dodatno povećali kompleksnost računarskih simulacija [83]-[84]. Zbog postojanja ovakvih međusobno suprotstavljenih zahteva, u literaturi postoji veliki broj različitih modela kanala i ne postoji jedinstven i najbolji model, već se model bira u zavisnosti od primene. Opšta podela modela radio kanala je na:

- fizičke modele,
- analitičke modele,
- standardizovane modele.

Fizički modeli opisuju mehanizme prostiranja radio talasa između predajnika i prijemnika, obuhvatajući fizičke parametre poput raspodele prostornog rasejanja, kašnjenja *multipath* komponenti, uglova dolazaka i odlazaka. Fizički model ne uzima u obzir propusni opseg signala koji se prenosi, kao ni konfiguraciju antenskog niza, odnosno ne razmatra dijagram zračenja antene, broj antena, geometriju antenskog niza, polarizaciju,...

Fizički modeli se dele na:

- determinističke modele,
- stohastičke modele zasnovane na geometriji,
- ne-geometrijske stohastičke modele.

Deterministički modeli opisuju fizičke parametre prostiranja radio talasa na potpuno deterministički način i pružaju kvalitetne informacije o vremenskoj i prostornoj distribuciji signala. Tipični predstavnici determinističkih modela kanala su: *ray-tracing* i *stored measurements*. Stohastički modeli zasnovani na geometriji opisuju prostorne karakteristike kanala uzimajući u

obzir statistiku primenjenu na specifični predajnik, prijemnik i geometriju rasejača, koja je izabrana na slučajan način. Tipični predstavnici stohastičkih metoda zasnovanih na geometriji su: *one-ring* model, *two-ring* model i eliptičan model. Negeometrijski stohastički modeli opisuju fizičke parametre prostiranja talasa primenjujući statistiku na potpuno slučajan način, ne uzimajući u obzir geometriju okruženja. Tipični predstavnici ne-geometrijskih stohastičkih modela su: *Saleh-Valenzuela* model, proširen *Saleh-Valenzuela* model i *Zwicky* model.

Analitički modeli opisuju impulsni odziv između antenskih nizova predajnika i prijemnika, odnosno matematički opisuju statističke karakteristike radio kanala, bez eksplicitnog pružanja informacija o prostiranju talasa [84]. U literaturi postoji veliki broj razvijenih analitičkih modela.

Analitički modeli se mogu podeliti na:

- analitičke modele zasnovane na korelaciji,
- analitičke modele motivisane prostiranjem talasa,
- analitičke modele zasnovane na prostorno-vremenskom kodiranju.

Analitički modeli zasnovani na korelaciji statistički opisuju kanalnu matricu koristeći korelaciju između elemenata matrice. Tipični predstavnici analitičkih modela zasnovanih na korelaciji su: nezavisan i identično raspoređen model (*independent and identically distributed model* – i.i.d. model), Kronekerov (*Kronecker*) model, *Weichselberger* model, dijagonalni dekorelacioni model, model grube površine (*rough surface model*) i strukturirani model. Analitički modeli motivisani prostiranjem talasa opisuju kanalnu matricu koristeći odgovarajuće parametre prostiranja. Tipični predstavnici su: model konačnog rasejanja (*finite scatterer model*) i model maksimalne entropije (*maximum entropy model*). Analitički modeli zasnovani na prostorno-vremenskom kodiranju opisuju radio kanal koristeći prostorno-vremenske kodove, koji kombinuju kodiranje, modulaciju i obradu signala u cilju postizanja predajnog diverzitija. Ova podgrupa analitičkih modela se sve više razvija, posebno za primenu u budućim bežičnim mrežama od kojih se očekuje sveobuhvatna i sveprisutna povezanost.

Standardizovani modeli su razvijeni od strane različitih organizacija, kako bi se stvorio jedinstven okvir za razvoj novih radio sistema i poboljšale performanse i kapacitet sistema. U okviru ovih modela obuhvaćene su tehnike obrade signala i višestrukog pristupa. Neki od najpoznatijih standardizovanih modela su: IEEE 802.11n model (*Institute of Electrical and Electronics Engineers* – IEEE), IEEE 802.16d/e model, 3GPP/3GPP2 model prostornog kanala (*3rd Generation Partnership Project* – 3GPP), COST 259/273/2100 model kanala, WINNER II/+ model kanala,...

U nastavku su dodatno objašnjeni neki od pomenutih modela, kao i model *Saleh-Valenzuela* koji će biti korišćen za potrebe daljih analiza u ovom radu.


3.4.1 *Ray-tracing* model kanala

Ray-tracing model predstavlja deterministički model za predikciju radio kanala, koji je suštinski vezan za specifičnu lokaciju. Za procenu karakteristika prostiranja radio talasa između specifičnog predajnika i prijemnika potrebno je poznavati tri parametra:

- rastojanje između predajnika i prijemnika,
- upadni ugao ka reflektujućoj površini,

- kompleksnu permitivnost reflektujuće površine [85].

Kompleksna permitivnost reflektujuće površine je unapred određen statički parametar, dok se rastojanje između predajnika i prijemnika i upadni ugao određuju na osnovu rezultata procene praćenja zraka. Simulacije praćenja zraka zavise od osnovnih fizičkih principa, poput Maksvelovih (*Maxwell*) jednačina, geometrijske optike (*geometrical optics*) i uniformne teorije difrakcije (*Uniform Theory of Diffraction*). Tokom simulacije, zraci se šalju iz predajnika i propagiraju unutar modelovanog okruženja sve do prijemnika, ili dok ne padnu ispod prethodno definisanog nivoa buke, kada se odbacuju. Preciznost procene modela se može poboljšati povećanjem broja zraka koji se odašilju ili povećanjem broja refleksija i difrakcija. Prilikom modelovanja potrebno je naći kompromis između tačnosti i vremena simulacija. Na slici 3.9 prikazan je *ray-tracing* model kanala za određeno okruženje [86].



Slika 3.9 – *Ray-tracing* model MIMO kanala [86].


Iako je sam model vezan za određenu lokaciju, može se iskoristiti za procenu statističkih vrednosti različitih propagacionih scenarija. Moguće je izvršiti višestruke simulacije u okviru istog okruženja i zatim iz prikupljenih rezultata izračunati statističke parametre, poput srednje vrednosti, standardne devijacije, kumulativne funkcije distribucije (*Cumulative Distribution Function* – CDF) i korelacije.

Korišćenjem *ray-tracing* modela moguće je modelovati *multipath* prostiranje, bez bilo kakvih ograničenja po pitanju antena i merne opreme. Stoga se ovaj model veoma efikasno primenjuje za modelovanje različitih MIMO kanala za *Long Term Evolution* (LTE).

3.4.2 One-ring model kanala

One-ring model kanala je stohastički model zasnovan na geometriji, kod koga se pretpostavlja da predajnik nije okružen rasejačima, dok je prijemnik okružen rasejačima postavljenim po kružnici oko prijemnika. Posmatra se model kod koga je prečnik kruga R , po kom su postavljeni rasejači, mali u odnosu na rastojanje D između predajnika i prijemnika, odnosno $R \ll D$. Pretpostavlja se da se signal reflektuje o svakom rasejaču jednom, kao i da su svi signali koji stignu od rasejača do prijemnika iste snage. Elementi kanalne matrice se određuju analizom različitih *multipath*

komponenti, koje pristižu u prijemnik, nakon odbijanja o rasejače. Da bi se odredili uglovi dolazaka ovih *multipath* komponenti u prijemnik potrebno je znati raspodelu rasejača po krugu oko prijemnika. U literaturi se mogu naći različite varijante *one-ring* modela, koje razmatraju različite raspodele rasejača [87]-[91]. Na slici 3.10 prikazan je *one-ring* model kanala za predajnik sa M_T predajnih antena, M_R prijemnih antena i N rasejača $S_R^{(n)}$, $n = 1, 2, \dots, N$ [91].




Slika 3.10 – One-ring model MIMO kanala [91].

U slučaju kada i oko predajnika postoje rasejači, koristi se tzv. *two-ring* model kanala, kod koga, pored kruga rasejača oko prijemnika, postoji i krug oko predajnika po kom su razmešteni rasejači.

3.4.3 Saleh-Valenzuela model kanala

Za potrebe širokopoljnih hibridnih *beamforming* mMIMO sistema nove generacije najčešće se koristi *Saleh-Valenzuela* model kanala [92]-[94]. Ovaj model kanala potpada pod negeometrijske stohastičke modele i zasnovan je na višestrukome prostiranju signala po klasterima. Fizička interpretacija modela prikazana je na slici 3.11. Model pretpostavlja da različiti zranci predajnog signala dolaze u prijemnik u grupama, tj. klasterima, pri čemu svaki zrak i svaki klaster imaju nezavisno slabljenje.



Slika 3.11 – Fizička interpretacija Saleh-Valenzuela modela kanala [93].

Matematički model kanala definisan je impulsnim odzivom:

$$h(t) = \sum_{l=0}^{N_{cl}-1} \sum_{k=0}^{N_{ray}-1} \beta_{kl} \cdot e^{j\theta_{kl}} \cdot \delta(t - T_l - \tau_{kl}), \quad (3.25)$$

gde su: N_{cl} i N_{ray} – broj klastera i broj rasipača u svakom klasteru, respektivno, β_{kl} , θ_{kl} – amplituda i faza k -tog zraka u l -tom klasteru, respektivno, T_l – vreme dolaska l -tog klastera, τ_{kl} – kašnjenje dolaska k -tog zraka u odnosu na prvi zrak l -tog klastera.

Amplituda i faza su slučajne veličine, pri čemu faza ima uniformnu raspodelu na intervalu $[0, 2\pi)$, dok amplituda ima Rejljev (Rayleigh) raspodelu:

$$f(\beta_{kl}) = (2 \beta_{kl} / \overline{\beta_{kl}^2}) e^{-\beta_{kl}^2 / \overline{\beta_{kl}^2}}, \quad (3.26)$$

pri čemu je: $\overline{\beta_{kl}^2}$ – srednja snaga k -tog zraka u l -tom klasteru.

Vreme dolaska klastera i kašnjenje zraka prate Poasonovu (*Poisson*) raspodelu:


$$f(T_l | T_{l-1}) = \Lambda e^{-\Lambda(T_l - T_{l-1})}, \quad (3.27)$$

$$f(\tau_{kl} | \tau_{(k-1)l}) = \lambda e^{-\lambda(\tau_{kl} - \tau_{(k-1)l})}, \quad (3.28)$$

gde su: Λ , λ – srednje vreme dolaska klastera i srednje vreme dolaska zraka, respektivno.

3.4.4 Kronekerov model kanala

Kronekerov (*Kronecker*) model pretpostavlja da na prostiranje signala utiču samo rasejači koji se nalaze u blizini antenskih elemenata predajnika i prijemnika, dok se uticaj rasejača koji se nalaze u udaljenom polju ne razmatra [95]-[97]. Pri modelovanju se pretpostavlja da postoji prostorna stacionarnost, odnosno pretpostavlja se da korelacija između primljenih signala zavisi samo od udaljenosti elemenata, a ne i od tačne lokacije. Kod Kronekerovog modela se smatra da su matrice prostorne korelacije predajnih i prijemnih nizova nezavisne. Pri analizi se razmatraju samo nizovi koji su dvostruko rasejani, dok se *Line-of-Sight* (LoS) komponenta, kao i komponente koje su se odbile o samo jednog rasejača, zanemaruju. Na slici 3.12 prikazan je Kronekerov model kanala.



Slika 3.12 – Kronekerov model kanala [95].

3.5 Neželjeni efekti u MIMO sistemu

Primena MIMO tehnika za bežične komunikacije pored velikog broja prednosti, poput povećanja pouzdanosti i kapaciteta sistema, donosi i određene izazove pri dizajniranju primopredajnika i obradi signala koji se prenosi. Kao što je izloženo u drugom poglavlju, pojačavači snage koji se koriste pri dizajniranju predajnika utiču na nelinearnost signala, čime se degradira kvalitet signala u bežičnim komunikacionim sistemima. Pored neželjenih efekata koje unosi pojačavač, curenja lokalnog oscilatora i nebalansiranosti I/Q grana, koji se javljaju i kod SISO sistema, u MIMO sistemima dolazi i do preslušavanja između RF grana predajnika.

3.5.1 Uticaj pojačavača snage

Kao što je izloženo u drugom poglavlju idealna prenosna karakteristika pojačavača je linearna, dok kod realnih pojačavača prenosna karakteristika odstupa od linearne, odnosno postoji oblast saturacije u kojoj promena izlaznog signala ne prati promenu ulaznog signala u pojačavač. Realna prenosna karakteristika pojačavača se može aproksimirati funkcijom drugog ili trećeg reda [16]. Ukoliko se nelinearnost pojačavača predstavi polinomijalnom funkcijom trećeg reda, izlazni signal se može zapisati sledećom relacijom:

$$x_{\text{out}}(t) = K_1 \cdot x_{\text{in}}(t) + K_3 \cdot x_{\text{in}}^3(t),$$

(3.29)

gde su: a_1, a_3 – koeficijenti modela, $x_{in}(t)$ – sinusoidalan ulazni signal dat sa:

$$x_{in}(t) = a \sin(\omega t). \quad (3.30)$$

Zamenom (3.30) u (3.29) i primenom osnovnih trigonometrijskih jednačina, dobija se:

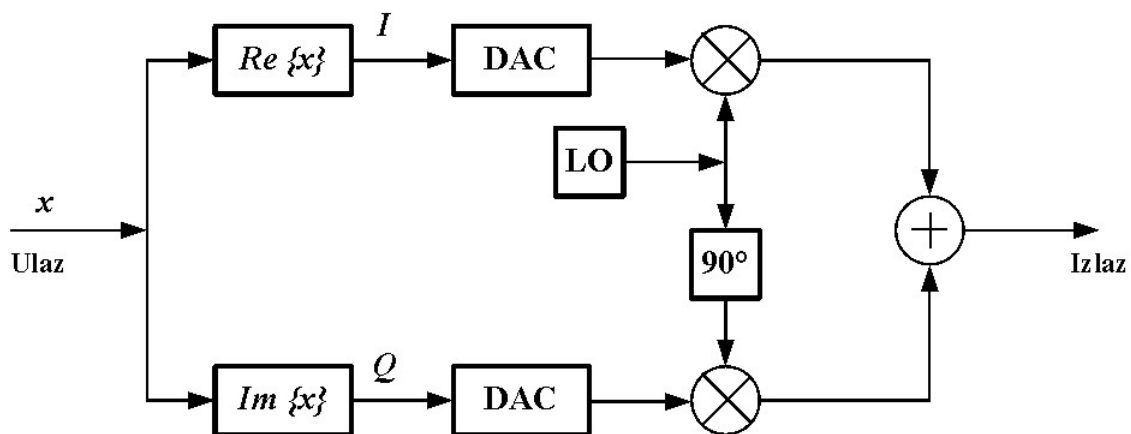
$$x_{out}(t) = \left(K_1 a + \frac{3K_3 a^3}{4} \right) \cdot \sin(\omega t) - \frac{K_3 a^3}{4} \sin(3\omega t). \quad (3.31)$$

Posmatranjem jednakosti (3.31) može se uočiti da je došlo do pojave tzv. harmonika trećeg reda, odnosno komponente na trostrukoj vrednosti osnovne učestanosti, 3ω . Pored ove distorzije van opsega signala, došlo je i do distorzije u opsegu signala. tzv. *in-band* distorzije, odnosno pored pojačanog osnovnog signala, $K_1 a \sin(\omega t)$, pojavila se i komponenta $\frac{3K_3 a^3}{4} \sin(\omega t)$.

Pri analizi uticaja pojačavača snage, u obzir bi trebalo uzeti i memorijske efekte, koji mogu biti električni i termički. Električni memorijski efekti se javljaju zbog promenljivog frekvencijskog odziva pojačavača, usled postojanja reaktivnih komponenti u pojačavaču, odnosno usled kapacitivnosti i induktivnosti pojačavača. Termički memorijski efekti se javljaju zbog zavisnosti električnih karakteristika pojačavača od temperature, usled promene temperature spoja (*junction temperature*) zbog samozagrevanja i različitih nivoa snage ulaznog signala. Termički efekti se javljaju tokom dužeg vremenskog perioda i stoga se nazivaju još i dugoročni memorijski efekti, dok se električni efekti nazivaju kratkoročni memorijski efekti. Kod širokopojasnih predajnika tipični su električni memorijski efekti, dok su kod uskopojasnih predajnika dominantni termički memorijski efekti [16].

3.5.2 I/Q neuravnoteženost

I/Q neuravnoteženost nastaje kao posledica neusklađenosti komponente u fazi (*I*) i komponente u kvadraturi (*Q*), usled nesavršenost I/Q modulatora koji je zadužen za konverziju signala iz osnovnog opsega u RF opseg. Na slici 3.13 prikazana je blok šema I/Q modulatora. Sa slike se može videti da se komponenta u fazi i komponenta u kvadraturi vode na nezavisne DAC konvertore. Usled njihove nesavršenosti dolazi do nelinearne distorzije koja se ispoljava kao DC *offset*. Ovi signali se zatim primenom kvadraturnog *up*-konvertora konvertuju iz osnovnog opsega u RF opseg, pri čemu može doći do distorzije signala koja se ispoljava kao I/Q neuravnoteženost.



Slika 3.13 – Blok šema I/Q modulatora.

Usled prisustva I/Q neuravnoteženosti signal na izlazu I/Q modulatora $P \times P$ MIMO sistema se može modelovati sledećim formulama:

$$\hat{x}_p(n) = a_p x_p(n) + b_p x_p^*(n), \quad (3.32)$$

$$a_p = \cos(\theta_p/2) + j\alpha_p \sin(\theta_p/2), \quad (3.33)$$

$$b_p = \alpha_p \cos(\theta_p/2) + j \sin(\theta_p/2), \quad (3.34)$$

gde je: $x_p(n)$ – ulazni signal u osnovnom opsegu p -te grane, $p = 1, 2, \dots, P$, α_p i θ_p – nebalansiranost pojačanja i faze p -te grane. Kod idealno izbalansiranog I/Q modulatora je $\alpha_p = 1$ i $\theta_p = 0^\circ$.

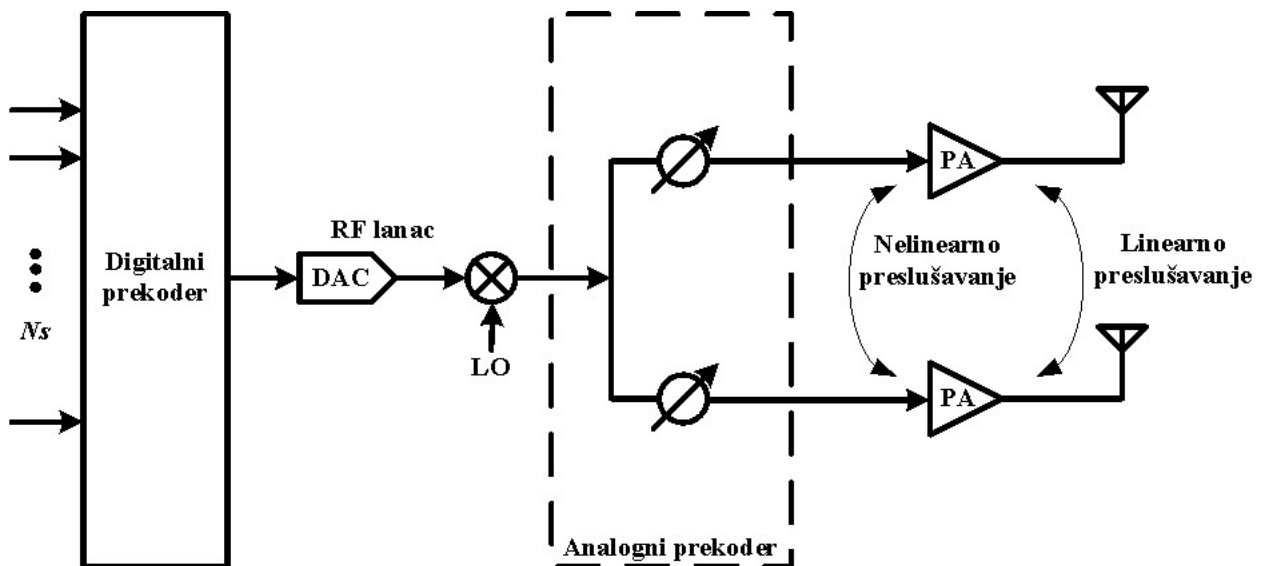
I/Q neuravnoteženost se može iskazati korišćenjem tzv. *Image Rejection Ratio* (IRR), odnosno odnosa snage tzv. signala interferencije slike (*image interference signal*) i snage željenog signala u osnovnom opsegu, definisanim sledećom relacijom:

$$\Gamma_p(\text{dB}) = 20 \log_{10}(b_p/a_p). \quad (3.35)$$

U praksi, vrednosti IRR-a se kreću od -40 dB do -20 dB [98].

3.5.3 Efekat preslušavanja

Zbog međusobne sprege jedne RF grane u odnosu na drugu kod MIMO predajnika, dolazi do pojave preslušavanja (*crosstalk*). U zavisnosti od toga gde se preslušavanje odvija, može se razlikovati linearno ili nelinearno preslušavanje [99]. Na slici 3.14 su ilustrovana oba tipa preslušavanja.



Slika 3.14 – Linearno i nelinearno preslušavanje u MIMO predajniku.

Linearno preslušavanje se javlja nakon pojačavača i ono se eliminiše u prijemniku. Naziva se linearnim zato što se javlja nakon nelinearnih komponenti i može se modelovati linearnom kombinacijom željenog signala i neželjene interferencije signala druge grane. Signali na izlazu iz antenskog elementa se u slučaju linearnog preslušavanja mogu predstaviti sledećom formulom:

$$y_i = x_i + \sum_{\substack{n=1 \\ n \neq i}}^{Nt} \alpha_{i,n} \cdot x_n, \quad (3.36)$$

gde je: x_i – signal na ulazu u i -ti antenski element, $\alpha_{i,n}$ – faktor antenskog preslušanja koje reflektuje uticaj n -tog antenskog elementa na i -ti antenski element.

Linearno preslušavanje dato sa (3.36) se može prikazati u matricnom obliku:

$$Y = AX. \quad (3.37)$$

Korišćenjem algoritma inverzije matrica u prijemniku može se izvršiti kompenzacija linearnog preslušavanja [64].

Nelinearno preslušavanje se javlja pre pojačavača i da bi se uzelo u obzir, izlaz svakog pojačavača se modeluje prikazanom jednačinom:

$$y_i = f_i \left(x_i + \sum_{\substack{n=1 \\ n \neq i}}^{Nt} \alpha_{i,n} \cdot x_n \right), \quad (3.38)$$

gde je: x_i – ulaz u i -ti pojačavač predajnika, f_i – funkcija odziva i -tog pojačavača, $\alpha_{i,n}$ – faktor preslušanja koji reflektuje uticaj n -tog pojačavača na i -ti pojačavač.

U praksi se vrednosti faktora preslušavanja kreću od -30 dB do -15 dB, pri čemu je najgori slučaj kada su faktori preslušavanja međusobno jednaki i iznose -15 dB [100].

Svi navedeni efekti dovode do nelinearne distorzije signala i značajne degradacije kvaliteta signala i stoga je potrebno izvršiti kompenzaciju nelinearne distorzije. Kako se digitalna predistorzija pokazala kao veoma efikasna tehnika za kompenzaciju nelinearne distorzije koju unosi pojačavač, ista tehnika je primenjena i za kompenzaciju I/Q nebalansiranosti u klasičnim SISO sistemima [101]-[102], kao i za kompenzaciju I/Q nebalansiranosti i preslušavanja u MIMO sistemima [35], [98]-[100].

3.6 DPD modeli za MIMO predajnike

Primena klasičnih modela digitalne predistorzije kod mMIMO sistema zahtevala bi postojanje posebnog predistortera i posebne povratne putanje za svaki pojačavač, što bi značajno povećalo složenost sistema, kako u pogledu hardvera, tako i po pitanju obrade povratnih informacija potrebnih za konstrukciju DPD bloka. Ovi ograničavajući činioci predstavljaju motiv mnogim istraživačima za proučavanje digitalne predistorzije u mMIMO sistemima, pri čemu su se razvila dva osnovna pravca istraživanja u zavisnosti od načina prikupljanja i obrade povratnih informacija. Tako se, na osnovu konfiguracije povratne putanje, razlikuju DPD tehnike zasnovane na povratnim informacijama direktno sa kraja predaje (*direct transmit-end*) i DPD tehnike zasnovane na *over-the-air* (OTA) povratnim informacijama [103]. OTA DPD model ne prikuplja povratne informacije direktno sa pojačavača, samim tim donosi znatnu uštedu u pogledu hardverskih resursa. Sa druge strane, OTA DPD model zahteva postavljanje dodatne antene u dalekom polju (*far field*) koja vrši prikupljanje informacija. Kako je odnos signal/šum, SNR, na prijemnom kraju uglavnom nizak, dešava se da se većina nelinearnih komponenti utopi ispod praga šuma. Rezultat toga je nedovoljan dinamički opseg primljenog signala, što može dovesti do problema i poteškoća u određivanju koeficijentata DPD bloka. Takođe, da bi se odredili koeficijenti DPD bloka potrebno je prvi put

poslati nelinearizovan signal kroz kanal, što može dovesti do pojave neželjenih smetnji drugim korisnicima. Iako u literaturi postoji određen broj radova koji razmatraju OTA DPD tehnike kod mMIMO predajnika [68], [104]-[105], zbog navedenih nedostataka OTA DPD tehnike, u ovoj doktorskoj tezi akcenat je stavljen na DPD tehnike zasnovane na povratnim informacijama direktno sa kraja predaje.

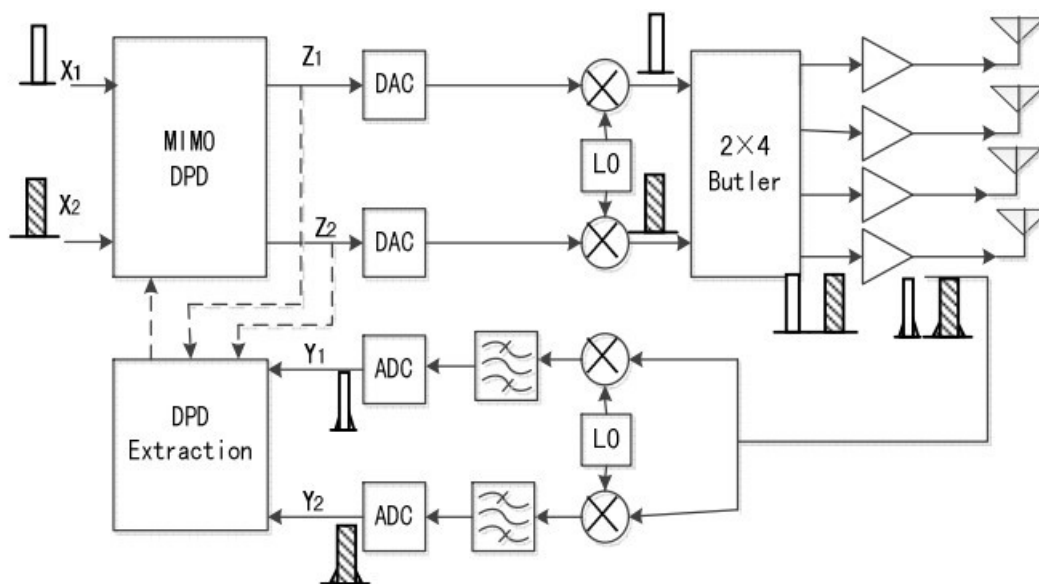
3.6.1 Single-PA-Feedback DPD

Jedno od prvih predloženih rešenja za kompenzaciju nelinearne distorzije kod MIMO predajnika zasniva se na povratnoj informaciji sa samo jednog pojačavača iz niza [17]. Predložen *Single-PA-Feedback* DPD model pretpostavlja da svi pojačavači imaju slične nelinearne karakteristike i da su ulazni signali u sve pojačavače istog nivoa snage. Povratni signal sa jednog pojačavača se nakon konverzije u osnovni opseg (*down conversion*), filtriranja i A/D konverzije, zajedno sa ulaznim signalima u osnovnom opsegu, dovodi u dvodimenzioni *Memory Polynomial* (MP) DPD blok, gde se primenom metoda indirektnog učenja (ILA) određuju koeficijenti digitalnog predistortera. Blok šema modela je prikazana na slici 3.15, dok se matematički model može formulisati sledećim relacijama [17]:

$$y_1(k) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \sum_{j=0}^n a_{mn,1} x_1(k-m) |x_1(k-m)|^{n-j} \times |x_2(k-m)|^j, \quad (3.39)$$

$$y_2(k) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \sum_{j=0}^n a_{mn,2} x_2(k-m) |x_2(k-m)|^{n-j} \times |x_1(k-m)|^j, \quad (3.40)$$

gde su: $x_1(k)$, $x_2(k)$ – ulazni signali, $y_1(k)$, $y_2(k)$ – izlazni signali, M – dubina memorije, N – najveći nelinearni red modela.



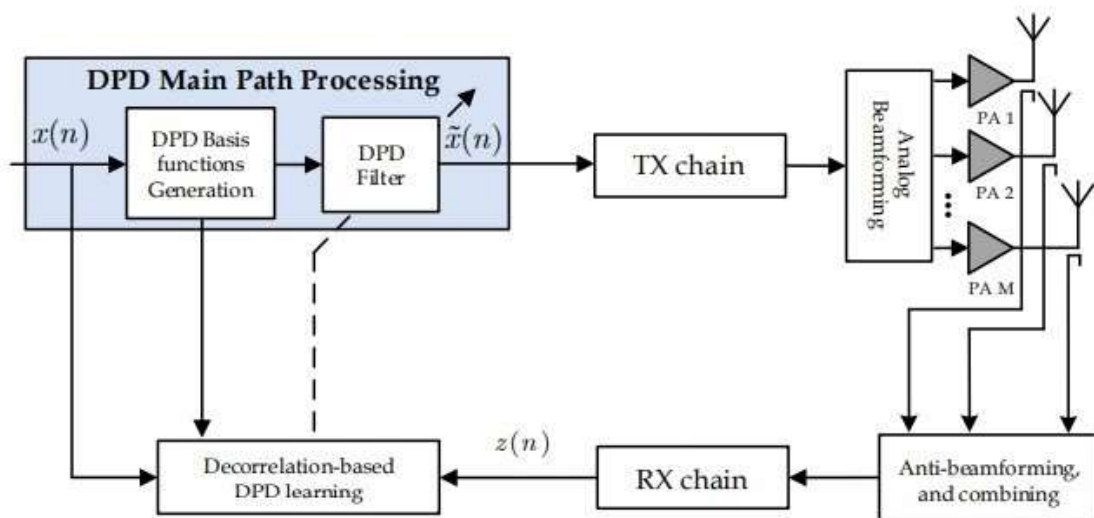
Slika 3.15 – Blok šema *Single-PA-Feedback* DPD modela [17].

Single-PA-Feedback DPD model je eksperimentalno testiran korišćenjem dva različita LTE signala. Prvi signal je širine 3 MHz i PAPR 10 dB, na centralnoj frekvenciji od 2.12 GHz, dok je drugi signal širine 5 MHz, i PAPR 11 dB, na centralnoj frekvenciji 2.18 GHz. Pokazano je da model dosta dobro kompenzuje nelinearnost predajnika i da pojednostavljuje arhitekturu sistema [17]. Glavni nedostatak za primenu ovog modela kod HBF mMIMO predajnika, kod koga

pojačavači mogu znatno da se razlikuju, je što model pretpostavlja da svi pojačavači imaju slične nelinearne karakteristike sa istim nivoom snage ulaznog signala.

3.6.2 Dekorelacioni DPD

U cilju smanjenja izobličenja u pravcu prijemnika, autori u [18] predlažu DPD model zasnovan na kombinovanju povratnih informacija sa izlaza pojedinačnih pojačavača u jednom antenskom podnizu, u sprezi sa pravilom učenja zasnovanim na dekokorelaciji. Ideja je da se minimizuje korelacija između nelinearnog izobličenja posmatranog podniza i statičkih nelinearnih izobličenja osnovnih funkcija i njihovih zakasnelih replika, čime se smanjuje i nivo nelinearnog izobličenja. Sličan model, zasnovan na dekokorelaciji, su autori već opisali i potvrdili u ranijim radovima za predajnik sa jednom antenom [106]-[107]. Blok šema modela prikazana je na slici 3.16.



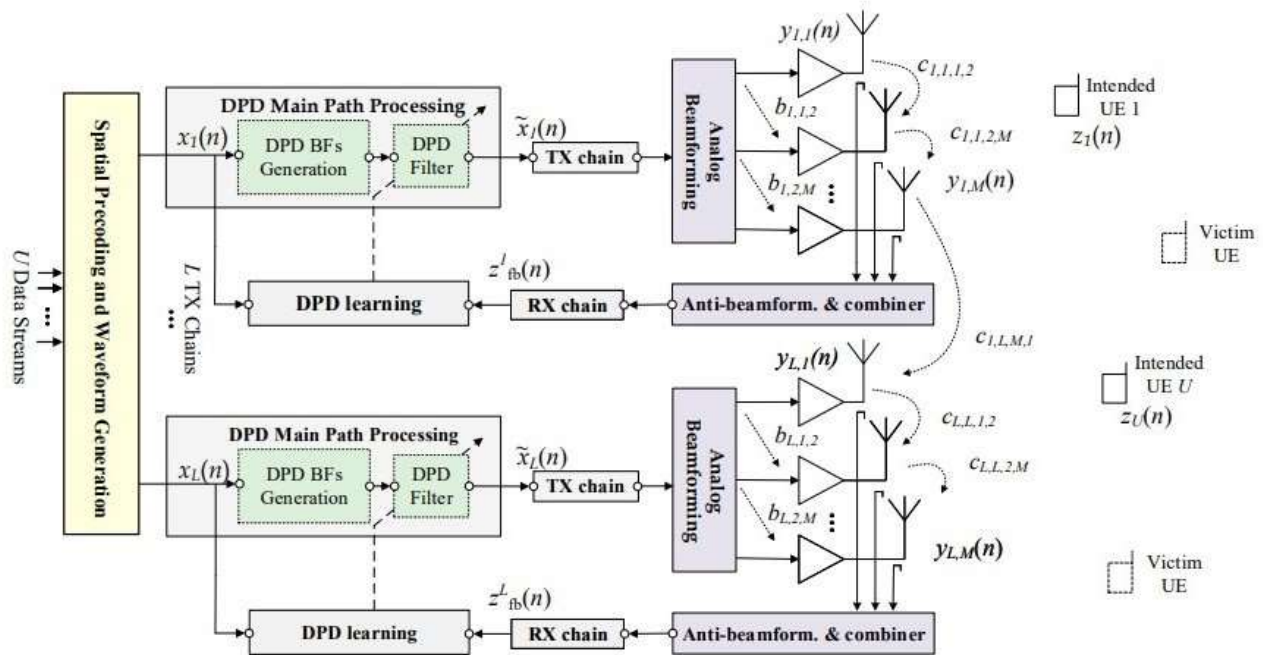
Slika 3.16 – Blok šema dekokorelacionog DPD modela za jedan podniz [18].

Izlazi svakog pojedinačnog pojačavača u podnizu se upotrebom usmerenih spojnika (*couplers*) vode na modul za kofaziranje (*anti-beamforming*) i kombinovanje. Svrha ovog modula je da se poništi efekat koeficijenata analognog *beamforming*-a tako da posmatrani signal u povratnoj grani RX odgovara stvarnom signalu izračenom u smeru nameravanog korisnika. Dekorelacioni DPD model je testiran simulacijama u *Matlab*-u. Pojačavači su modelovani korišćenjem paralelnog *Hammerstein* modela 11. reda, pri čemu su kao podaci za modelovanje uzeti praktično izmereni modeli pojačavača na frekvenciji od 2 GHz, dobijeni iz testne laboratorije za mMIMO Univerziteta Lund. Red nelinearnosti predloženog dekokorelacionog DPD modela je $K=9$, a dubina memorije je $N=3$. U simulacijama je korišćen OFDM signal širine 20 MHz sa 16-QAM modulacijom podnosilaca, dok je PAPR signala ograničen na približno 8.3 dB. Korišćenjem predloženog dekokorelacionog DPD-a autori su, u poređenju sa DPD modelom koji koristi izlaz samo jednog pojačavača za učenje, postigli dobitak od više od 10 dB u ACLR-u (*Adjacent Channel Leakage Ratio*) [18].

3.6.3 Closed-loop DPD

Kompenzacija nelinearne distorzije kod mMIMO predajnika sa više korisnika analizirana je u [19], gde je i predloženo *closed-loop* DPD rešenje. U predloženom DPD modelu, koriste se

paralelno po jedan DPD blok, strukturno sličan DPD bloku predloženom za slučaj jednog korisnika u [18], po svakom predajnom TX lancu ili podnizu. Blok šema modela prikazana je na slici 3.17.

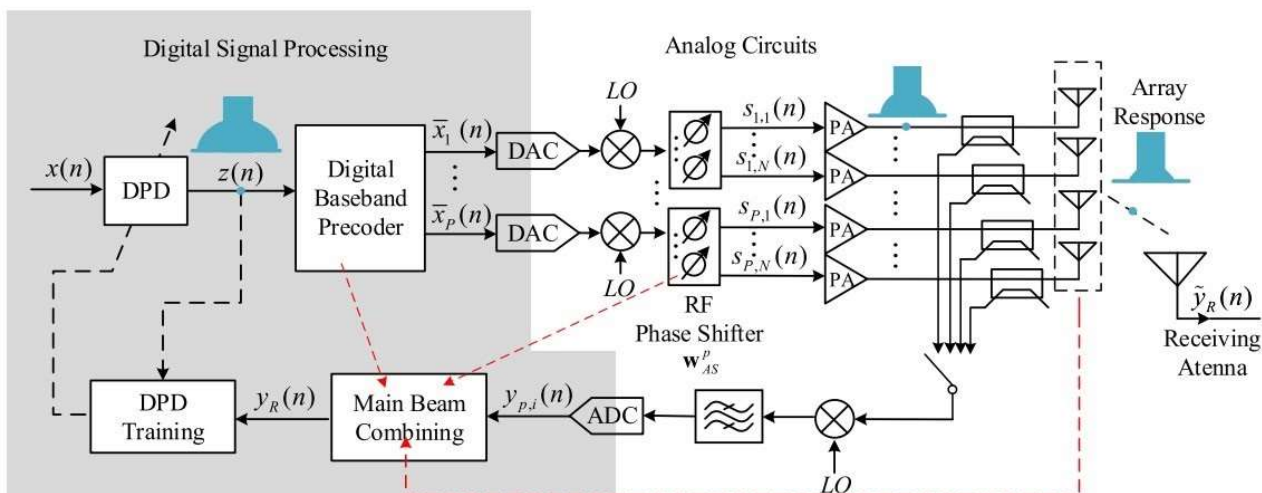


Slika 3.17 – Blok šema closed-loop DPD modela za jedan podniz [19].

Analiza performansi predloženog DPD modela izvršena je simulacijama u *Matlab*-u, pri čemu je za model kanala usvojen *Saleh-Valenzuela* model sa $N_{cl} = 6$ klastera i $N_{ray} = 5$ zraka u svakom klasteru. Pretpostavljeno je da hibridni MIMO predajnik sadrži dva predajna lanca, od kojih svaki ima $M=32$ antenska elementa i odgovarajuće pojačavače (ukupno 64 antene i 64 pojačavača), i da istovremeno opslužuje dva korisnika sa po jednom antenom. Pojačavači su modelovani korišćenjem MP modela reda nelinearnosti $P=11$ i dubine memorije $N=3$, pri čemu su za modelovanje korišćeni izmereni podaci realnog pojačavača na 28 GHz. U simulacijama je korišćen OFDM signal širine 200 MHz, sa razmakom podnosioca od 60 kHz [19].

3.6.4 Beam-Oriented DPD

Osnovna ideja kod *Beam-Oriented* DPD (BO-DPD) modela, predloženog u [20], jeste linearizacija signala glavnog snopa, umesto linearizacije pojedinačnih pojačavača u nizu. U predloženom BO-DPD modelu, digitalni prekoder, RF fazni pomerači, pojačavači i antene se posmatraju kao jedan nelinearni sistem za koji se formira digitalni predistorter. Blok šema modela prikazana je na slici 3.18. U povratnoj grani pre DPD bloka postavljen je modul za kombinovanje signala glavnog snopa. Ovaj modul kombinuje izlaze iz svih pojačavača i na osnovu koeficijenata analognog i digitalnog *beamforming*-a vrši procenu signala glavnog snopa.

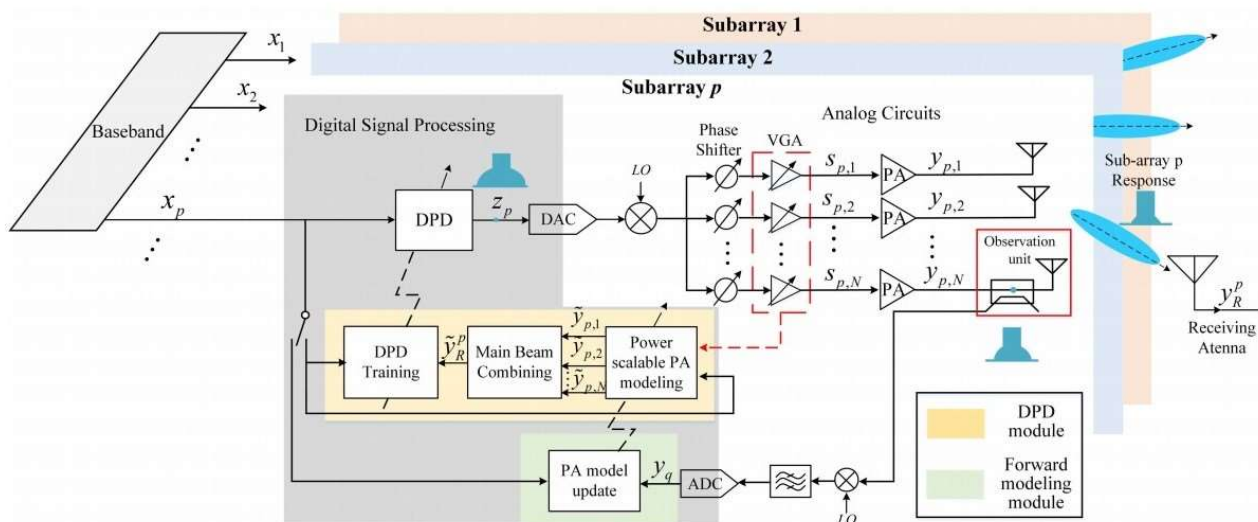


Slika 3.18 – Blok šema BO-DPD modela [20].

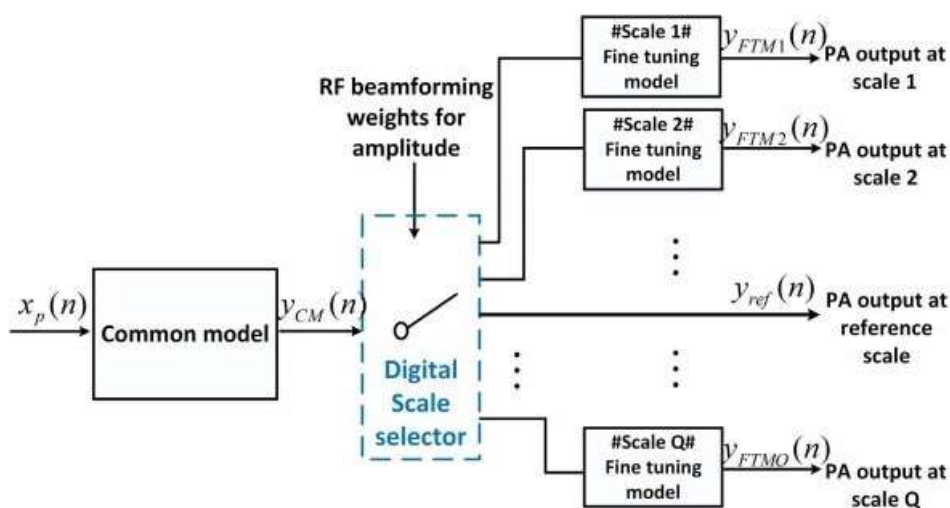
Model je testiran simulacijama u *Matlab*-u i eksperimentalno. U simulacijama je korišćen uniformni linearni antenski niz sa 4 podniza i 16 antena u svakom podnizu (*4x16 Uniform Linear Array* – ULA) sa *patch* antenama razmaka $\lambda/2$, na 3.5 GHz, dok su eksperimentalna merenja vršena sa 1x2 ULA na 2.5 GHz i sa 2x2 ULA na 3.5 GHz. Na ulaz su dovedena dva LTE signala širine 10 MHz i PAPR od 9.4 dB. Za modelovanje samog predistortera koristi se MP model, dubine memorije $N=3$ i reda nelinearnosti $K=7$. Eksperimentalno je pokazano da predloženi BO-DPD model postiže poboljšanje ACPR od oko 15 dB [20].

3.6.5 Power-Scalable Beam-Oriented DPD

Power-Scalable Beam-Oriented DPD (PSBO-DPD) model, predložen u [21], modeluje i linearizuje signal glavnog snopa jednog podniza HBF mMIMO predajnika, na osnovu povratne informacije samo jednog pojačavača iz datog podniza. Blok šema modela prikazana je na slici 3.19. Da bi se konstruisao signal glavnog snopa podniza, potrebno je prethodno izvršiti procenu izlaznih signala pojačavača posmatranog podniza. Kako su kod većine komercijalnih proizvoda pojačavači u jednom antenskom nizu slični, moguće je izvršiti modelovanje samo jednog pojačavača kada radi na različitim nivoima snage, i zatim tako formiran model koristiti za predviđanje izlaza preostalih pojačavača u podnizu. Za efikasnu procenu izlaza pojačavača predložen je kaskadni model pojačavača skalabilan po snazi (*power scalable cascade PA model*). Blok šema predloženog kaskadnog modela pojačavača skalabilnog po snazi prikazana je na slici 3.20. Model se formira kaskadnom vezom zajedničkog modela i niza modela za fino podešavanje. Zajednički model se formira na osnovu izlaznog signala pojačavača na referentnom nivou snage, koristeći model ponašanja koji može da modeluje i statička izobličenja i memorijske efekte, kao što je npr. generalizovan MP (*Generalized Memory Polynomial* – GMP) model. Modeli za fino podešavanje se formiraju na osnovu izlaznih signala posmatranog pojačavača pobuđenog različitim nivoima snage, koristeći jednostavnije modele nižeg reda, kao što su *MemoryLess Polynomial* (MLP) modeli, ili *box-oriented* modeli formirani kaskadnom vezom statičkih modela i FIR filtera.



Slika 3.19 – Blok šema PSBO-DPD modela [21].



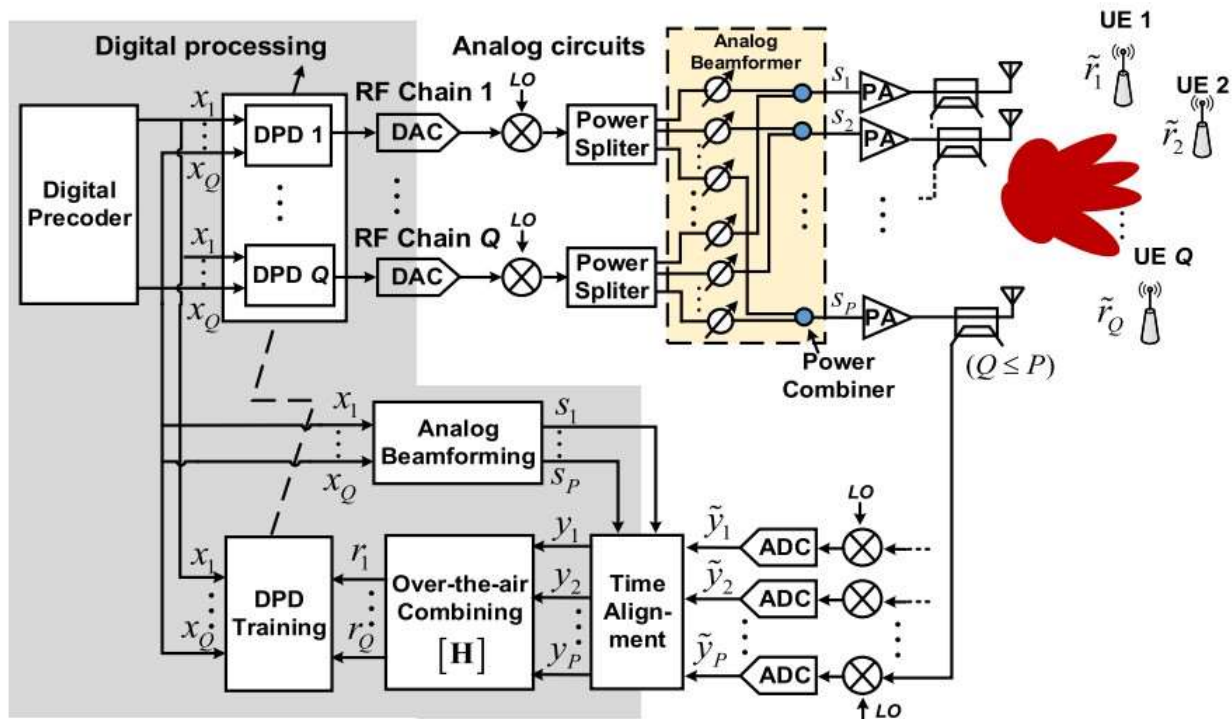
Slika 3.20 – Blok šema kaskadnog modela pojačavača skalabilnog po snazi [21].

PSBO-DPD model je eksperimentalno verifikovan za dva različita tipa pojačavača (*Cree CGH40010p class-AB PA* i *Doherty PA*) korišćenjem uniformnog linearnog antenskog niza sa 4 elementa, pri čemu je za testiranje na pojačavaču klase AB korišćen 64 QAM signal širine 100 MHz i PAPR od 7.2 dB, dok je za *Doherty* pojačavač korišćen 64 QAM signal širine 60 MHz i PAPR od 7.2 dB. Za formiranje modela pojačavača skalabilnog po snazi korišćen je GMP model dubine memorije $N=6$, reda nelinearnosti $K=5$ i dubine zaostale i vodeće anvelope $L=2$, kao i MLP model reda nelinearnosti $K_{MLP} = 3$. Dobijeni rezultati su pokazali da se korišćenjem PSBO-DPD modela postižu neznatno bolje performanse u odnosu na BO-DPD model, uz znatnu uštedu u pogledu samog hardvera [21].

3.6.6 Multi-Stream Spatial DPD

Svi prethodno izloženi modeli razmatraju delimično povezanu arhitekturu hibridnog *beamforming* MIMO predajnika, koja je jednostavnija, ali i spektralno manje efikasna. *Multi-Stream Spatial* DPD predstavlja jedno od prvih rešenja za potpuno povezanu arhitekturu hibridnih *beamforming* mMIMO predajnika [23]. Blok šema modela prikazana je na slici 3.21. Predloženi model se sastoji od Q predistortera, pri čemu je Q broj RF grana u predajniku. U povratnoj grani se

koriste izlazni signali sa svih pojačavača i korišćenjem modula „*over-the-air combining*“ formiraju se virtuelni snopovi signala u digitalnom domenu. Zatim se konstruišu „multi-varijabilni“ DPD modeli za svaki RF lanac, na osnovu ulaznih signala i procenjenih virtuelnih snopova signala. Predloženi DPD model se sastoji od glavne grane koja vrši kompenzaciju intermodulacionih (IMD) produkata prvog i drugog reda, i pomoćne grane koja vrši kompenzaciju intermodulacionih produkata trećeg i viših redova.



Slika 3.21 – Blok šema Multi-Stream Spatial DPD modela [23].

Model je verifikovan simulacijama u *Matlab*-u i eksperimentalno. U simulacijama je korišćen potpuno povezan uniformni linearni niz sa 64 elementa i 4 niza podataka, dok je u eksperimentima korišćen potpuno povezan uniformni linearni niz sa 4 elementa i 2 niza podataka. Korišćenjem predložene DPD tehnike, postignuto je poboljšanje ACPR od 13 dB i poboljšanje NMSE od 12 dB, [23].

3.6.7 MP DPD za potpuno povezan HBF mMIMO predajnik

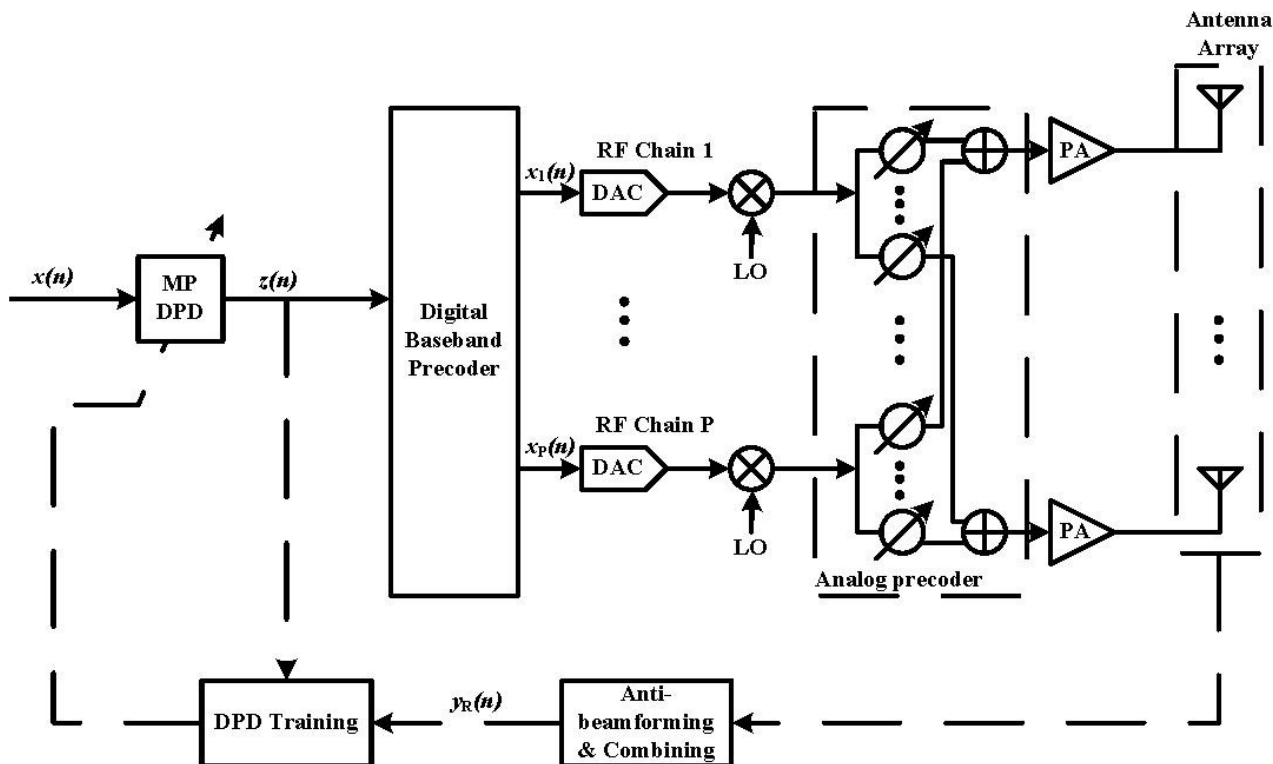
Linearizacija potpuno povezane arhitekture hibridnog *beamforming* mMIMO predajnika je razmatrana i u [70], gde je korišćen jedan MP DPD blok za linearizaciju glavnog snopa. Blok šema modela prikazana je na slici 3.22. Korišćen je MP DPD model, čiji se izlaz računa po formuli:

$$x_{\text{out}}(n) = \sum_{m=0}^M \sum_{k=1}^K a_{mk} \cdot x_{\text{in}}(n-m) \cdot |x_{\text{in}}(n-m)|^{k-1}, \quad (3.41)$$

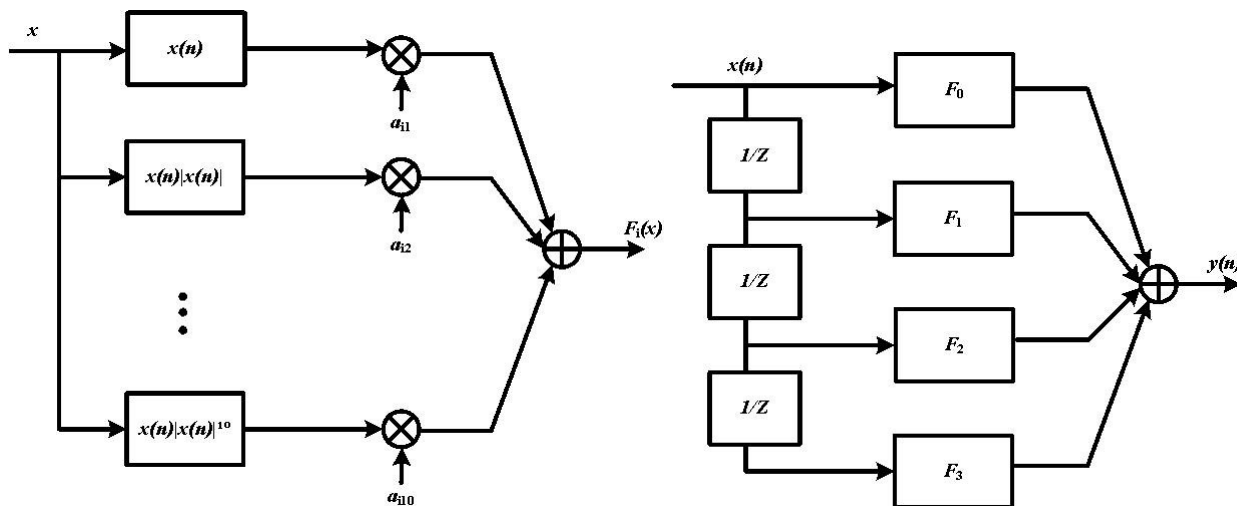
gde su: a_{mk} , K , M – parametri modela, red nelinearnosti i dubina memorije, respektivno.

Predloženi MP DPD model je testiran simulacijama u *Matlab*-u, za različite vrednosti dubine memorije M i različite vrednosti reda nelinearnosti K , na 64x64 MIMO HBF sistemu sa 2 RF grane na predajnoj strani i 2 RF grane na prijemnoj strani. Korišćen je *Saleh-Valenzuela* model kanala, sa

parametrima 6 klastera i 5 rasipača u svakom klasteru. Na ulaz je doveden OFDM signal širine 20 MHz, sa razmakom između podnosioca 15 kHz, generisan u *Matlab*-u. Na slici 3.23 prikazana je blok šema MP modela, za vrednosti parametara $M=3$ i $K=11$.



Slika 3.22 – Blok šema MP DPD modela za FC HBF mMIMO [70].



Slika 3.23 – Blok šema MP modela za $M=3$, $K=11$ [31].

3.6.8 Poređenje različitih DPD modela za MIMO predajnike

Kao što je izloženo u poglavlju 2.5, poređenje različitih DPD modela može se izvršiti posmatrajući njihove performanse, odnosno upoređujući vrednosti normalizovane srednje kvadratne greške, NMSE, i vektora greške amplitude, EVM, koje se dobijaju primenom odgovarajućeg modela za digitalnu predistorziju. Uporedni prikaz performansi DPD modela za hibridne beamforming MIMO predajnike, izloženih u poglavljima 3.6.2-3.6.7, dat je u tabeli 3.1. Na osnovu

prikazanih vrednosti za EVM i NMSE se može primetiti da ovi modeli veoma dobro kompenzuju nelinearnu distorziju kod hibridnog *beamforming* MIMO predajnika, ali da, takođe, postoji i mogućnost za njihovim daljim poboljšanjem. Istraživačima u ovoj oblasti predstoje novi izazovi u vidu otpimizacije postojećih modela, kao i u pronalaženju novih efikasnijih i manje složenih modela za digitalnu predistorziju kod mMIMO predajnika.

Tabela 3.1 – Performanse DPD modela za hibridne *beamforming* MIMO predajnike.

Referenca	Signal	Širina signala [MHz]	PAPR [dB]	EVM [%]	NMSE [dB]
[18]	16-QAM OFDM	20	8.3	1.85	-
[19]	OFDM	200	8.3	2.25 ^a 2.32 ^b	-
[20]	LTE	10	9.4	-	-34.28
[21]	64 QAM	100	7.2	1.13 ^c	-
[21]	64 QAM	60	7.2	1.49 ^d	-
[23]	64 QAM	20	-	-	-37.41
[70]	OFDM	20	-	1.71	-35.33

^a. UE1 – korisnik 1,

^b. UE2 – korisnik 2

^c. Class AB PA

^d. Doherty PA

4. NEURALNE MREŽE

Veštačke neuralne mreže (*Artificial Neural Network* – ANN), često nazivane i samo neuralne mreže (*Neural Network* – NN), su paralelni računarski sistemi dizajnirani tako da njihova struktura i način funkcionisanja podržava način na koji funkcioniše ljudski mozak. Sastoje se od jednostavnih računarskih jedinica koje se nazivaju čvorovi ili neuroni, međusobno gusto povezanih i grupisanih po slojevima, tako da je omogućena paralelna obrada informacija. Poput ljudskog mozga, veštačke neuralne mreže stiču znanje iz okruženja kroz proces učenja, pri čemu se to znanje skladišti u sinaptičke veze između neurona [108]. Proces učenja se sprovodi kroz tačno definisane „algoritme učenja“ kojima se vrši postepeno menjanje sinaptičkih veza između neurona, odnosno matematički posmatrano menjaju se težinski koeficijenti.

Istorijski gledano, razvoj veštačkih neuralnih mreža započinje radom MekKuloha (*W.S.McCulloch*) i Pita (*W.Pitts*), 1943. godine [109], koji su matematički opisali model biološkog neurona. Za ovim je usledio Hebov (*D.O.Hebb*) rad, 1949. godine [110], u kom je opisan mehanizam učenja kod bioloških neurona i istaknuto da se učenje može posmatrati kao proces modifikacija sinaptičkih težina. Opisani mehanizam predstavlja jedno od prvih pravila učenja, koje je kasnije usvojeno i primenjeno i u veštačkim neuralnim mrežama. Praktična primena veštačkih neuralnih mreža započinje radom Rozenblata (*F.Rosenblatt*), 1958. godine [111], koji je izumeo neuralnu mrežu poznatu kao *perceptron*. Zajedno sa kolegama izgradio je mrežu perceptrona i pokazao da je predložena mreža sposobna da izvrši prepoznavanja oblika. Odmah za njim, usledio je i rad Vidrova (*B.Widrow*) i Hofa (*M.E.Hoff*), 1960. godine [112], koji su predstavili novi tip neurona poznat kao ADALINE (*ADaptive LInear Element*) i novi algoritam učenja, poznat kao *Least Mean Squares* (LMS) algoritam ili Vidrov-Hofov (*Widrow-Hoff*) algoritam.

Sedamdesetih i osamdesetih godina prošlog veka, pojavljuje se veliki broj novih istraživačkih radova i započinje intenzivan razvoj u oblasti veštačkih neuralnih mreža. Neki od najznačajnijih su radovi Kohonena (*Kohonen*), Grosberga (*Grossberg*), Hopfilda (*Hopfield*), Rumelharta (*D.Rumelhart*), MekKlilanda (*J.McClelland*),... Kohonen je predložio model korelacione matrice za asocijativne modele [113], postavio fundamentalne teorije distribuirane asocijativne memorije i dao veliki doprinos ovoj oblasti razvojem samoorganizujućih mapa (*Self-Organizing Map* – SOM), poznatih i kao Kohonenove mreže [114]. Grosberg je u svom radu opisao vremenski kontinualnu kompetitivnu mrežu, čija struktura predstavlja osnovu za mnoge druge mreže koje su se kasnije razvile [115]. Hopfild je u svojim radovima isticao praktičnost implementacije predloženih mreža, povezujući svoje neuralne mreže sa modelima koji se koriste u statističkoj fizici [116]-[117]. Rumelhart i MekKliland su dali ključan doprinos za dalji razvoj neuralnih mreža uvođenjem algoritma učenja sa propagacijom greške unazad (*backpropagation algorithm*) za treniranje višeslojnih neuralnih mreža [118].

Zbog svojih sposobnosti da „uče“, pamte i generalizuju na osnovu skupa ulaznih podataka, veštačke neuralne mreže se danas koriste za rešavanje velikog broja problema u različitim naučnim oblastima. Neke od primena neuralnih mreža su: aproksimacija funkcija, modelovanje nelinearnih sistema, prepoznavanje oblika, sinteza i prepoznavanje govora, prepoznavanje i kompresija slika, medicinska dijagnostika, prognoza vremena i klimatskih promena, analize tržišta, procena berze, procene proizvodnje useva,...

Hejkin (*Haykin*) je istakao sledeća bitna svojstva neuralnih mreža [108]:

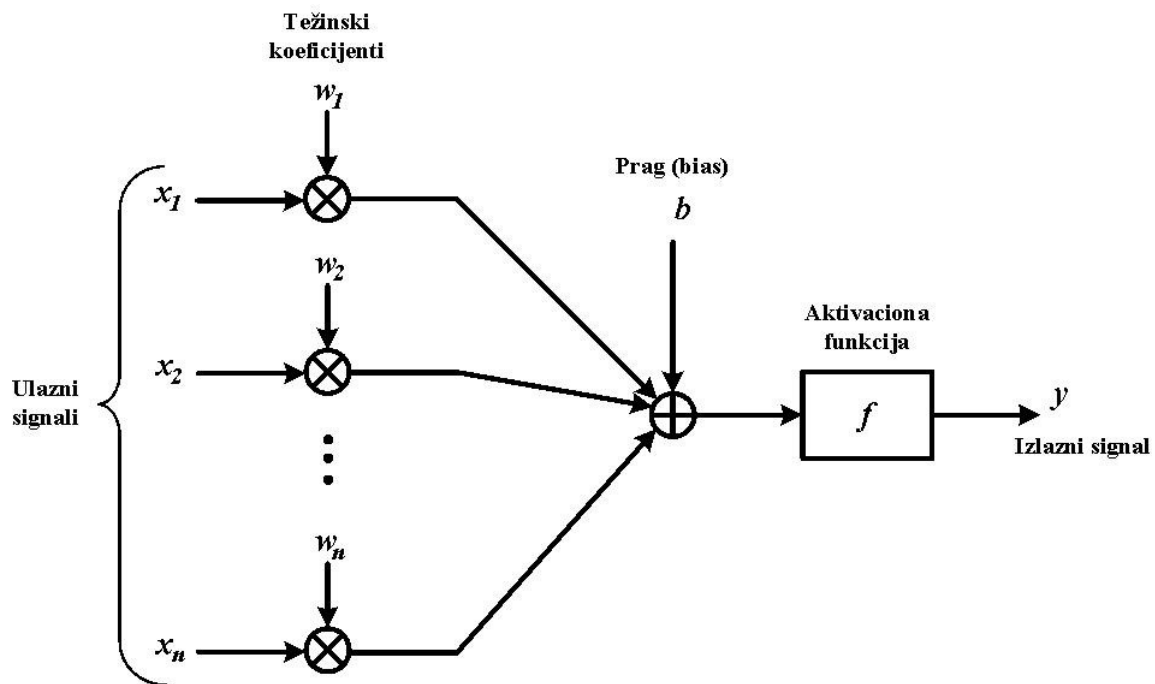
1. Nelinearnost – Veštački neuron može biti linearan ili nelinearan. Ovo je veoma važno svojstvo neurona, pogotovo u slučajevima kada se analiziraju nelinearne pojave u prirodi, poput na primer govornog signala.
2. Mapiranje ulaza i izlaza – Neuralna mreža uči tako što vrši mapiranje ulaznih i izlaznih podataka za zadati problem, odnosno vrši promenu sinaptičkih težina tako da minimizuje razliku između željenog izlaznog signala i generisanog izlaznog signala kad je na ulaz doveden određen signal iz trening skupa.
3. Adaptivnost – Neuralna mreža ima sposobnost da prilagođava sinaptičke težine promenama u okruženju, odnosno neuralna mreža trenirana za rad u određenim uslovima se može lako ponovo istrenirati u slučaju da dođe do promena u okruženju.
4. Evidentni odgovor – Neuralna mreža se može dizajnirati tako da pruža informacije i o pouzdanosti donešene odluke, odnosno generisanog izlaznog podatka.
5. Informacija zavisna od konteksta – Svaki neuron u mreži se pobuđuje aktivnošću svih ostalih neurona u mreži.
6. Tolerancija greške – Neuralna mreža ima mogućnost da bude suštinski tolerantna na greške, što znači da oštećenje neurona ili veze između njih mora da bude značajno da bi se odziv neuralne mreže degradirao. Razlog je taj što su informacije koje je mreža primila tokom procesa učenja sačuvane i distribuiraju se kroz mrežu.
7. Mogućnost implementacije u VLSI (*Very-Large-Scale Integration*) komponente – Zbog svoje paralelne prirode neuralne mreže su pogodne za implementaciju u VLSI komponentama.
8. Uniformnost analize i projektovanja – Isto označavanje se koristi u svim oblastima koje vrše primenu neuralnih mreža, pri čemu neuron predstavlja zajedničku jedinicu za sve neuralne mreže. Ova istovetnost omogućava da se teorije i algoritmi učenja razvijeni u jednoj oblasti primene neuralnih mreža koriste i u drugim oblastima u kojima ih je moguće primeniti.
9. Neurobiološka analogija – Kako je neuralna mreža dizajnirana analogno ljudskom mozgu, neurobiolozi posmatraju neuralne mreže kao istraživačko sredstvo za objašnjenje neurobioloških pojava, dok sa druge strane inženjeri u neurobiologiji traže ideje za rešavanje kompleksnijih problema.

4.1 Model neurona

Osnovni model neurona se sastoji od tri elementa [108]:

- skupa sinapsi, odnosno skupa ulaznih signala sa njihovim težinskim funkcijama,
- sabirača koji vrši linearno kombinovanje ulaznih signala, i
- aktivacione funkcije koja ograničava izlazni signal iz neurona na određeni ograničeni interval.

Blok šema modela neurona prikazana je na slici 4.1.



Slika 4.1 – Blok šema modela neurona.

Matematički opis modela neurona, dat je sledećom relacijom:

$$y = f \left(\sum_{i=1}^n w_i x_i + b \right), \quad (4.1)$$

gde je: y – izlaz posmatranog neurona, x_i – i -ti ulaz u neuron, w_i – težinski koeficijent koji odgovara vezi između i -tog ulaza i posmatranog neurona, b – prag (*bias*) posmatranog neurona, f – aktivaciona funkcija. Težinski koeficijent predstavlja relativan značaj određenog ulaznog signala za posmatrani neuron.

4.1.1 Aktivacione funkcije

Aktivaciona, ili transfer, funkcija definiše izlaz iz posmatranog neurona. Neke od najčešće korišćenih aktivacionih funkcija su: linearna prenosna funkcija, funkcija praga (*threshold*), deo-po-deo linearna funkcija (*piecewise-linear*), sigmoidna funkcija (*sigmoid*), ispravljena linearna funkcija (*Rectified Linear Unit – ReLU*) [119], i prikazane su na slici 4.2.

Linearna aktivaciona funkcija je data sledećom relacijom:

$$f(x) = x. \quad (4.2)$$

Ovaj tip aktivacione funkcije se obično koristi u izlaznom sloju višeslojnih neuralnih mreža koje se koriste za različite aproksimacije. U *Matlab*-u se poziva funkcijom *purelin*.

Funkcija praga je data sledećom relacijom:

$$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}. \quad (4.3)$$

Ovaj tip aktivacione funkcije se obično koristi za klasifikaciju ulaznih podataka u dve različite kategorije. U *Matlab*-u se poziva funkcijom *hardlim*.

Deo-po-deo linearna funkcija je data sledećom relacijom:

$$f(x) = \begin{cases} 1, & x > 1 \\ x, & 0 \leq x \leq 1 \\ 0, & x < 0 \end{cases} \quad (4.4)$$

U *Matlab*-u se poziva funkcijom *satlin*.

Sigmoidna funkcija je najčešće korišćena aktivaciona funkcija i data je sledećom relacijom:





$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.5)$$


U *Matlab*-u se poziva funkcijom *logsig*. Tangens hiperbolički predstavlja varijantu sigmoidne funkcije koja omogućava postojanje i negativnih izlaznih vrednosti, u *Matlab*-u se poziva funkcijom *tansig*, i definisana je sledećom relacijom:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (4.6)$$

Ispravljena linearna funkcija se može opisati sledećom relacijom:

$$f(x) = \max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4.7)$$





Slika 4.2 – Tipovi aktivacionih funkcija: a) linearna, b) funkcija praga, c) deo-po-deo linearna, d) logsig, e) tansig, f) ispravljena linearna.

4.2 Arhitektura neuralne mreže

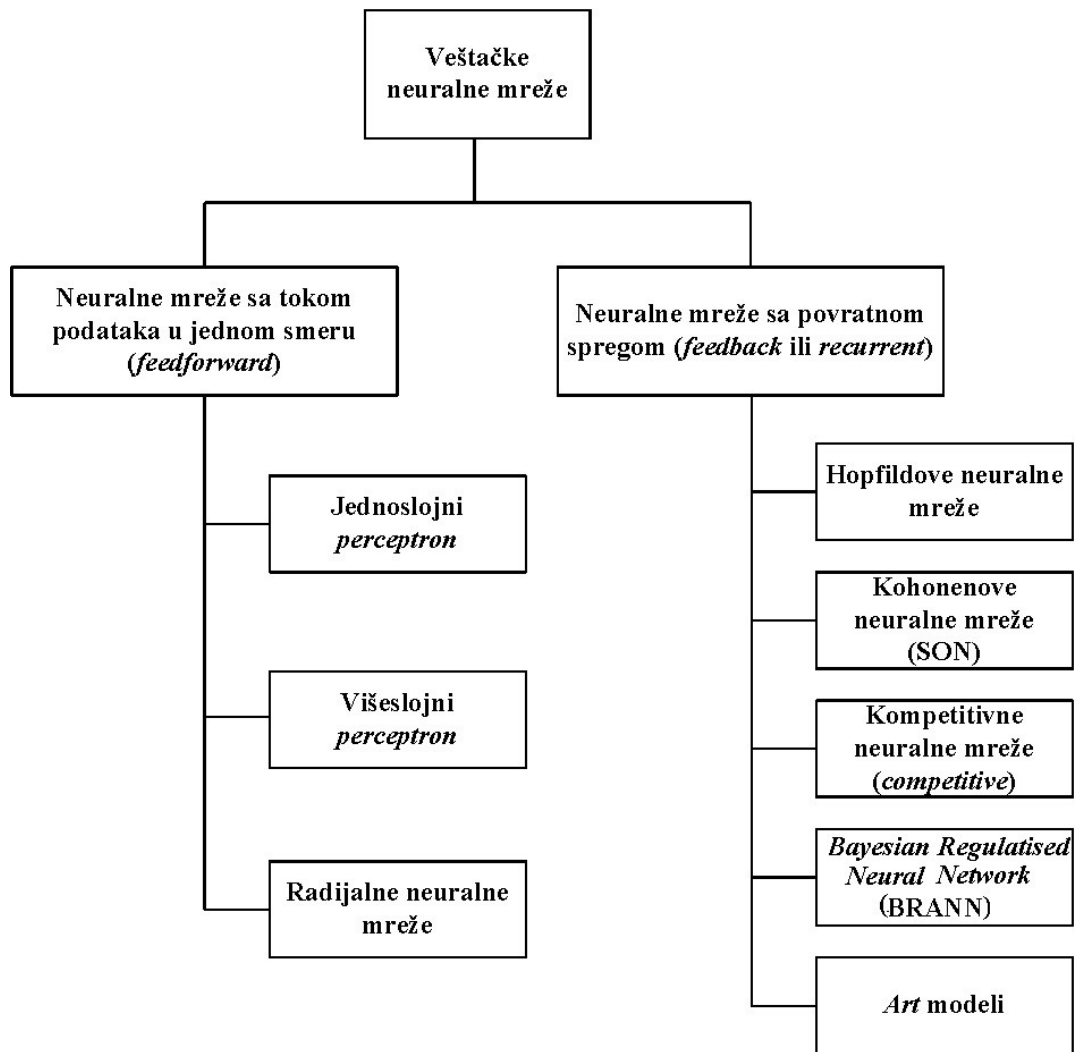
Neuralna mreža se može predstaviti korišćenjem usmerenih grafova, pri čemu je svaki neuron predstavljen jednim čvorom grafa, dok su veze između neurona predstavljene usmerenim orjentisanim granama grafa prikazujući smer i tok prostiranja informacija kroz mrežu. Čvorovi neuralne mreže su raspoređeni tako da formiraju slojeve: ulazni, skriveni i izlazni sloj. U neuralnoj mreži može postojati samo jedan ulazni i samo jedan izlazni sloj. Ulazni sloj služi za prikupljanje ulaznih podataka u mrežu i ne učestvuje u samim proračunima. Izlazni sloj služi za generisanje konačnog rezultata obrade neuralne mreže.

Na osnovu broja slojeva neuralne mreže se dele na jednoslojne i višeslojne neuralne mreže, pri čemu se ulazni sloj ne broji zato što ne učestvuje u proračunima, već samo prosleđuje informacije do sledećeg sloja [108]. Jednoslojne neuralne mreže se sastoje od ulaznog i izlaznog sloja, dok višeslojne neuralne mreže pored ulaznog i izlaznog sloja sadrže i jedan ili više skrivenih slojeva. U zavisnosti od broja skrivenih slojeva, višeslojne neuralne mreže se dalje dele na „plitke“ i „duboke“ neuralne mreže. Plitke neuralne mreže (*Shallow Neural Network – SNN*) imaju jedan ili dva skrivena sloja, dok duboke neuralne mreže (*Deep Neural Network – DNN*) imaju tri ili više skrivenih slojeva, sa većim brojem neurona u svakom od slojeva.

Prema načinu na koji su neuroni međusobno povezani, tj. prema smeru prostiranja signala kroz mrežu, razlikuju se dva tipa mreža:

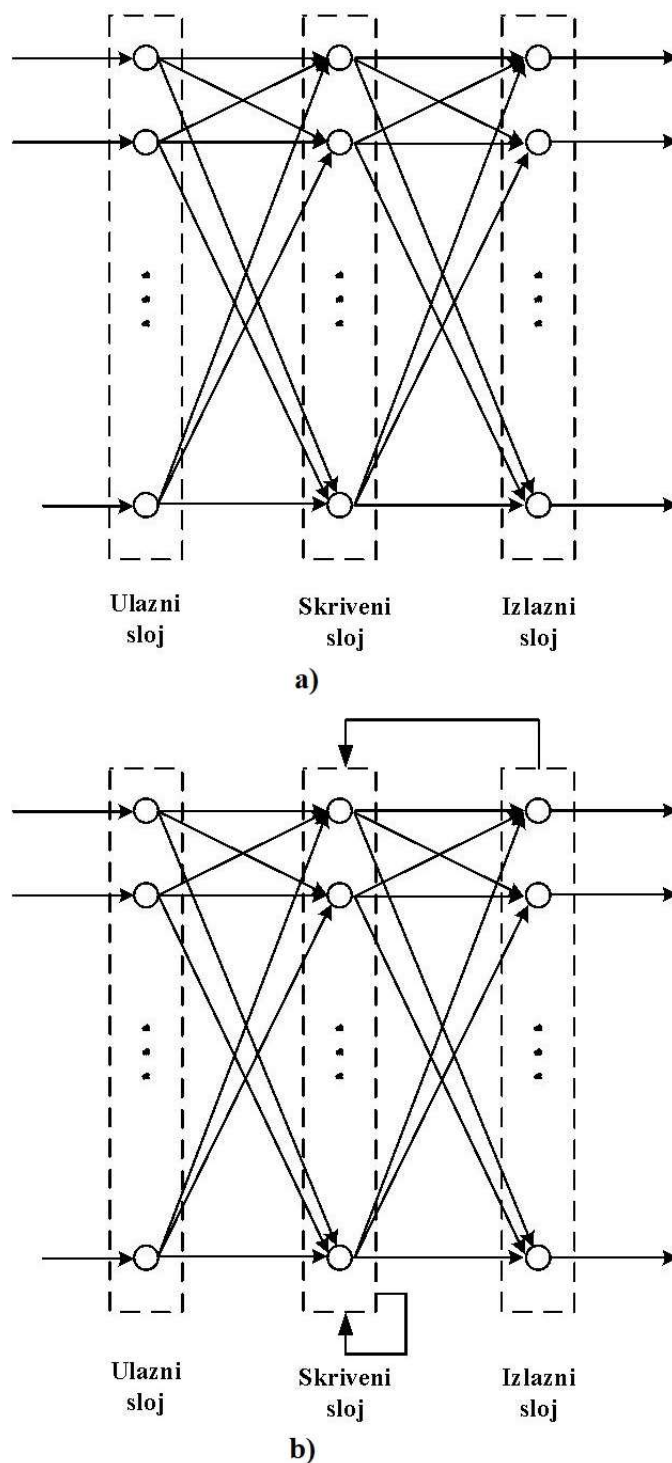
- neuralne mreže sa tokom podataka u jednom smeru (*feedforward*),
- neuralne mreže sa povratnom spregom (*feedback* ili *recurrent*).

Opšta podela neuralnih mreža [120]-[121] prikazana je na slici 4.3.



Slika 4.3 – Klasifikacija neuralnih mreža.

Kod neuralnih mreža sa tokom podataka u jednom smeru viši slojevi mreže ne vraćaju informacije u niže slojeve, odnosno propagacija signala se vrši samo u jednom smeru (od ulaza ka izlazu mreže), a pridruženi grafovi nemaju povratne petlje. Jedan od najznačajnijih predstavnika ovog tipa mreža je višeslojni *perceptron* sa primenjenim *backpropagation* algoritmom kod koga signal greške propagira unazad. Kod neuralnih mreža sa povratnom spregom viši slojevi vraćaju informacije u niže slojeve ili u isti sloj, a pridruženi grafovi sadrže petlje. Tipični predstavnici ovog tipa mreža su Hopfieldove (*Hopfield*) neuralne mreže i Kohonenove (*Kohonen*) samoorganizujuće mape. Na slici 4.4 prikazane su arhitekture *feedforward* i rekurentne neuralne mreže.



Slika 4.4 – Arhitektura neuralne mreže: a) feedforward, b) rekurentna.

Usled povratnih veza ulazi neurona u rekurentnoj neuralnoj mreži se menjaju, čime se menja i stanje neuralne mreže, stoga rekurentne neuralne mreže predstavljaju dinamičke sisteme. Sa druge strane uvođenjem rekurzije povećava se složenost analize rada mreže i menja se stabilnost rada neuralne mreže. *Time-delay feedforward* neuralne mreže rešavaju problem nestabilnosti koji se javlja kod rekurentnih mreža i imaju dobru sposobnost modelovanja ponašanja pojačavača sa memorijom. Ove mreže spadaju u mreže sa tokom podataka u jednom smeru koje, za razliku od klasičnih *feedforward* neuralnih mreža, sadrže liniju kašnjenja težinskih koeficijenata, odnosno kod kojih svaki neuron ima vezu sa neuronima nižeg sloja i sa njihovim prošlim (zakašnjenim) izlazima.

4.3 Algoritmi učenja

Sposobnost učenja predstavlja jednu od najznačajnijih karakteristika neuralnih mreža. Učenje se odvija kroz iterativni proces podešavanja sinaptičkih težina i pragova, pri čemu bi nakon svake iteracije neuralna mreža trebalo da ima više znanja o određenom problemu. Matematički posmatrano, proces učenja se može posmatrati kao optimizacioni proces u kom se traži određivanje težinskih koeficijenata, pri čemu se vrši postepena optimizacija kriterijumske funkcije. Vrednost težinskog koeficijenta se menja prema sledećoj formuli:

$$w_{ij}(n + 1) = w_{ij}(n) + \Delta w_{ij}(n), \quad (4.8)$$

pri čemu su: $w_{ij}(n + 1)$ i $w_{ij}(n)$ – nova i stara vrednost težinskog koeficijenta, respektivno, a $\Delta w_{ij}(n)$ – promena težine veze u n -toj iteraciji.

Skup pravila kojima se određuje način izračunavanja $\Delta w_{ij}(n)$ predstavlja algoritam učenja neuralne mreže. Postoji više različitih algoritama učenja, od kojih svaki ima prednosti i mane. Osnovna podela algoritama učenja je na:

- algoritme učenja sa nadgledanjem (*supervised learning*),
- algoritme učenja sa podrškom (*reinforcement learning*),
- algoritme učenja bez nadgledanja (*unsupervised learning*).

Kod učenja sa nadgledanjem, pored ulaznih podataka u mrežu poznati su i očekivani izlazni podaci, a neuralna mreža vrši podešavanje težinskih koeficijenata postepeno upoređujući generisane izlaze sa očekivanim, tako da greška između njih bude što manja. Cilj učenja je da se dobije model koji će davati dobre rezultate, ne samo sa podacima koji se koriste pri obučavanju mreže, već i sa novim podacima. Ovaj vid učenja nalazi primenu u zadacima klasifikacije i predikcije.

Učenje sa podrškom predstavlja oblik nadgledanog učenja kod koga se učenje vrši na osnovu ulaznih podataka i tzv. signala podrške koji predstavlja povratnu informaciju o tačnosti generisanog izlaznog signala. Signal podrške može biti pozitivan ili negativan, u zavisnosti od toga da li je generisan izlazni signal tačan ili ne, a cilj algoritma je dobiti što više nagrada, odnosno iskoristiti signal podrške i utvrditi koji skup akcija dovodi do pozitivnog signala podrške i prema tome korigovati ponašanje mreže. Ovaj tip učenja se koristi pri igranju kompjuterskih igrica, poput recimo šaha, zatim za probleme raspoređivanja i upravljanja određenim mašinama i robotima u raznim okruženjima.

Kod učenja bez nadgledanja ne postoji povratna informacija o generisanim izlaznim vrednostima, već su dati samo ulazni podaci i cilj je pronaći korelaciju između podataka, odnosno utvrditi neku pravilnost ili obrazac ponašanja. Tipični problemi koji se rešavaju ovim vidom učenja su grupisanje podataka i smanjenje dimenzionalnosti, odnosno pronalaženje manjeg skupa podataka koji zadržavaju glavne osobine početnih podataka.

U literaturi postoji veliki broj algoritama učenja, a neki od najčešće korišćenih su: učenje sa propagacijom greške unazad (*backpropagation*), *Levenberg-Marquardt* (LM) algoritam, algoritam skaliranog konjugovanog gradijenta (*Scaled Conjugate Gradient* – SCG), Q učenje, Hebovo učenje, kompetitivno učenje, Bolcmanovo (*Boltzmann*) učenje,...

4.3.1 Učenje sa propagacijom greške unazad

Učenje sa propagacijom greške unazad spada u algoritme učenja sa nadgledanjem i vrši se u dve faze: prvo se računaju izlazi svakog sloja od ulaznog do izlaznog, a zatim se generiše signal greške koji se šalje od izlaznog sloja ka ulaznom sloju i služi za popravljjanje težinskih koeficijenata u prethodnim slojevima. Na ovaj način se greška šalje od izlaznog sloja unazad po jedan sloj sve do ulaznog. Algoritam učenja se sastoji iz sledećih koraka:

1. Inicijalizacija mreže, odnosno postavljanje početnih vrednosti težinskih koeficijenata i pragova, bilo po nekom pravilu ili na slučajan način.
2. Dovođenje podataka za treniranje na ulaz mreže, pokretanje neuralne mreže i izračunavanje izlaznog signala.
3. Izračunavanje greške, odnosno razlike između željenog izlaza mreže za dati skup ulaznih parametara i generisanog izlaznog signala.
4. Propagacija greške unazad od izlaznog sloja do ulaznog sloja i menjanje težinskih koeficijenata kako bi se smanjila greška.
5. Ukoliko je greška dostigla zadatu minimalnu vrednost ili ukoliko je dostignut definisan maksimalan broj epoha algoritam se završava, u suprotnom se algoritam ponavlja od 2. koraka.

Ako se sa d_k obeleži željeni izlazni signal k -tog neurona, i sa y_k generisani izlazni signal k -tog neurona na pobudu ulaznim signalom x , tada se signal greške k -tog neurona u n -toj iteraciji može izračunati korišćenjem sledeće formule:

$$e_k(n) = d_k(n) - y_k(n). \quad (4.10)$$

Cilj algoritma je pronaći optimalan skup težinskih koeficijenata \mathbf{w} tako da se minimizira ukupna kvadratna greška:

$$E(\mathbf{w}) = \frac{1}{2} \sum_k e_k^2. \quad (4.11)$$

Za minimizaciju funkcije greške koristi se tzv. delta (ili Vidrov-Hofovo) pravilo, na osnovu koga je korekcija težinskih faktora u trenutku n definisana sledećom relacijom:

$$\Delta w_{ij}(n) = \eta e_i(n) x_j(n), \quad (4.12)$$

gde je: η – pozitivna konstanta koja određuje brzinu učenja. Za velike vrednosti konstante η algoritam brže konvergira ka minimumu, odnosno ubrzava se učenje, ali istovremeno postoji rizik od nestabilnosti sistema. Dok manje vrednosti konstante η pružaju stabilnost, ali je proces učenja sporiji, odnosno algoritam sporije konvergira ka minimumu.

Postoje dva tipa implementacije algoritma sa propagacijom greške unazad:

- inkrementalni – greška se računa nakon svakog pojedinačnog ulaza, tj. za jedan odbirak ulaznog signala se izračunava izlazni signal i greška koja se šalje unazad, vrši se ažuriranje težinskih koeficijenata, i zatim se procedura ponavlja za svaki odbirak.

- *batch* – greška se računa za sve odбирke ulaznog signala istovremeno, odnosno prvo se primene svi ulazni signali, izračunaju se izlazni signali iz mreže i tek onda se računa greška i vrši ažuriranje težinskih koeficijenata.

4.3.2 LM algoritam

LM algoritam [122] spada u algoritme učenja sa nadgledanjem. Težinski koeficijenti i pragovi se menjaju na osnovu sledećeg izraza:

$$\mathbf{w}^{k+1} = \mathbf{w}^k - [\mathbf{J}_k^T \mathbf{J}_k + \mu_k \mathbf{I}]^{-1} \mathbf{J}_k^T \mathbf{e}_k, \quad (4.13)$$

gde je: \mathbf{J}_k – Jakobijanov (Jacobian) matrica u k -toj iteraciji koja sadrži prve izvode vektora greške u odnosu na težinske koeficijente i pragove, μ_k – parameter učenja u k -toj iteraciji, \mathbf{I} – jedinična matrica, \mathbf{e}_k – vektor greške u k -toj iteraciji.

$$\mathbf{J}_k = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \dots & \frac{\partial e_1}{\partial w_n} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \dots & \frac{\partial e_2}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N}{\partial w_1} & \frac{\partial e_N}{\partial w_2} & \dots & \frac{\partial e_N}{\partial w_n} \end{bmatrix}, \quad (4.14)$$

$$\mathbf{e}_k = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_N \end{bmatrix}, \quad (4.15)$$

gde je N ukupan broj težina i pragova.

Za velike vrednosti parametra učenja μ algoritam postaje “*steepest descent*”, dok za male vrednosti parametra μ algoritam postaje Gaus-Njutnov (*Gauss-Newton*).

Algoritam učenja se sastoji iz sledećih koraka:

1. Dovođenje podataka za treniranje na ulaz mreže i izračunavanje izlaznih signala i vektora greške.
2. Računanje Jakobijanove matrice \mathbf{J}_k .
3. Izračunavanje razlike $\Delta \mathbf{w}^k = [\mathbf{J}_k^T \mathbf{J}_k + \mu_k \mathbf{I}]^{-1} \mathbf{J}_k^T \mathbf{e}_k$.
4. Izračunavanje težinskih koeficijenata i pragova, na osnovu razlike $\Delta \mathbf{w}^k$, i računanje novog vektora greške. Ukoliko je nova vrednost manja od vrednosti dobijene u koraku 1, parameter učenja μ smanjiti deljenjem sa definisanim parametrom β (obično 10) i vratiti se na korak 1. Ukoliko vrednost greške nije smanjena, parameter učenja μ uvećati množenjem sa β i vratiti se na korak 3.
5. Algoritam se završava kada greška dostigne neku prethodno definisanu vrednost.

Primena LM algoritma je veoma zastupljena pri obučavanju *feedforward* neuralnih mreža, zbog svoje brze konvergencije srednje kvadratne greške [33].

4.3.3 Algoritam skaliranog konjugovanog gradijenta

Algoritam skaliranog konjugovanog gradijenta [123], kao jedan od oblika algoritama konjugovanog gradijenta, spada u algoritme učenja sa nadgledanjem. Težinski koeficijenti se menjaju na osnovu sledećeg izraza:

$$\mathbf{w}_{k+1} = \mathbf{w}_k - \eta_k \mathbf{d}_k, \quad (4.16)$$

gde je: η_k – parameter brzine učenja u k -toj iteraciji, \mathbf{d}_k – smer promene vektora težine u k -toj iteraciji.

Kod većine algoritama konjugovanog gradijenta parameter brzine učenja u svakoj iteraciji se određuje korišćenjem tehnika linijskog pretraživanja, što povećava složenost algoritma. Kod algoritma skaliranog konjugovanog gradijenta ovo nije slučaj, već se umesto linijskog pretraživanja koristi LM (*Levenberg-Marquardt*) pristup za skaliranje. Tako da se parameter brzine učenja računa po sledećoj formuli:

$$\eta_k = -\mathbf{d}_k^T \nabla \mathbf{E}(\mathbf{w}_k) / \mathbf{d}_k^T \mathbf{s}_k, \quad (4.17)$$

pri tom, algoritam u svakom koraku računa sledeće parametre:

$$\sigma_k = \sigma_{k-1} / |\mathbf{d}_k|, \quad (4.18)$$

$$\lambda_k = 2 \left(\lambda_{k-1} - \frac{\mathbf{d}_{k-1}^T \mathbf{s}_{k-1}}{|\mathbf{d}_{k-1}|^2} \right), \quad (4.19)$$

$$\mathbf{s}_k = \frac{\nabla \mathbf{E} \left(\mathbf{w}_k + \frac{\sigma}{|\mathbf{d}_k|} \mathbf{d}_k \right) - \nabla \mathbf{E}(\mathbf{w}_k)}{\frac{\sigma}{|\mathbf{d}_k|}} + \lambda_k \mathbf{d}_k. \quad (4.20)$$

Početni parametri se definišu pre početka korišćenja algoritma, i najčešće se usvajaju sledeće vrednosti: $\sigma_0 = 5 \cdot 10^{-5}$ i $\lambda_0 = 5 \cdot 10^{-7}$.

4.3.4 Q učenje

Q učenje spada u algoritme učenja sa podrškom i zasnovano je na postojanju Q funkcije koja procenjuje nagradu. Očekivana nagrada za određenu akciju a_t u stanju s_t se označava sa $Q(s_t, a_t)$. Postoje različite varijacije Q učenja [124]. Osnovni princip je postojanje tzv. agenta čiji je zadatak da nauči strategiju koja će maksimizirati kumulativnu nagradu Q , koja je jednaka trenutnoj nagradi uvećanoj za umanjenje buduće nagrade. Vrednost Q funkcije se ažurira korišćenjem sledećeg izraza:

$$Q^{\text{new}}(s, a) \leftarrow Q^{\text{old}}(s, a) + \alpha \left(R(s, a) + \gamma \cdot \max_a Q(s', a) - Q^{\text{old}}(s, a) \right), \quad (4.21)$$

gde je: α – parameter učenja, $R(s, a)$ – trenutna nagrada za izvršenje radnje a u stanju s , γ – koeficijent popusta koji određuje važnost budućih nagrada.

Pre nego što počne učenje, vrši se inicijalizacija, odnosno popunjavanje Q tabele proizvoljnim vrednostima. Zatim se za svaki trenutak t bira akcija a , posmatra se nagrada R , ulazi se u novo stanje s' i ažurira vrednost nagrade Q . Postupak se ponavlja sve dok ukupna nagrada ne konvergira ka određenoj vrednosti.

Postoje različite varijante Q učenja, koje se generalno mogu podeliti u dve grupacije:

- Q algoritmi sa jednim agentom – osnovno Q učenje, duboko Q učenje koje kombinuje konvolucione neuralne mreže (*Convolution Neural Network* – CNN) sa osnovnim Q učenjem, hijerarhijsko Q učenje, dvostruko Q učenje, QV učenje,...
- Q algoritmi sa više agenata – modularno Q učenje, *EMA* Q učenje, *Nash* Q učenje, kooperativno Q učenje sa više agenata,...

Kod Q algoritama učenja sa više agenata, Q funkcija zavisi od više tzv. agenata, odnosno vrednost Q funkcije je $Q(s, a_1, \dots, a_n)$.

4.3.5 Hebovo učenje

Hebovo pravilo učenja je jedno od najstarijih pravila učenja i spada u pravila učenja bez nadgledanja. Jedna od formulacija Hebovog pravila učenja je [108]:

- Ako se dva neurona sa obe strane sinapse aktiviraju istovremeno (sinhrono), onda se snaga te sinapse, odnosno veze, uvećava.
- Ako se dva neurona sa obe strane sinapse aktiviraju asinhrono, odnosno jedan neuron ne utiče na drugog, onda se ta sinapsa, odnosno veza, oslabljuje ili elimiše.

Na osnovu ovih formulacija, mogu se izdvojiti četiri osnovna mehanizma Hebovog učenja:

1. Vremenski zavisani mehanizam – Promena sinaptičkih težina zavisi od tačnog trenutka pojave presinaptičkih i postsinaptičkih signala.
2. Prostorni mehanizam – Informacije koje se koriste za izmenu lokalnih sinaptičkih težina su prostorno i vremenski povezane, odnosno zavise od lokacije.
3. Interaktivni mehanizam – Promena sinaptičkih težina zavisi od signala na obe strane sinapse, odnosno pravilo učenja zavisi od „prave interakcije“ između presinaptičkih i postsinaptičkih signala i nije moguće izvršiti predikciju jednog bez postojanja drugog.
4. Vezni ili korelacioni mehanizam – Uslov za promenu sinaptičkih težina je zajedničko pojavljivanje presinaptičkih i postsinaptičkih signala, odnosno statistički gledano korelacija u vremenu između presinaptičkih i postsinaptičkih signala odgovorna je za promenu sinaptičkih težina.

Matematički formulirano, težinski koeficijenti sinapsi se menjaju prema sledećem pravilu:

$$\Delta w_{ij}(n) = \eta y_i(n) x_j(n), \quad (4.22)$$

gde je: η – koeficijent brzine učenja, $y_i(n)$ – izlaz i -tog neurona, i $x_j(n)$ – j -ti ulaz i -tog neurona.

Uzastopno ponavljanje ulazne pobude i postojanje izlaza, dovodi do rasta težinskog koeficijenta i dolazi do zasićenja. Kako bi se prevazišao ovaj problem predložene su različite modifikacije Hebovog pravila koje imaju za cilj da ograniče rast težinskih koeficijenata.

4.3.6 Kompetitivno učenje

Kompetitivno učenje spada u algoritme učenja bez nadgledanja i zasniva se na principu takmičenja između neurona. U jednom trenutku može biti aktivan samo jedan neuron, tako da se praktično neuroni takmiče za dozvolu da budu aktivni. Takmičenje se odvija tako što se za dati ulazni signal pobeđuje onaj neuron čije su vrednosti vektora težina najbliže ulazu. Tri osnovna elementa kompetitivnog učenja su [108]:

1. Skup istih neurona čije su sinaptičke težine slučajno raspoređene i koji zbog toga različito reaguju na određeni skup ulaznih vektora.
2. Ograničenje koje se postavlja na vrednost „jačine“ svakog neurona.
3. Mehanizam koji dozvoljava neuronima da se takmiče za pravo da odgovore na dati podskup ulaznih vektora, tako da je samo jedan izlazni neuron, ili jedan izlazni neuron po određenoj grupi, aktivan u jednom trenutku.


Matematička formulacija pravila učenja data je sledećim izrazom:

$$\Delta w_{ij}(n) = \begin{cases} \eta(x_j - w_{ij}) & \text{ako je neuron } j \text{ pobedio} \\ 0 & \text{ako je neuron } j \text{ izgubio} \end{cases} \quad (4.23)$$

gde je: η – koeficijent brzine učenja.

Geometrijska interpretacija kompetitivnog učenja prikazana je na slici 4.5, pri čemu su tačkama označeni ulazni vektori, a krstićima vektori sinaptičkih težina tri izlazna neurona. Osnovna pretpostavka je da svaki ulazni vektor \mathbf{x} ima konstantno Euklidsko rastojanje, tako da se može prikazati na N -dimenzionoj jediničnoj sferi, pri čemu je N broj ulaznih čvorova. Takođe je pretpostavljeno da su svi neuroni u mreži ograničeni tako da imaju istu Euklidsku dužinu, odnosno normu, što se matematički može iskazati kao:

$$\sum_j w_{ij}^2 = 1, \text{ za svako } i. \quad (4.24)$$



Slika 4.5 – Geometrijska interpretacija kompetitivnog učenja: a) početno stanje mreže, b) krajnje stanje mreže [108].

Kompetitivno pravilo učenja se ogleda u pomeranju vektora težine w_j pobjedničkog neurona ka ulaznom vektoru x_j . Ovaj oblik učenja je pogodan za rešavanje problema klasifikacije.

4.3.7 Bolcmanovo učenje

Bolcmanovo (*Boltzmann*) učenje je stohastički algoritam učenja zasnovan na teoriji informacija i termodinamici. Neuralne mreže zasnovane na ovom algoritmu učenja nazivaju se *Boltzmann*-ove mašine i u njima neuroni mogu biti u jednom od dva stanja: aktivni (označava se sa +1) ili neaktivni (označava se sa -1). Na osnovu stanja neurona određuje se funkcija energije *Boltzmann*-ove mašine E :

$$E = -\frac{1}{2} \sum_{j \neq k} \sum_k w_{kj} x_k x_j, \quad (4.25)$$

gde je: x_i – stanje i -tog neurona, w_{kj} – sinaptička težina veze k -tog i j -tog neurona.

Neuroni mogu biti „vidljivi“ ili skriveni, pri čemu se pod pojmom „vidljivih“ neurona smatraju neuroni koji vrše interakciju sa okolinom, dok su ostali skriveni. Razlikuju se dva načina rada:

- Spregnuto stanje (*clamped state*) – Svi „vidljivi“ neuroni su fiksirani za specifično stanje određeno okruženjem.
- Stanje slobodnog rada (*free-running condition*) – Svi neuroni, i „vidljivi“ i skriveni, mogu slobodno da rade.

Promena težinskih koeficijenata se vrši koristeći sledeći matematički izraz:

$$\Delta w_{ij}(n) = \eta(\rho_{ij}^+ - \rho_{ij}^-), \quad (4.26)$$

gde je: η – koeficijent brzine učenja, ρ_{ij}^+ i ρ_{ij}^- – korelacije između stanja neurona i i j kada su „vidljivi“ neuroni fiksni i kada su slobodni, respektivno.

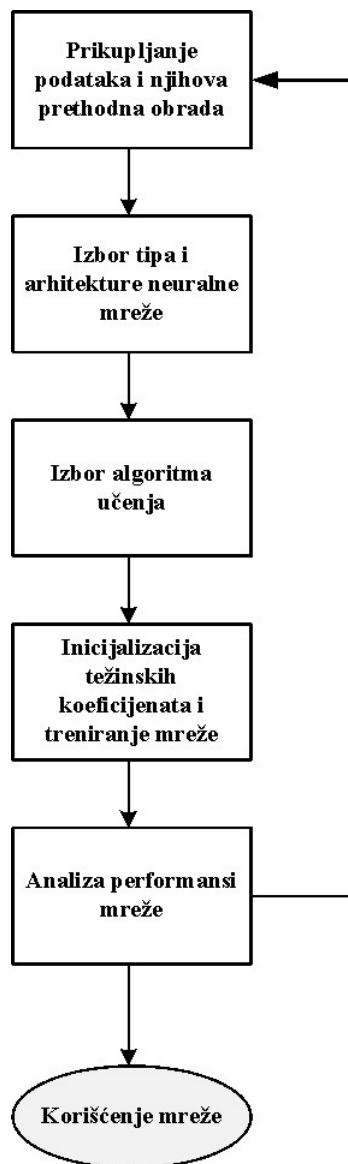
Cilj Bolcmanovog učenja je izmena sinaptičkih težina tako da stanje „vidljivih“ neurona zadovoljava određenu željenu verovatnoću raspodele.

4.4 Treniranje neuralne mreže

Neuralne mreže se koriste za rešavanje različitih problema i potrebno ih je što bolje istrenirati kako bi se postigle maksimalne performanse i ispunili očekivani zadaci. Treniranje neuralne mreže je iterativan proces koji se sastoji iz sledećih nekoliko faza:

- Prikupljanje podataka i njihova prethodna obrada (*preprocessing*) u cilju efikasnijeg treniranja mreže. U ovoj fazi se vrši i podela ulaznog skupa podataka na tri različita podskupa za treniranje, validaciju i testiranje neuralne mreže.
- Izbor odgovarajućeg tipa i arhitekture neuralne mreže. U ovoj fazi se vrši određivanje broja slojeva i broja neurona po slojevima.
- Izbor odgovarajućeg algoritma učenja, u zavisnosti od problema koji mreža treba da rešava.
- Inicijalizacija težinskih koeficijenata i treniranje mreže, prema izabranim parametrima i zadatim ulaznim podacima.
- Analiza performansi mreže. Svrha ove faze je donošenje odluke o tome da li je izabrana mreža adekvatna za problem koji treba rešiti. Ukoliko performanse mreže nisu zadovoljavajuće ceo proces se ponavlja sve dok se ne postignu zadovoljavajuće performanse neuralne mreže.

Na slici 4.6 dat je grafik dijagrama toka procesa treniranja neuralne mreže.



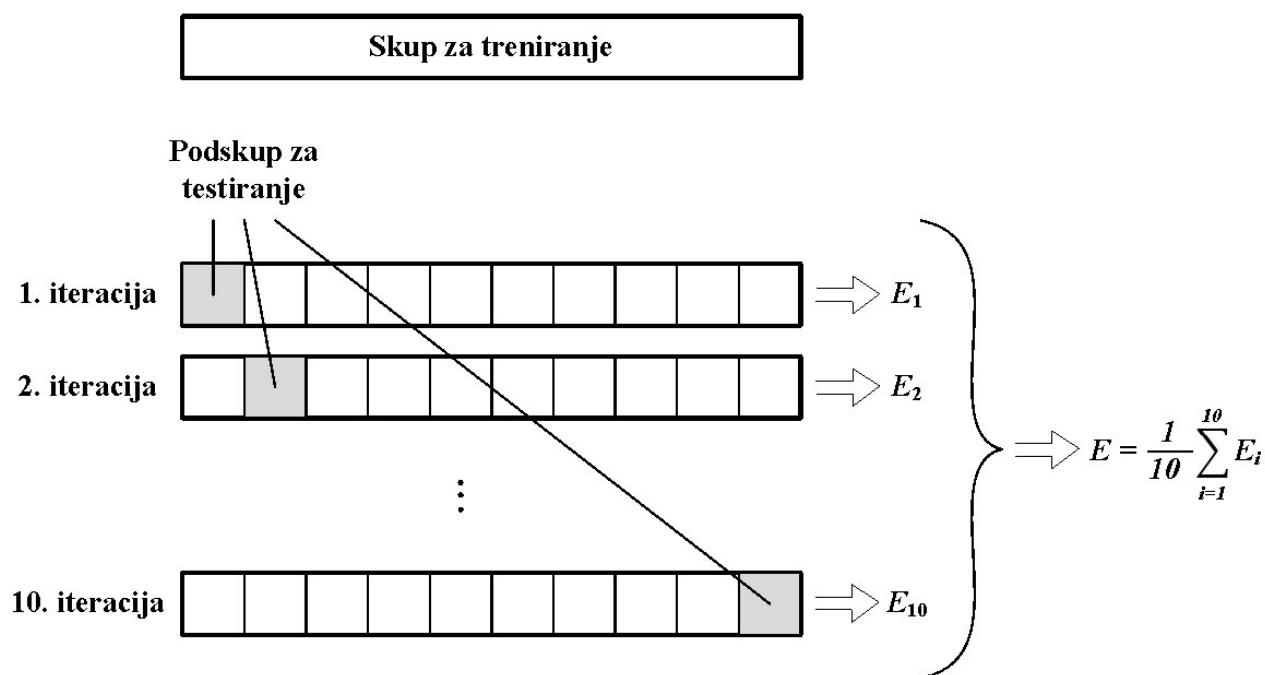
Slika 4.6 – Dijagram toka treniranja neuralne mreže.

4.4.1 Prikupljanje i obrada podataka

Tačnost modelovanja neuralne mreže u velikoj meri zavisi od ulaznih podataka koji se koriste za njenu obuku. Stoga je od izuzetne važnosti pravilno odabrati skup ulaznih podataka. Količina ulaznih podataka potrebnih za treniranje neuralne mreže zavisi od složenosti zadatka koji neuralna mreža obavlja, odnosno u slučaju aproksimacija funkcija od kompleksnosti funkcije koju neuralna mreža treba da aproksimira. U većini slučajeva je teško utvrditi da li je uzorkovani skup ulaznih podataka adekvatan i dovoljno velik, pre samog treniranja mreže. Stoga se i kaže da je proces treniranja neuralne mreže iterativan. Tek nakon završetka treniranja mogu se analizirati performanse neuralne mreže i reći da li je ulazni skup podataka dovoljno dobar ili ima potrebe za proširenjem ili menjanjem skupa ulaznih podataka.

Nakon prikupljanja podataka, vrši se njihova podela u tri međusobno različita skupa: skup za obuku, skup za validaciju i skup za testiranje. Skup za obuku služi za treniranje neuralne mreže. Skup za validaciju se koristi za proveru performansi neuralne mreže. Skup za testiranje se koristi za proveru tačnosti algoritma, odnosno tačnosti neuralne mreže. Podela ulaznih podataka u ove podskupove treba da bude slučajna, pri čemu treba voditi računa o tome da se u slučaju postojanja

više klasa u skupu ulaznih podataka izvrši ravnomerna raspodela podataka iz različitih klasa po podskupovima za treniranje, validaciju i testiranje. Ne postoji jedinstveno rešenje za podelu ulaznih podataka u odgovarajuće podskupove, već ono zavisi od više faktora, poput tipa i veličine ulaznih podataka, kao i karakteristika samog problema koji se rešava. Najčešće korišćena metoda podelu ulaznih podataka je postupak unakrsne validacije (*cross-validation*), i to tzv. *k-fold cross-validation*. Ulazni skup podataka se deli na k podskupova, od kojih se jedan uzima za testiranje neuralne mreže, a ostalih $k-1$ se koriste za trening. Treniranje i testiranje se zatim ponavlja k puta, pri čemu se svaki od prethodno definisanih k podskupova koristi tačno jednom kao podskup za testiranje. Pri svakoj od tih k iteracija se izračunava tačnost, odnosno greška. Dobijene vrednosti se zatim usrednjavaju kako bi se dobila prosečna vrednost tačnosti, odnosno kako bi se izvela tačnija procena performansi neuralne mreže. Najčešće se vrši 10 iteracija, odnosno vrši se *10-fold cross-validation* [125]. Postupak unakrsne validacije prikazan je na slici 4.7.



Slika 4.7 – Postupak unakrsne validacije (10-fold cross-validation).

Prethodna obrada ulaznih podataka se vrši u cilju olakšavanja treniranja neuralne mreže, odnosno kako bi se neuralnoj mreži olakšalo izdvajanje relevantnih informacija za treniranje. Pod tim se smatra normalizacija ulaznih podataka, nelinearne transformacije, izdvajanje određenih karakteristika, kodiranje diskretnih ulazno/izlaznih podataka, manipulacija podacima koji nedostaju, ... [119]

Za normalizaciju podataka najčešće se koristi neka od sledećih:

- linearna transformacija u opseg $[0,1]$, data sledećom formulom:

$$x_n = \frac{(x - x_{\min})}{(x_{\max} - x_{\min})}, \quad (4.27)$$

- linearna transformacija u opseg $[a, b]$, data sledećom formulom:

$$x_n = a + \frac{(b - a)(x - x_{\min})}{x_{\max} - x_{\min}}, \quad (4.28)$$

- statistička normalizacija, data sledećom formulom:

$$x_n = \frac{(x - \tilde{x})}{\sigma}, \quad (4.29)$$

- prosta normalizacija, data sledećom formulom:

$$x_n = \frac{x}{x_{\max}}, \quad (4.30)$$

gde je: x_n – normalizovana vrednost podatka, x – stvarna vrednost podatka, x_{\max} – maksimalna vrednost podatka, x_{\min} – minimalna vrednost podatka, \tilde{x} – srednja vrednost podatka, σ – standardna devijacija.

4.4.2 Izbor tipa i arhitekture neuralne mreže

U zavisnosti od tipa problema koji neuralna mreža treba da reši, koriste se različiti tipovi neuralnih mreža. Stoga je prvi zadatak koji treba izvršiti, odrediti tip problema, odnosno odrediti kojoj grupi problema pripada problem koji se rešava. Neke od mogućih grupa su: uklapanje (*fitting*), klasifikacija ili prepoznavanje oblika, grupisanje, predviđanje, aproksimacija funkcija, filtriranje, kontrola i optimizacija,... U problemima uklapanja neuralna mreža ima zadatak da izvrši mapiranje između seta ulaznih podataka i odgovarajućeg skupa ciljeva. Za rešavanje ovog tipa problema se najčešće koristi višeslojni *perceptron*, sa *tansig* aktivacionom funkcijom, ili radijalna neuralna mreža sa *Gauss*-ovom aktivacionom funkcijom u skrivenom sloju i linearnom funkcijom u izlaznom sloju mreže. U problemima prepoznavanja oblika neuralna mreža ima zadatak da klasifikuje ulazne podatke u određeni ciljni skup. Za rešavanje ovog tipa problema se može koristiti radijalna neuralna mreža ili višeslojni *perceptron* sa *logsig* aktivacionom funkcijom u izlaznom sloju. Kod problema grupisanja neuralna mreža ima zadatak da grupiše ulazne podatke po sličnosti. Za rešavanje problema grupisanja se koriste kompetitivne neuralne mreže ili samoorganizujuće mape (*Self-Organizing Map* – SOM). Problemi predviđanja buduće vrednosti neke vremenske serije podataka se rešavaju primenom dinamičkih neuralnih mreža, poput npr. *Time-Delay Neural Network* (TDNN).

Nakon izbora tipa neuralne mreže, potrebno je definisati arhitekturu mreže, odnosno odrediti broj slojeva i broj neurona u svakom sloju. Kod određenih tipova neuralnih mreža broj slojeva je unapred određen, dok kod recimo višeslojne neuralne mreže on može biti proizvoljan i određuje se eksperimentalnim putem. Osnovni princip je polazak od najjednostavnije mreže sa jednim skrivenim slojem. Ukoliko ova mreža nema zadovoljavajuće performanse, povećava se broj skrivenih slojeva na dva ili više. Dodavanjem više skrivenih slojeva povećava se tačnost mreže i njena sposobnost da reši složenije probleme, dok su sa druge strane ovakve mreže računski kompleksnije i teže za obučavanje. Stoga se za rešavanje jednostavnijih problema koriste neuralne mreže sa jednim ili dva skrivena sloja (SNN), dok se za veoma komplikovane probleme koriste duboke neuralne mreže (DNN) koje imaju više skrivenih slojeva.

Broj neurona u ulaznom sloju je definisan ulaznim vektorom podataka, dok je broj neurona u izlaznom sloju određen veličinom izlaznog, odnosno ciljnog vektora. Sa druge strane broj neurona u skrivenim slojevima može biti proizvoljan i određuje se eksperimentalnim putem, kao i broj

skrivenih slojeva. Ukoliko je broj neurona prevelik može doći do pojave tzv. *overfitting*-a. Postoje slučajevi kada je ulazni vektor podataka prevelik, odnosno zahteva mnogo neurona u ulaznom sloju. Tada se vrši eliminacija suvišnih ili irelevantnih podataka ulaznog vektora. Takođe, u nekim slučajevima je potrebno povećati dimenziju ulaznog vektora podataka, uvođenjem novih dodatnih parametara ulaznog signala. Stoga, izbor ulaznog vektora podataka, takođe, može predstavljati kompleksan i težak zadatak, za koji ne postoji savršeno rešenje.

4.4.3 Izbor algoritma učenja

Kao što je već izloženo, postoji veliki broj algoritama učenja, svaki od njih ima određene prednosti i nedostatke i ne postoji jedan algoritam koji je optimalan za rešavanje svih problema. U zavisnosti od tipa problema koji se rešava, obima ulaznih podataka koji su na raspolaganju za treniranje neuralne mreže, kao i od same arhitekture neuralne mreže, neki od njih su se pokazali efikasnijim u odnosu na druge. Uspešnost algoritma učenja se procenjuje različitim metrikama, od kojih su najčešće korišćene tačnost, preciznost, odziv,...

Tačnost algoritma se računa na taj način što se broj ispravno generisanih izlaznih vrednosti podeli sa ukupnim brojem izlaznih vrednosti, odnosno matematički formulisano:

$$\text{tačnost} = \frac{\text{broj ispravno generisanih vrednosti izlaznog signala}}{\text{ukupan broj izlaznih signala}} . \quad (4.31)$$

U praksi se pokazalo da je za višeslojne mreže sa do nekoliko stotina težinskih koeficijenata, koje se koriste za rešavanje problema aproksimacije funkcije, najbolje primeniti LM algoritam. Algoritam veoma brzo dolazi do optimalnog rešenja, odnosno srednja kvadratna greška između željenih i stvarnih izlaznih vrednosti veoma brzo konvergira ka minimumu. Ukoliko je broj težinskih koeficijenata neuralne mreže hiljadu i više, LM algoritam postaje manje efikasan, odnosno znatno sporiji, zato što izračunavanje matrice inverzije geometrijski zavisi od broja težinskih koeficijenata i raste vreme potrebno za njeno izračunavanje. U tom slučaju se kao veoma efikasan pokazao algoritam skaliranog konjugovanog gradijenta.

4.4.4 Inicijalizacija neuralne mreže

Nakon prikupljanja i obrade ulaznih podataka, kao i izbora tipa i arhitekture neuralne mreže i odgovarajućeg algoritma učenja, pre samog treniranja neuralne mreže, neophodno je izvršiti inicijalizaciju mreže, odnosno odabrati početne vrednosti težinskih koeficijenata i pragova. Inicijalizacija neuralne mreže, takođe, zavisi od tipa mreže.

Kod višeslojnih neuralnih mreža uglavnom se težinski koeficijenti i pragovi postavljaju na male slučajne vrednosti. Tako se na primer, ukoliko su ulazne vrednosti normalizovane u opsegu $[-1,1]$, težinski koeficijenti i pragovi raspoređuju ravnomerno u opsegu $[-0.5,0.5]$.

Kod kompetitivnih neuralnih mreža postoje dva najčešće korišćena pristupa za inicijalizaciju. Prvi pristup je postavljanje težinskih koeficijenata i pragova na male slučajne vrednosti, kao i kod višeslojnih mreža. Drugi pristup je da se od trening skupa ulaznih vektora slučajno odaberu neki ulazni vektori i postave kao redovi početne matrice težinskih koeficijenata.

4.4.5 Analiza performansi mreže

Nakon što se izvrši treniranje neuralne mreže prema prethodno izabranim parametrima, neophodno je izvršiti analizu performansi mreže i doneti odluku o tome da li je mreža dovoljno efikasna za rešavanje zadatog problema ili je potrebno izvršiti određene izmene i prilagođavanje mreže. Jedinstven kriterijum za određivanje performansi neuralne mreže ne postoji. Kao najznačajnije karakteristike izdvajaju se vreme treniranja i tačnost modelovanja, pri čemu se tačnost najčešće definiše preko greške između izračunate i stvarne očekivane vrednosti. U literaturi se sreće više različitih mera, među kojima su najčešće korišćene:

- srednja apsolutna devijacija (*Mean Absolute Deviation* – MAD), data sledećom formulom:

$$MAD = \frac{\sum |e_t|}{N}, \quad (4.32)$$

- srednja kvadratna greška (*Mean Square Error* – MSE), data sledećom formulom:

$$MSE = \frac{\sum (e_t)^2}{N}, \quad (4.33)$$

- koren srednje kvadratne greške (*Root Mean Square Error* – RMSE), dat sledećom formulom:

$$RMSE = \sqrt{\frac{\sum (e_t)^2}{N}}, \quad (4.34)$$

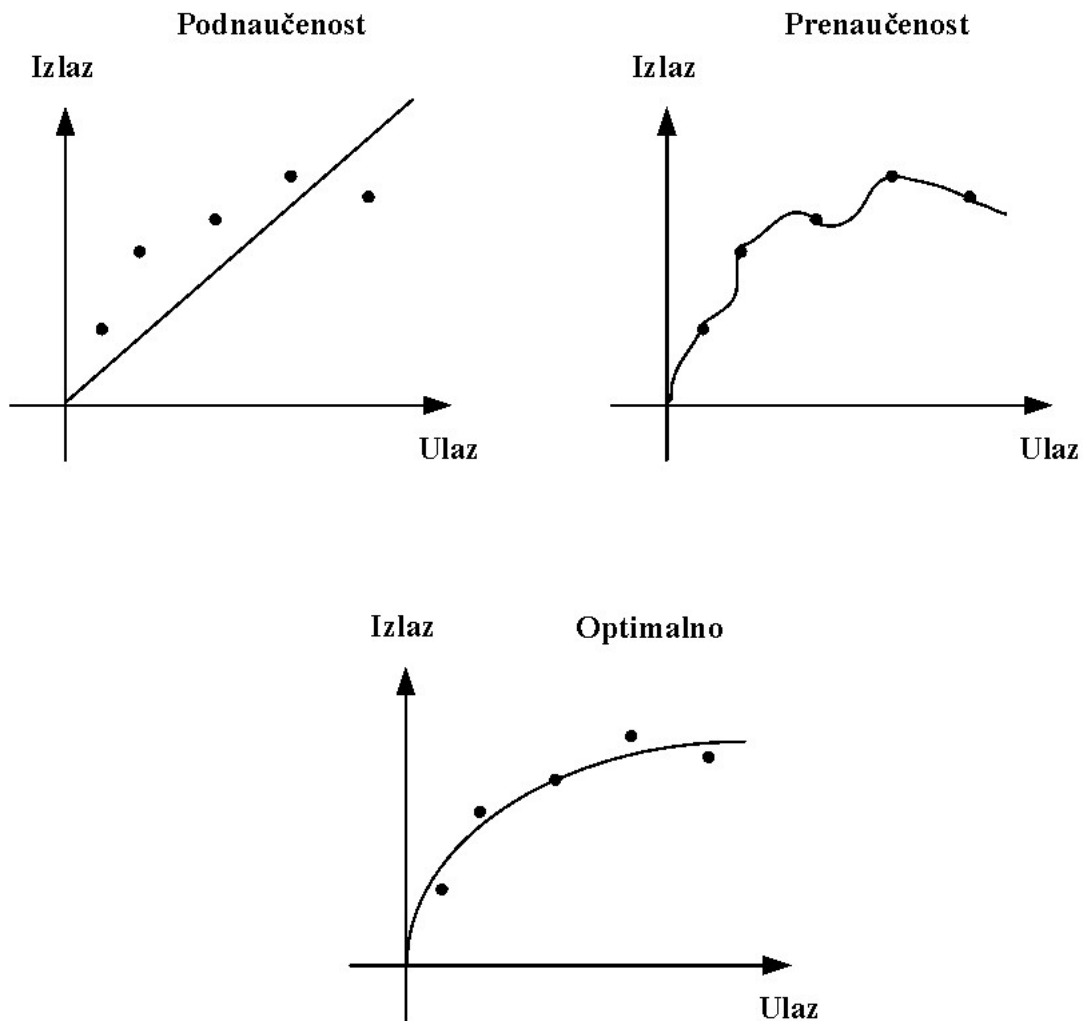
- srednja apsolutna procentualna greška (*Mean Absolute Percentage Error* – MAPE), data sledećom formulom:

$$MAPE = \frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| \cdot 100\%, \quad (4.35)$$


gde je: e_t – pojedinačna greška, y_t – stvarna vrednost, N – ukupan broj izlaznih vrednosti.

4.5 Regularizacija

Jedan od osnovnih zadataka pri treniranju neuralnih mreža jeste i postizanje dobrih performansi modela na skupu novih podataka, tj. na podacima koji nisu korišćeni pri treniranju mreže. Stoga pri treniranju neuralnih mreža treba voditi računa i o postizanju kompromisa između podnaučenosti (*underfitting*) i prenaučivosti (*overfitting*). Podnaučenost se obično javlja kod neuralnih mreža koje nisu dovoljno trenirane ili kod kojih model nije adekvatan. Podnaučene mreže ne moduluju dobro problem koji se rešava, ni na trening skupu podataka ni na novim ulaznim podacima. Sa druge strane, prenaučivost se javlja kada je neuralna mreža previše trenirana na određenom skupu podataka ili kada je model neuralne mreže suviše kompleksan za problem koji se rešava. Prenaučene mreže neće imati dobre performanse sa novim ulaznim podacima. Na slici 4.8 je ilustrovan problem podnaučenosti i prenaučivosti, dok je na slici 4.9 prikazana zavisnost greške treninga i testiranja od kompleksnosti modela za slučaj prenaučivog i podnaučenog modela.



Slika 4.8 – Ilustracija problema podnaučenosti i prenaučivosti.




Slika 4.9 – Zavisnost greške od kompleksnosti modela za prenaučeni i podnaučeni model.

Prenaučivost je problem koji se javlja češće od podnaučenosti i u literaturi se mogu naći različite tehnike regularizacije, odnosno različite metode za sprečavanje pojave prenaučivosti, kao

npr. tehnika ranog zaustavljanja (*early stopping*), tehnika izbacivanja (*dropout*), L1 i L2 regularizacija,...

4.5.1 Tehnika ranog zaustavljanja

Osnovni princip tehnike ranog zaustavljanja je prestanak obučavanja mreže u trenutku kada greška na skupu za učenje i dalje pada, a greška na skupu za validaciju dostigne svoj minimum. Za parametre neuralne mreže se usvajaju parametri koji su dali najbolje rezultate na skupu za validaciju. Ova tehnika je najjednostavnija tehnika za sprečavanje pojave prenaučenosti i obično se kombinuje sa još nekom tehnikom. Na slici 4.10 je grafički prikazana tačka u kojoj se prekida treniranje primenom tehnike ranog zaustavljanja.




Slika 4.10– Tehnika ranog zaustavljanja.


4.5.2 Tehnika izbacivanja

Tehnika izbacivanja je jednostavna tehnika kojom se smanjuje kompleksnost modela, čime se sprečava pojava prenaučenosti. Osnovni princip ove tehnike se sastoji u tome da se tokom svake iteracije određeni aktivni neuroni deaktiviraju, odnosno prebace u neaktivan mod. Na ovaj način se sprečava koadaptacija neurona. Izbor neurona koji se prebacuju u neaktivan mod je slučajan u svakoj iteraciji, sa verovatnoćom 0.5. Pored smanjenja kompleksnosti modela, usled manjeg broja aktivnih neurona u svakoj iteraciji, prednost ove tehnike je i brže treniranje neuralne mreže zbog činjenice da je potrebno podesiti duplo manje parametara [126]. Na slici 4.11 je grafički prikazan princip tehnike izbacivanja.

Neuralna mreža pre primene tehnike izbacivanja:



Neuralna mreža nakon primene tehnike izbacivanja:



Slika 4.11 – Tehnika izbacivanja.

4.5.3 L1 i L2 regularizacija

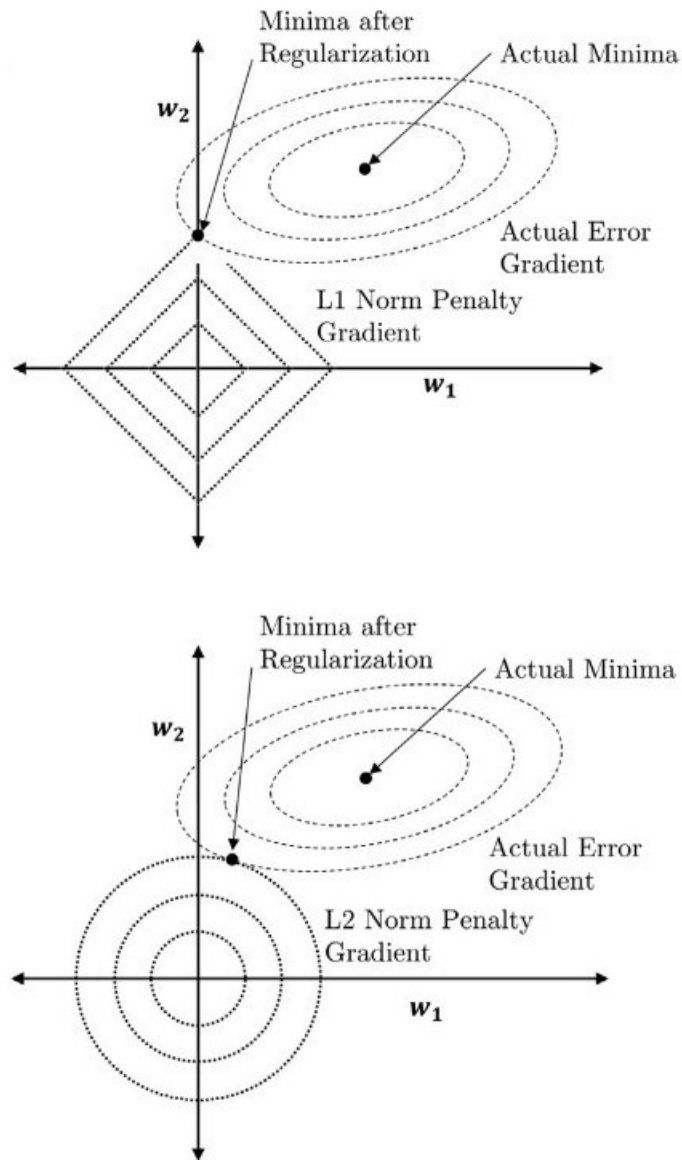
L1 i L2 regularizacija su tehnike kod kojih se uvodi tzv. kazna, kako bi se sprečila pojava prenaučenosti, odnosno na funkciju greške koju koristi algoritam učenja se dodaje član kojim se smanjuju vrednosti težinskih koeficijenata, a samim tim se smanjuje i kompleksnost modela. L1 regularizacija „kažnjava“ zbir apsolutnih vrednosti težinskih koeficijenata, dok L2 regularizacija „kažnjava“ zbir kvadrata težinskih koeficijenata. Matematički funkcije greške kod L1 i L2 regularizacije se mogu izraziti sledećim formulama:

$$J_{L1}(\mathbf{w}) = E(\mathbf{w}) + \lambda \sum |w_{ij}|, \tag{4.36}$$

$$J_{L2}(\mathbf{w}) = E(\mathbf{w}) + \lambda \sum w_{ij}^2, \tag{4.37}$$

gde je: $E(\mathbf{w})$ – kriterijumska funkcija za određivanje težinskih koeficijenata, odnosno funkcija greške bez primene regularizacije, λ – regularizacioni parametar koji određuje koliko ograničenje se uvodi. Za $\lambda = 0$ funkcija greške je nepromenjena, odnosno identična je kao i u slučaju bez regularizacije.

Na slici 4.12 je grafički prikazan princip L1 i L2 tehnika regularizacije [127].



Slika 4.12 – L1 i L2 tehnike regularizacije [127].

5. NN DPD MODELI ZA SU HBF mMIMO PREDAJNIKE

Kao što je opisano u prethodnom poglavlju, neuralne mreže imaju sposobnost da veoma dobro aproksimiraju nelinearne funkcije, imaju visoku tačnost modelovanja i prilagodljivost, i pogodne su za implementaciju na VLSI komponentama, koje predstavljaju osnovu svih današnjih elektronskih sklopova. Zbog ovih osobina veliki broj istraživača je razmatrao mogućnost primene neuralnih mreža u oblasti linearizacije pojačavača i pokazali su da neuralne mreže ispoljavaju veoma dobre performanse u kompenzaciji distorzije koju unosi pojačavač [24]-[31], [102], [128]-[138].

U trećem poglavlju rečeno je da postoje dva tipa arhitekture hibridnog *beamforming* mMIMO predajnika: potpuno povezana i delimično povezana arhitektura, kao i da potpuno povezana arhitektura omogućava veću spektralnu efikasnost. Stoga je od posebnog značaja ispitati efikasnost primene različitih tipova neuralnih mreža za digitalnu predistorziju signala kod potpuno povezanog hibridnog *beamforming* mMIMO predajnika. Kako bi se došlo do predloga rešenja za digitalnu predistorziju potpuno povezanog hibridnog *beamforming* mMIMO predajnika primenom neuralnih mreža, potrebno je izabrati tip i arhitekturu neuralne mreže, kao i način formiranja DPD modela.

Pri izboru tipa neuralne mreže koja će se koristiti, kao što je rečeno, potrebno je voditi računa o problemu koji mreža treba da reši. Pokazalo se da su *feedforward* neuralne mreže veoma efikasne za rešavanje problema modelovanja ulazno/izlazne funkcije pojačavača. Kod ovog tipa neuralne mreže podaci putuju unapred, odnosno od neurona nižeg sloja ka neuronima višeg sloja, i ne postoje povratne putanje. Ulazni podaci u $(l+1)$ -i sloj računaju se po sledećoj formuli [138]:

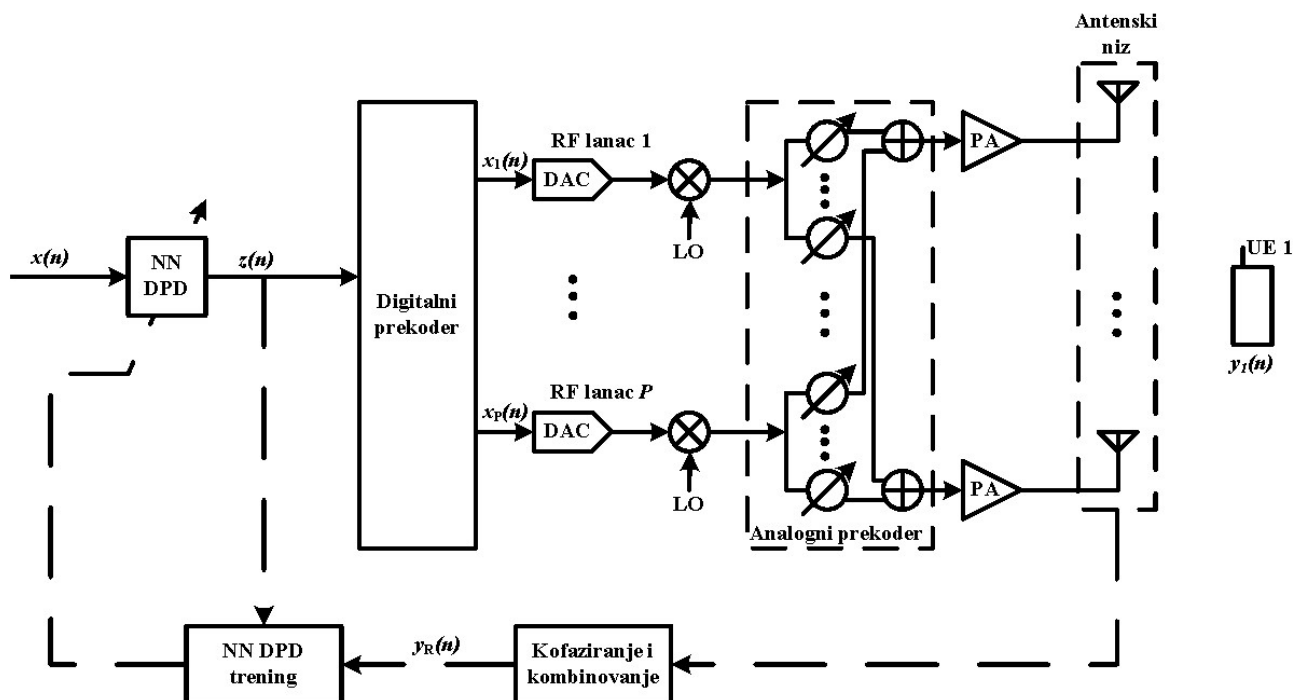
$$net_j^{l+1} = \sum_{i=1}^q \omega_{ji}^{l+1} \sigma_i^l + b_j^{l+1}, \quad (5.1)$$

gde je: ω_{ji}^{l+1} – sinaptička težina između i -tog ulaza prethodnog sloja i j -tog neurona trenutnog sloja, σ_i^l – izlaz j -tog neurona u $(l+1)$ -om sloju, b_j^{l+1} – pomeraj j -tog neurona u $(l+1)$ -om sloju. Pri tom izlaz j -tog neurona u $(l+1)$ -om sloju zavisi od aktivacione funkcije f , odnosno matematički iskazano:

$$\sigma_i^l = f(net_j^{l+1}). \quad (5.2)$$

Blok šema modela digitalne predistorzije za potpuno povezan hibridni *beamforming* (FC HBF) mMIMO predajnik sa jednim korisnikom (*Single-User* – SU) primenom neuralnih mreža (NN DPD model) prikazana je na slici 5.1. Korišćena je metoda indirektnog učenja (ILA), kod koje se prvo određuju koeficijenti modela, tj. formira se i trenira neuralna mreža na osnovu izlaznih signala sa svih antena i ulaznih signala u HBF mMIMO predajnik. Zatim se tako formirana neuralna mreža koristi za ažuriranje ulaznog signala u HBF mMIMO predajnik, kako bi se izvršila predistorzija signala. Signal za treniranje NN DPD modela se uzima direktno sa kraja predaje, odnosno koristi se direktna povratna sprega. Izdvajaju se izlazi pojedinačnih pojačavača, a zatim se

vrši njihovo kofaziranje i kombinovanje u analognom domenu, čime se poništava efekat koeficijena *beamforming*-a. Ovako dobijen signal u povratnoj grani odgovara signalu koji korisnik prima.



Slika 5.1 – Blok šema NN DPD modela za SU FC HBF mMIMO predajnik.

5.1 Izbor modela neuralne mreže

Analizirano je više različitih modela neuralnih mreža:

- *Deep Neural Network* (DNN), sa tri skrivena sloja i *logsig* aktivacionom funkcijom,
- *Real-Valued Time-Delay Neural Network* (RVTDNN), sa jednim skrivenim slojem i *tansig* aktivacionom funkcijom,
- *Augmented Real-Valued Time-Delay Neural Network* (ARVTDNN), sa jednim skrivenim slojem i *tansig* aktivacionom funkcijom,
- RVTDNN sa 2 skrivena sloja (RVTDNN2L), sa *tansig* aktivacionom funkcijom.

Jedan od parametara po kojima se mogu uporediti različite neuralne mreže jeste kompleksnost mreže. Procena kompleksnosti neuralne mreže može se izvršiti na osnovu broja koeficijena N_{coef} i na osnovu broja FLOP-ova, kao i pri proceni kompleksnosti DPD modela pojačavača. Ukupan broj koeficijena *feedforward* neuralne mreže se računa kao zbir koeficijena korišćenih u svakom sloju mreže i zavisi od broja neurona u svakom od slojeva. Matematička formula po kojoj se računa broj koeficijena data je sledećim izrazom:

$$N_{\text{coef}} = (N_1 + 1)N_1 + \sum_{f=2}^F (N_{f-1} + 1)N_f + (N_F + 1)N_0, \quad (5.3)$$

gde je: N_i – broj neurona u ulaznom sloju, F – broj skrivenih slojeva, N_f – broj neurona u f -tom skrivenom sloju ($f = 1, 2, \dots, F$), N_o – broj neurona u izlaznom sloju.

Kao što je izloženo u poglavlju 2.7, broj FLOP-ova zavisi od broja i vrste korišćenih aritmetičkih operacija. U slučaju neuralnih mreža, broj i vrsta korišćenih aritmetičkih operacija zavise od tipa korišćene aktivacione funkcije. Koristeći tabelu 2.1 i formule za izračunavanje aktivacionih funkcija mreže, može se izračunati broj FLOP-ova za neuralnu mrežu sa određenom aktivacionom funkcijom.

Za neuralnu mrežu koja koristi sigmoidnu funkciju (*logsig*), datu sa (4.5), broj FLOP-ova se može izračunati korišćenjem sledeće formule:

$$FLOP = 2N_iN_1 + 2N_FN_o + 2 \sum_{f=2}^F N_{f-1}N_f + 13 \sum_{f=1}^F N_f. \quad (5.4)$$

Za neuralnu mrežu koja koristi aktivacionu funkciju tangens hiperbolički (*tansig*), datu sa (4.6), broj FLOP-ova se može izračunati korišćenjem sledeće formule:

$$FLOP = 2N_iN_1 + 2N_FN_o + 2 \sum_{f=2}^F N_{f-1}N_f + 15 \sum_{f=1}^F N_f. \quad (5.5)$$

Kao ulazni signali u DNN, RVTDDN i RVTDDN2L mrežama dovedene su komponente signala u fazi (*inphase*) i kvadraturi (*quadrature*): I i Q . Ulazni signali u ARVTDDN mrežu, pored I i Q komponenti ulaznog signala, su i $|x(n)|$, $|x(n)|^2$ i $|x(n)|^3$, pri čemu je $|x(n)|$ amplituda ulaznog signala. Kao izlazni signali iz neuralnih mreža posmatraju se komponente izlaznog signala u fazi i kvadraturi.

Za treniranje neuralnih mreža korišćen je LM algoritam, opisan u poglavlju 4.3.2, koji se pokazao kao izuzetno dobar algoritam zbog svoje brze konvergencije srednje kvadratne greške. Ovaj algoritam je efikasno implementiran u programskom paketu *Matlab*, koji je korišćen za simulacije. Kao inicijalne vrednosti usvojene su sledeće vrednosti za parametar učenja $\mu = 0.001$ i faktor uvećanja $\beta = 10$. Tokom treninga neuralne mreže korišćen je postupak unakrsne validacije, opisan u poglavlju 4.4.1. Ulazno/izlazni skup podataka je podeljen tako da su skupovi podataka koji se koriste za treniranje, validaciju i testiranje međusobno različiti.

Određivanje optimalnog broja neurona vrši se eksperimentalno u toku treniranja mreže, tako da se postignu najbolje moguće performanse same mreže. Za različite kombinacije broja neurona u svakom skrivenom sloju, izračunata je vrednost za amplitudu vektora greške EVM i normalizovanu srednju kvadratnu grešku NMSE, prema formulama (2.11) i (2.28), kao i broj koeficijenata modela i broj FLOP-ova, prema formulama (5.3), (5.4) i (5.5). Simulacije su izvršene za 4x4 potpuno povezan hibridni *beamforming* mMIMO sistem sa 2 RF grane i generisan OFDM signal širine 10 MHz. Kao DPD model korišćena je RVTDDN2L neuralna mreža. U tabelama 5.1 i 5.2 prikazane su dobijene vrednosti za EVM i NMSE za različite vrednosti broja neurona u prvom i drugom skrivenom sloju, respektivno. Dok su u tabelama 5.3 i 5.4 prikazane izračunate vrednosti kompleksnosti DPD modela u zavisnosti od broja neurona po slojevima, konkretno broj koeficijenata modela i broj FLOP-ova, respektivno.

Tabela 5.1 – EVM za 4x4 FC HBF mMIMO sistem sa 2 RF grane [%].

I \ II	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	80.14	79.01	77.81	76.37	76.38	76.32	77.41	77.61	77.21	77.56	77.54	77.46	76.25	77.72
2	78.62	18.69	77.51	17.63	17.91	14.63	18.05	15.71	15.92	17.37	17.49	14.45	15.27	18.08
3	76.61	16.37	17.48	14.73	15.08	15.76	14.42	6.88	16.91	7.22	6.51	7.85	6.12	4.41
4	77.31	16.87	15.62	12.71	10.91	10.37	4.71	5.91	4.36	6.14	7.29	3.98	4.39	4.81
5	78.73	12.89	6.39	7.71	5.29	5.94	6.89	4.16	4.61	5.51	4.19	3.37	3.47	5.17
6	76.93	7.09	11.75	13.38	8.02	5.05	3.88	4.93	4.34	3.41	3.92	3.54	3.18	3.51
7	78.09	7.35	8.27	4.31	4.95	5.08	3.48	3.69	2.69	4.16	3.72	2.93	2.97	2.71
8	78.38	7.44	5.89	4.34	4.18	2.99	3.71	4.11	2.68	4.39	3.46	3.21	2.45	3.65
9	76.91	5.61	6.09	3.59	3.82	4.07	3.39	3.67	3.49	4.14	3.25	2.91	2.89	2.74
10	78.36	3.79	4.77	4.64	3.18	3.65	3.24	2.38	3.59	3.43	3.01	2.83	2.65	1.89
11	78.03	4.51	3.61	3.72	2.95	3.72	2.52	2.91	3.18	2.77	1.75	2.77	1.92	1,89
12	76.25	6.66	3.78	3.65	4.02	2.78	2.85	2.42	3.08	1.95	1.82	1.74	2.72	2.34
13	82.09	6.03	4.22	4.25	3.06	2.93	3.82	3.36	2.49	2.39	2.22	2.46	2.89	2.71
14	78.04	4.15	2.51	2.71	2.76	3.74	2.91	2.97	2.32	2.09	1.87	3.01	1.75	1.75
15	79.68	4.48	3.41	3.19	2.31	2.36	2.19	2.27	1.88	1.98	1.87	2.46	1.85	1.84
16	77.81	3.29	3.18	2.68	2.51	2.55	2.05	2.14	2.66	1.97	2.86	1.61	2.47	2.57
17	76.48	3.34	3.39	3.05	2.47	2.28	2.27	1.83	1.83	1.71	1.67	2.91	1.94	1.66
18	77.63	3.72	3.66	2.29	2.19	2.34	1.92	1.98	1.84	2.45	2.44	2.56	2.17	1.86
19	76.28	3.35	2.73	1.82	2.49	1.91	1.97	2.49	2.12	1.86	2.01	1.88	2.24	1.78
20	76.66	2.75	2.51	2.67	2.26	2.12	2.37	1.83	1.89	2.31	1.73	1.89	2.05	1.95
21	77.01	2.76	2.87	3.01	2.88	1.61	1.99	1.73	1.19	1.57	2.05	2.09	1.47	1.93
22	76.26	2.42	3.21	1.95	2.21	2.55	2.09	2.64	1.38	1.95	1.55	1.72	1.53	1.51
23	77.17	2.69	3.44	2.53	2.21	2.74	1.98	1.76	1.77	1.82	1.71	1.83	1.41	1.59
24	81.89	3.59	2.26	2.25	1.99	2.13	2.27	1.95	1.27	1.68	1.81	2.03	1.98	1.53
25	78.48	2.66	2.56	2.35	2.23	1.93	2.11	1.56	1.58	1.77	1.63	1.67	1.37	2.34
26	79.01	3.13	2.17	1.89	1.88	1.89	1.96	1.57	2.24	1.55	1.55	1.73	1.88	1.69
27	80.79	2.34	2.43	2.21	1.69	2.08	1.81	1.64	2.59	1.46	1.51	1.41	1.44	1.79
28	76.71	3.08	2.39	2.48	2.05	1.97	1.66	1.57	1.86	1.43	1.66	1.53	1.37	1.54
29	78.54	2.43	1.89	2.07	1.49	1.54	1.88	2.09	2.09	1.58	1.63	1.65	1.53	1.61
30	78.94	2.16	2.11	2.49	2.41	1.65	1.91	1.92	1.72	1.62	1.83	1.26	1.59	1.54
31	78.08	2.16	3.05	1.99	2.11	1.68	1.96	1.44	1.59	1.01	2.21	1.52	1.74	1.71
32	76.35	2.05	2.02	2.01	2.02	1.79	1.78	1.54	1.06	1.65	1.59	1.22	1.58	1.53

Tabela 5.2 – NMSE za 4x4 FC HBF mMIMO sistem sa 2 RF grane [dBm].

I \ II	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	-1,92	-2,05	-2,18	-2,34	-2,34	-2,35	-2,22	-2,21	-2,25	-2,21	-2,21	-2,22	-2,36	-2,19
2	-2,09	-14,57	-2,22	-15,07	-14,94	-16,69	-14,87	-16,08	-15,96	-15,21	-15,14	-16,81	-16,32	-14,85
3	-2,32	-15,72	-15,15	-16,63	-16,43	-16,05	-16,82	-23,25	-15,44	-22,83	-23,73	-22,11	-24,26	-27,11
4	-2,24	-15,46	-16,13	-17,92	-19,25	-19,68	-26,55	-24,58	-27,21	-24,24	-22,73	-27,99	-27,14	-26,36
5	-2,08	-17,79	-23,89	-22,27	-25,53	-24,52	-23,23	-27,61	-26,73	-25,18	-27,55	-29,45	-29,19	-25,72
6	-2,28	-22,99	-18,59	-17,47	-21,92	-25,94	-28,23	-26,15	-27,25	-29,36	-28,14	-29,01	-29,95	-29,11
7	-2,15	-22,67	-21,65	-27,32	-26,09	-25,89	-29,17	-28,65	-31,42	-27,62	-28,61	-30,65	-30,53	-31,35
8	-2,12	-22,57	-24,61	-27,26	-27,58	-30,47	-28,63	-27,72	-31,42	-27,15	-29,21	-29,87	-32,21	-28,75
9	-2,28	-25,01	-24,31	-28,88	-28,36	-27,79	-29,38	-28,71	-29,14	-27,66	-29,75	-30,75	-30,74	-31,25
10	-2,12	-28,41	-26,44	-26,67	-29,95	-28,75	-29,81	-32,48	-28,89	-29,29	-30,44	-30,96	-31,54	-34,44
11	-2,15	-26,93	-28,87	-28,59	-30,62	-28,61	-31,98	-30,74	-29,95	-31,15	-35,18	-31,14	-34,33	-34,47
12	-2,36	-23,53	-28,46	-28,76	-27,91	-31,11	-30,91	-32,32	-30,24	-34,21	-34,81	-35,18	-31,29	-32,63
13	-1,71	-24,39	-27,49	-27,44	-30,29	-30,66	-28,35	-29,48	-32,06	-32,41	-33,09	-32,18	-30,77	-31,33
14	-2,15	-27,63	-31,99	-31,37	-31,19	-28,55	-30,75	-30,55	-32,71	-33,61	-34,58	-30,42	-35,16	-35,14
15	-1,97	-26,98	-29,36	-29,91	-32,76	-32,53	-33,21	-32,89	-34,49	-34,05	-34,44	-32,17	-34,63	-34,69
16	-2,18	-29,67	-29,96	-31,45	-32,04	-31,88	-33,78	-33,41	-31,49	-34,09	-30,87	-35,86	-32,16	-31,81
17	-2,33	-29,54	-29,38	-30,32	-32,16	-32,84	-32,87	-34,75	-34,73	-35,37	-35,56	-30,73	-34,24	-35,62
18	-2,19	-28,58	-28,73	-32,82	-33,15	-32,61	-34,33	-34,08	-34,68	-32,19	-32,27	-31,84	-33,26	-34,63
19	-2,35	-29,51	-31,27	-34,78	-32,06	-34,42	-34,09	-32,05	-33,47	-34,63	-33,94	-34,52	-32,98	-34,98
20	-2,31	-31,21	-31,99	-31,47	-32,91	-33,47	-32,49	-34,77	-34,47	-32,74	-35,22	-34,43	-33,77	-34,21
21	-2,27	-31,19	-30,84	-30,44	-30,82	-35,85	-34,04	-35,26	-38,44	-36,09	-33,77	-33,59	-36,66	-34,27
22	-2,35	-32,32	-29,89	-34,19	-33,14	-31,88	-33,57	-31,57	-37,18	-34,18	-36,19	-35,29	-36,32	-36,41
23	-2,25	-31,41	-29,26	-31,95	-33,13	-31,24	-34,07	-35,06	-35,06	-34,79	-35,37	-34,75	-37,04	-35,99
24	-1,73	-28,91	-32,93	-32,96	-34,02	-33,44	-32,87	-34,19	-37,92	-35,48	-34,89	-33,85	-34,08	-36,31
25	-2,11	-31,52	-31,82	-32,58	-33,04	-34,28	-33,54	-36,13	-36,04	-35,03	-35,74	-35,54	-37,25	-32,61
26	-2,05	-30,11	-33,29	-34,49	-34,52	-34,46	-34,16	-36,09	-33,01	-36,19	-36,19	-35,25	-34,49	-35,46
27	-1,85	-32,62	-32,31	-33,14	-35,46	-33,65	-34,86	-35,69	-31,71	-36,73	-36,48	-37,04	-36,83	-34,93
28	-2,31	-30,24	-32,43	-32,11	-33,78	-34,12	-35,61	-36,09	-34,63	-36,91	-35,59	-36,28	-37,24	-36,23
29	-2,09	-32,27	-34,46	-33,69	-36,48	-36,24	-34,52	-33,56	-33,58	-36,05	-35,76	-35,66	-36,33	-35,91
30	-2,05	-33,33	-33,49	-32,09	-32,36	-35,63	-34,39	-34,31	-35,29	-35,82	-34,74	-37,99	-35,97	-36,26
31	-2,15	-33,32	-30,31	-34,03	-33,52	-35,48	-34,16	-36,82	-35,92	-39,97	-33,12	-36,35	-35,19	-35,39
32	-2,34	-33,76	-33,88	-33,98	-33,89	-34,91	-34,99	-36,27	-39,52	-35,68	-35,94	-38,27	-36,01	-36,29

Tabela 5.3 – Broj koeficijenata RVTDNN2L DPD modela.

I \ II	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	9	13	17	21	25	29	33	37	41	45	49	53	57	61
2	13	18	23	28	33	38	43	48	53	58	63	68	73	78
3	17	23	29	35	41	47	53	59	65	71	77	83	89	95
4	21	28	35	42	49	56	63	70	77	84	91	98	105	112
5	25	33	41	49	57	65	73	81	89	97	105	113	121	129
6	29	38	47	56	65	74	83	92	101	110	119	128	137	146
7	33	43	53	63	73	83	93	103	113	123	133	143	153	163
8	37	48	59	70	81	92	103	114	125	136	147	158	169	180
9	41	53	65	77	89	101	113	125	137	149	161	173	185	197
10	45	58	71	84	97	110	123	136	149	162	175	188	201	214
11	49	63	77	91	105	119	133	147	161	175	189	203	217	231
12	53	68	83	98	113	128	143	158	173	188	203	218	233	248
13	57	73	89	105	121	137	153	169	185	201	217	233	249	265
14	61	78	95	112	129	146	163	180	197	214	231	248	265	282
15	65	83	101	119	137	155	173	191	209	227	245	263	281	299
16	69	88	107	126	145	164	183	202	221	240	259	278	297	316
17	73	93	113	133	153	173	193	213	233	253	273	293	313	333
18	77	98	119	140	161	182	203	224	245	266	287	308	329	350
19	81	103	125	147	169	191	213	235	257	279	301	323	345	367
20	85	108	131	154	177	200	223	246	269	292	315	338	361	384
21	89	113	137	161	185	209	233	257	281	305	329	353	377	401
22	93	118	143	168	193	218	243	268	293	318	343	368	393	418
23	97	123	149	175	201	227	253	279	305	331	357	383	409	435
24	101	128	155	182	209	236	263	290	317	344	371	398	425	452
25	105	133	161	189	217	245	273	301	329	357	385	413	441	469
26	109	138	167	196	225	254	283	312	341	370	399	428	457	486
27	113	143	173	203	233	263	293	323	353	383	413	443	473	503
28	117	148	179	210	241	272	303	334	365	396	427	458	489	520
29	121	153	185	217	249	281	313	345	377	409	441	473	505	537
30	125	158	191	224	257	290	323	356	389	422	455	488	521	554
31	129	163	197	231	265	299	333	367	401	435	469	503	537	571
32	133	168	203	238	273	308	343	378	413	448	483	518	553	588

Tabela 5.4 – Broj FLOP-ova RVTDNN2L DPD modela.

I \ II	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	44	61	78	95	112	129	146	163	180	197	214	231	248	265
2	65	84	103	122	141	160	179	198	217	236	255	274	293	312
3	86	107	128	149	170	191	212	233	254	275	296	317	338	359
4	107	130	153	176	199	222	245	268	291	314	337	360	383	406
5	128	153	178	203	228	253	278	303	328	353	378	403	428	453
6	149	176	203	230	257	284	311	338	365	392	419	446	473	500
7	170	199	228	257	286	315	344	373	402	431	460	489	518	547
8	191	222	253	284	315	346	377	408	439	470	501	532	563	594
9	212	245	278	311	344	377	410	443	476	509	542	575	608	641
10	233	268	303	338	373	408	443	478	513	548	583	618	653	688
11	254	291	328	365	402	439	476	513	550	587	624	661	698	735
12	275	314	353	392	431	470	509	548	587	626	665	704	743	782
13	296	337	378	419	460	501	542	583	624	665	706	747	788	829
14	317	360	403	446	489	532	575	618	661	704	747	790	833	876
15	338	383	428	473	518	563	608	653	698	743	788	833	878	923
16	359	406	453	500	547	594	641	688	735	782	829	876	923	970
17	380	429	478	527	576	625	674	723	772	821	870	919	968	1017
18	401	452	503	554	605	656	707	758	809	860	911	962	1013	1064
19	422	475	528	581	634	687	740	793	846	899	952	1005	1058	1111
20	443	498	553	608	663	718	773	828	883	938	993	1048	1103	1158
21	464	521	578	635	692	749	806	863	920	977	1034	1091	1148	1205
22	485	544	603	662	721	780	839	898	957	1016	1075	1134	1193	1252
23	506	567	628	689	750	811	872	933	994	1055	1116	1177	1238	1299
24	527	590	653	716	779	842	905	968	1031	1094	1157	1220	1283	1346
25	548	613	678	743	808	873	938	1003	1068	1133	1198	1263	1328	1393
26	569	636	703	770	837	904	971	1038	1105	1172	1239	1306	1373	1440
27	590	659	728	797	866	935	1004	1073	1142	1211	1280	1349	1418	1487
28	611	682	753	824	895	966	1037	1108	1179	1250	1321	1392	1463	1534
29	632	705	778	851	924	997	1070	1143	1216	1289	1362	1435	1508	1581
30	653	728	803	878	953	1028	1103	1178	1253	1328	1403	1478	1553	1628
31	674	751	828	905	982	1059	1136	1213	1290	1367	1444	1521	1598	1675
32	695	774	853	932	1011	1090	1169	1248	1327	1406	1485	1564	1643	1722

Dobijene vrednosti su analizirane i izabran je optimalan broj neurona tako da vrednosti za NMSE i EVM budu uporedive sa postojećim vrednostima u literaturi, prikazanim u tabeli 3.1. Pri izboru broja neurona vodilo se računa i da broj koeficijenata i broj FLOP-ova bude što je moguće manji, tj. da kompleksnost neuralne mreže bude što manja. Optimalne vrednosti broja neurona po slojevima za DNN, RVTDNN i ARVTDNN DPD modele izabrane su tako da svi analizirani NN DPD modeli budu slični po kompleksnosti.

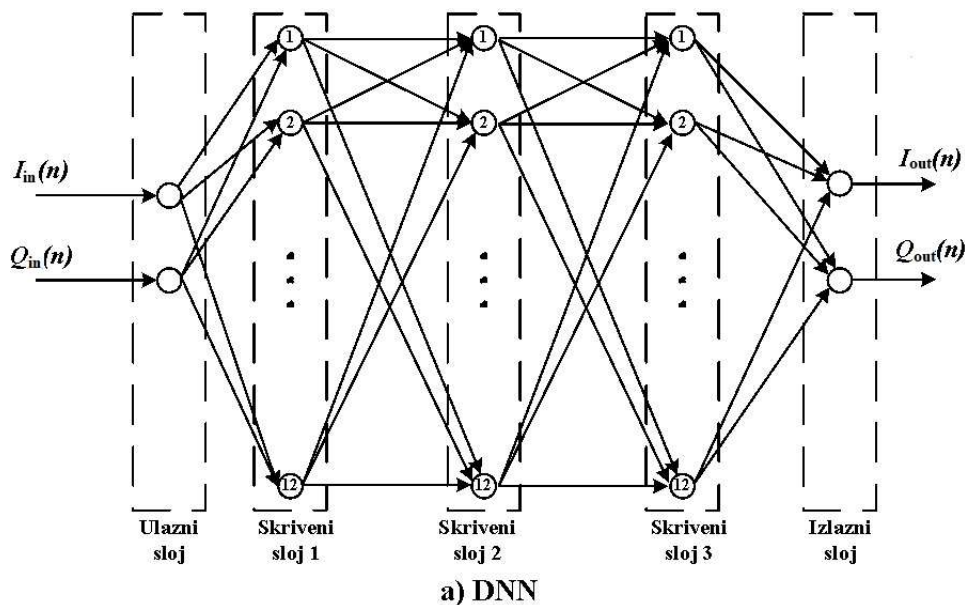
Nakon sprovedenih simulacija i analiza dobijenih rezultata, izabrane su sledeće arhitekture neuralnih mreža:

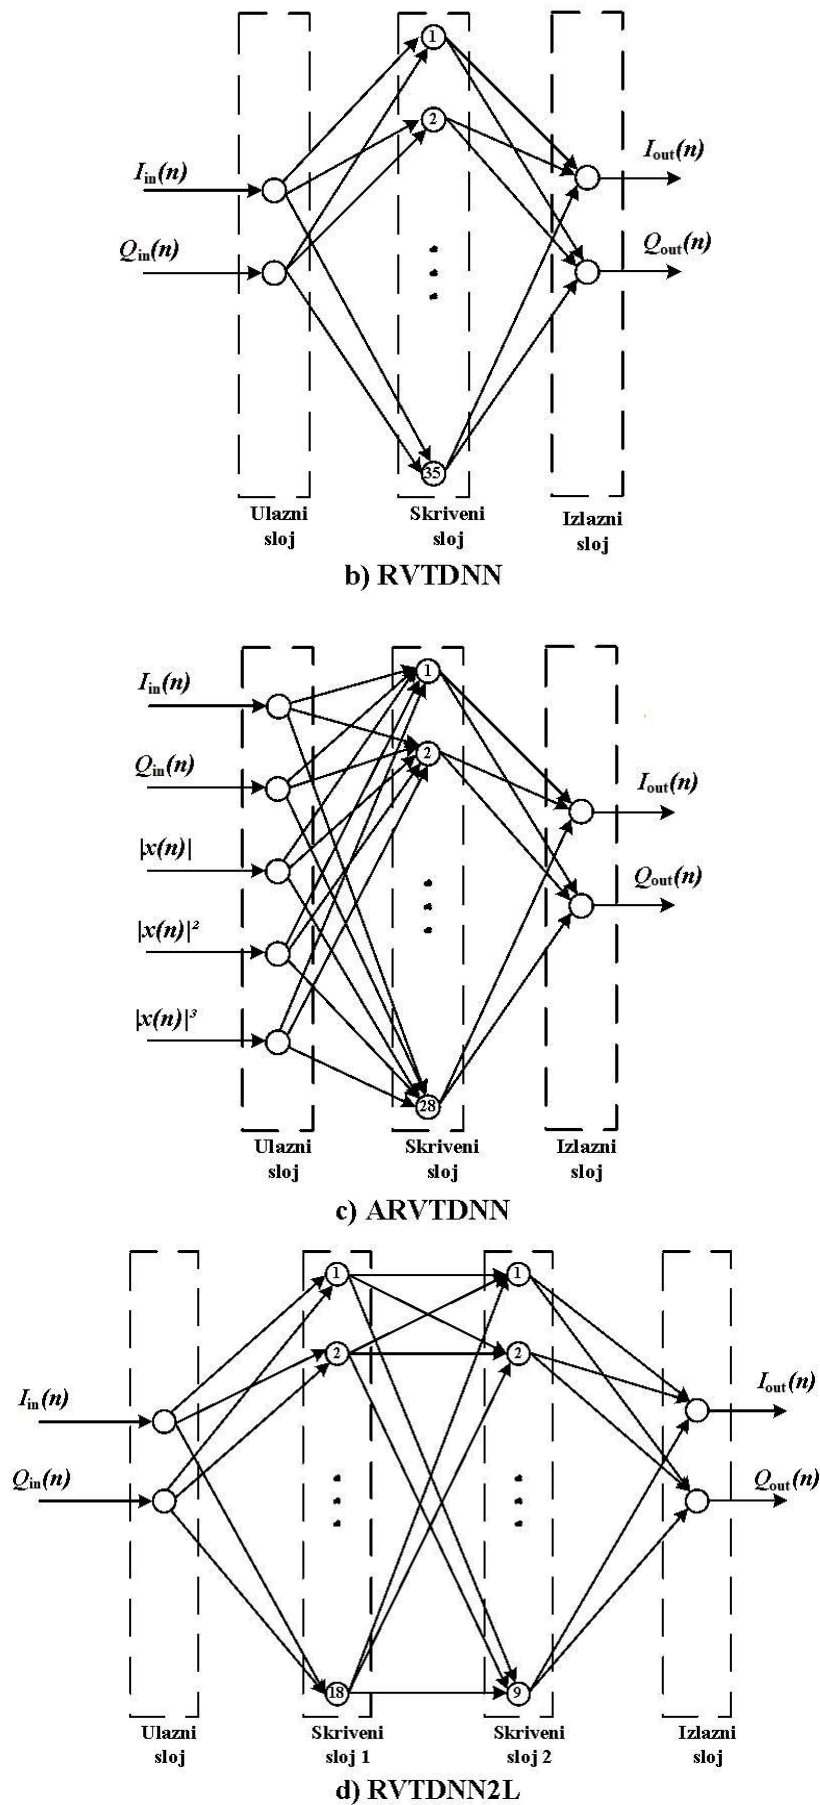
- DNN – sa tri skrivena sloja i po 12 neurona u svakom skrivenom sloju,
- RVTDNN – sa jednim skrivenim slojem i 35 neurona u skrivenom sloju,
- ARVTDNN – sa jednim skrivenim slojem i 28 neurona u skrivenom sloju,
- RVTDNN2L – sa dva skrivena sloja, 18 neurona u prvom skrivenom sloju i 9 neurona u drugom skrivenom sloju.

Blok šeme ovako izabranih neuralnih mreža, prikazane su na slici 5.2. Parametri i kompleksnost izabranih modela neuralnih mreža prikazani su u tabeli 5.5.

Tabela 5.5 – Parametri i kompleksnost izabranih modela neuralnih mreža [31].

Tip NN mreže	Ulazni podaci	Broj neurona u ulaznom sloju	Broj neurona u skrivenim slojevima	Aktivaciona funkcija	Broj neurona u izlaznom sloju	N_{coef}	FLOP
DNN	I, Q	2	12 12 12	<i>logsig</i>	2	374	852
RVTDNN	I, Q	2	35	<i>tansig</i>	2	177	805
ARVTDNN	$I, Q, x(n) , x(n) ^2, x(n) ^3$	5	28	<i>tansig</i>	2	226	812
RVTDNN2L	I, Q	2	18 9	<i>tansig</i>	2	245	837

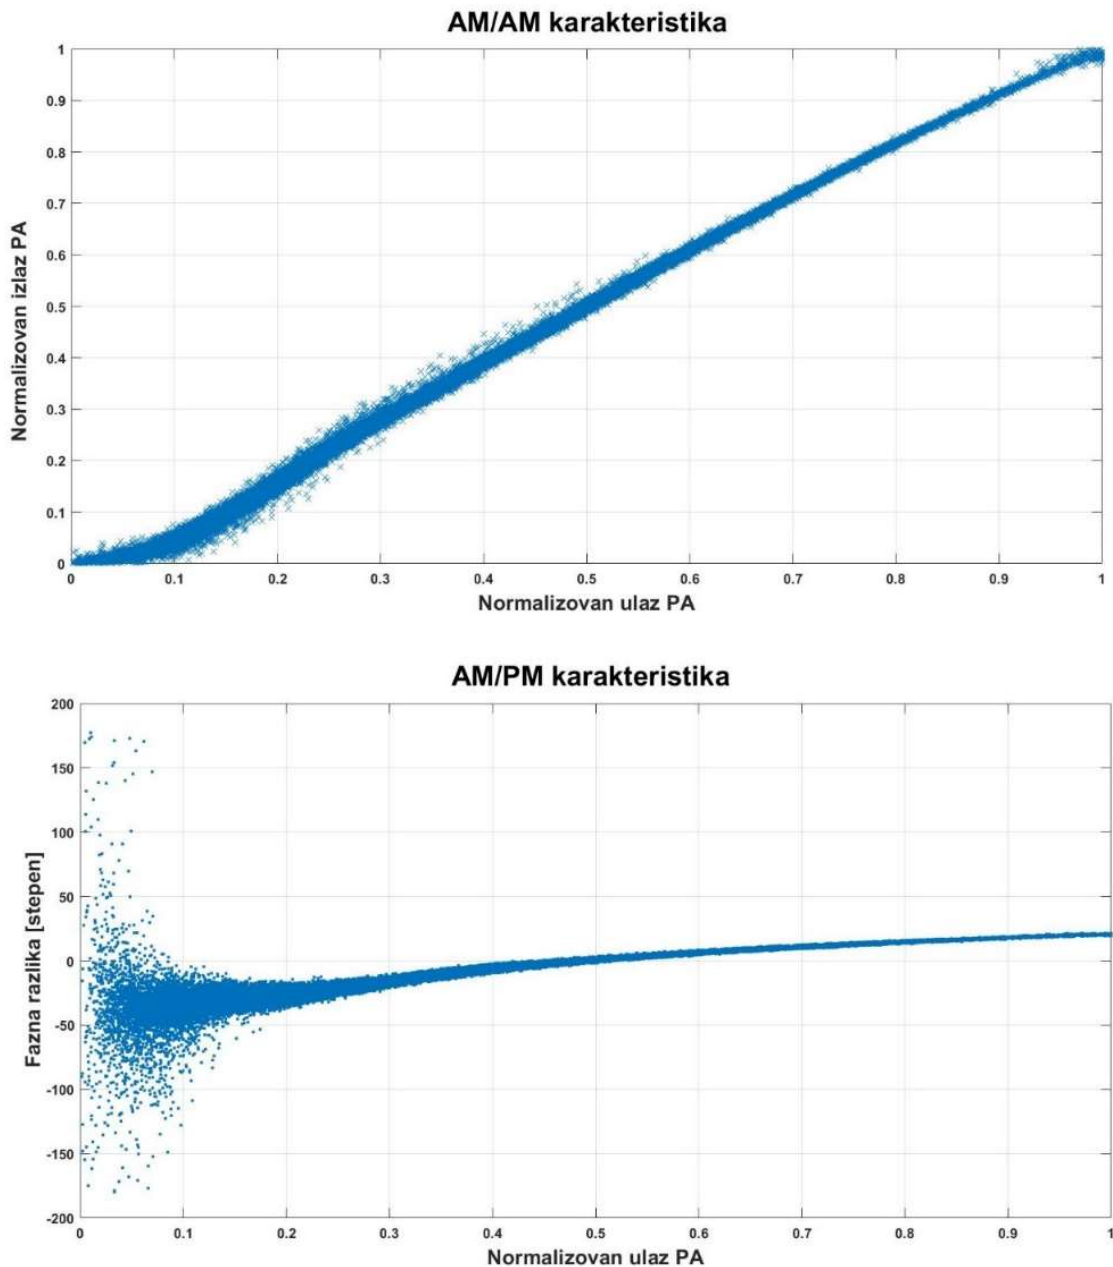




Slika 5.2 – Blok šeme izabranih modela neuralnih mreža: a) DNN, b) RVDNNDNN, c) ARVDNNDNN, d) RVDNNDNN2L.

5.2 Formiranje NN DPD modela

Za potrebe simulacija korišćene su merne vrednosti realnog dvostepenog pojačavača - CFH 2162-P3 PA [139]-[140], pojačanja 14 dB i $P_{1dB}=37$ dBm. Modulisan signal širine 20 MHz, centralne frekvencije 2140 MHz, doveden je na ulaz ovog pojačavača i snimljen je izlazni signal. Na slici 5.3 su date AM/AM i AM/PM karakteristike realnog pojačavača.



Slika 5.3 – AM/AM i AM/PM karakteristike pojačavača.

Na osnovu izmerenih ulazno/izlaznih vrednosti izvršeno je određivanje prenosne funkcije pojačavača, odnosno modelovanje ponašanja pojačavača korišćenjem neuralne mreže. Proces modelovanja ponašanja pojačavača vrši se primenom sledećeg algoritma:

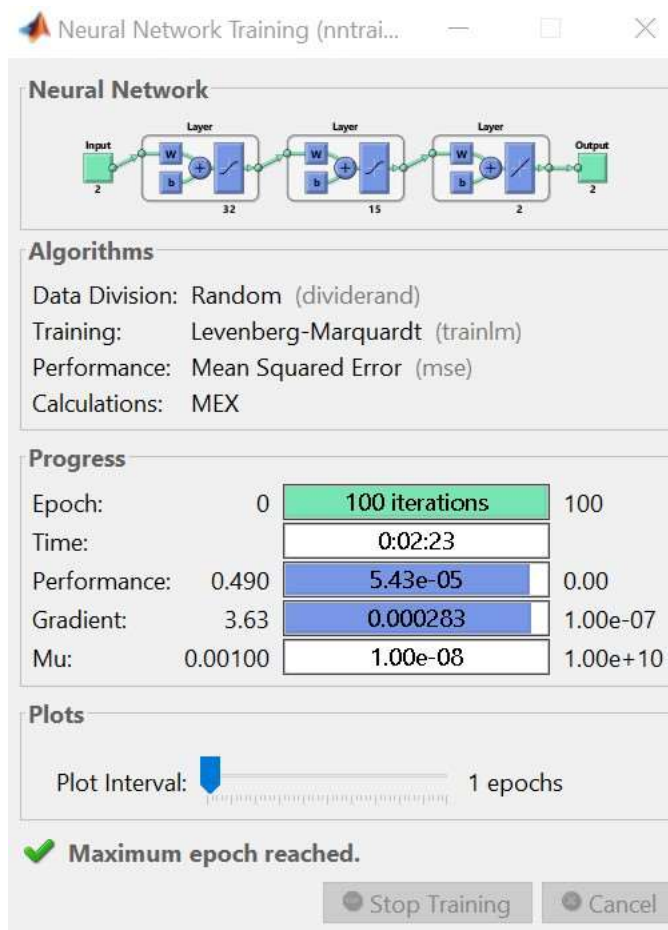
1. Odrediti tip i strukturu neuralne mreže – Izabrana je RVTDNN2L mreža sa dva skrivena sloja, 32 neurona u prvom i 15 neurona u drugom skrivenom sloju, i *tansig* aktivacionom funkcijom.

2. Prikupiti i pripremiti ulazno/izlazne podatke – Sačuvani su ulazni podaci u pojačavač u formi vektora komponenti u fazi i komponenti u kvadraturi \mathbf{X}_n i snimljeni su izlazni podaci iz pojačavača u formi vektora komponenti u fazi i komponenti u kvadraturi \mathbf{Y}_n .
3. Definisati funkciju troškova, odnosno funkciju greške – Izabrana je MSE funkcija, koja se u svakoj iteraciji, za komponente u fazi i kvadraturi generisanog izlaznog signala $I_{\text{out}}(n)$ i $Q_{\text{out}}(n)$, i komponente u fazi i kvadraturi referentnog izlaznog signala $I_{\text{ref}}(n)$ i $Q_{\text{ref}}(n)$, računa po formuli:


$$MSE = \frac{1}{2N} \sum \left((I_{\text{out}}(n) - I_{\text{ref}}(n))^2 + (Q_{\text{out}}(n) - Q_{\text{ref}}(n))^2 \right). \quad (5.6)$$

4. Definisati optimizacioni algoritam – Izabran je LM algoritam sa parametrom učenja $\mu = 0.001$ i faktorom uvećanja $\beta = 10$.
5. Izvršiti treniranje neuralne mreže:
 - i. Za dovedenu ulaznu vrednost izračunati izlaz iz neuralne mreže.
 - ii. Izračunati funkciju troškova prema formuli (5.6).
 - iii. Doneti odluku: ako nisu zadovoljene zahtevane performanse po pitanju vrednosti greške, izvršiti ažuriranje koeficijenata u skladu sa zadatim pravilom učenja i ponoviti proces.
 - iv. Završiti treniranje mreže kada se postigne jedan od sledeća dva kriterijuma:
 - a. postignuta je zahtevana minimalna greška,
 - b. postignut je maksimalan broj iteracija.

Na slici 5.4 prikazan je proces treniranja neuralne mreže koja vrši modelovanje ponašanja realnog pojačavača, dok je na slici 5.5 prikazan rezultat modelovanja, odnosno grafici realnog izmerenog i modelovanog izlaznog signala pojačavača.



Slika 5.4 – Treniranje neuralne mreže koja vrši modelovanje ponašanja pojačavača.



Slika 5.5 – Spektralna gustina snage izlaznog signala pojačavača.

Nakon modelovanja ponašanja pojačavača, formira se NN DPD model za HBF mMIMO predajnik prema šemi sa slike 5.1, pri čemu se simulacije vrše za različite, prethodno izabrane

neuralne mreže (DNN, RVTDDN, ARVTDDN, RVTDDN2L). Ovako kreiran NN DPD model predstavlja integralno rešenje kojim se vrši zajednička kompenzacija svih nelinearnosti pojačavača: preslušavanje, neuravnoteženosti komponenti u fazi i kvadraturi (*I/Q imbalance*) i *DC offset imperfections*.

Kao što je opisano u poglavlju 3.3, hibridni *beamforming* se realizuje primenom digitalnog procesora u osnovnom opsegu, koji vrši prekodiranje signala, i korišćenjem analognih pomerača faze u RF domenu, kojima se vrši promena faze signala. Model je realizovan u programskom paketu *Matlab*, generisanjem koeficijenata za hibridni *beamforming*. Generisanje koeficijenata prekodiranja u osnovnom opsegu F_{BB} i koeficijenata prekodiranja u RF domenu F_{RF} , kao i koeficijenata za kombinovanje u osnovnom opsegu W_{BB} i koeficijenata za kombinovanje u RF domenu W_{RF} , izvršeno je korišćenjem *Spatially Sparse Precoding* algoritma koji vrši potragu za ortogonalnim podudaranjem, koji je opisan u poglavlju 3.3.1. Kod za generisanje koeficijenata za hibridni *beamforming* u *Matlab*-u dat je u prilogu 1.

Korišćen je *Saleh-Valenzuela* model kanala, opisan u poglavlju 3.4.3, sa 6 klastera i 5 rasipača u svakom klasteru. Ovako izabrani parametri modeluju kanal u skladu sa 3GPP specifikacijom [141]. Matematički model kanala definisan je impulsnim odzivom:

$$h(t) = \sum_{l=0}^5 \sum_{k=0}^4 \beta_{kl} \cdot e^{j\theta_{kl}} \cdot \delta(t - T_l - \tau_{kl}), \quad (5.7)$$

gde su: β_{kl} , θ_{kl} - amplituda i faza k -tog zraka u l -tom klasteru, respektivno, T_l - vreme dolaska l -tog klastera, τ_{kl} - kašnjenje dolaska k -tog zraka u odnosu na prvi zrak l -tog klastera.


5.3 Rezultati simulacija za predajnik sa 2 RF grane

Simulacije su izvršene u programskom paketu *Matlab*, u kom je projektovan ceo model predajnika, kao i izabrani modeli neuralnih mreža. Generisan je 64-QAM (*Quadrature Amplitude Modulation*) OFDM (*Orthogonal Frequency Division Multiplexing*) signal širine 20 MHz, pri čemu je razmak podnosioca (*subcarrier*) 15 kHz, a broj korišćenih podnosioca je 1200. Kod za generisanje OFDM signala u *Matlab*-u je dat u prilogu 2.

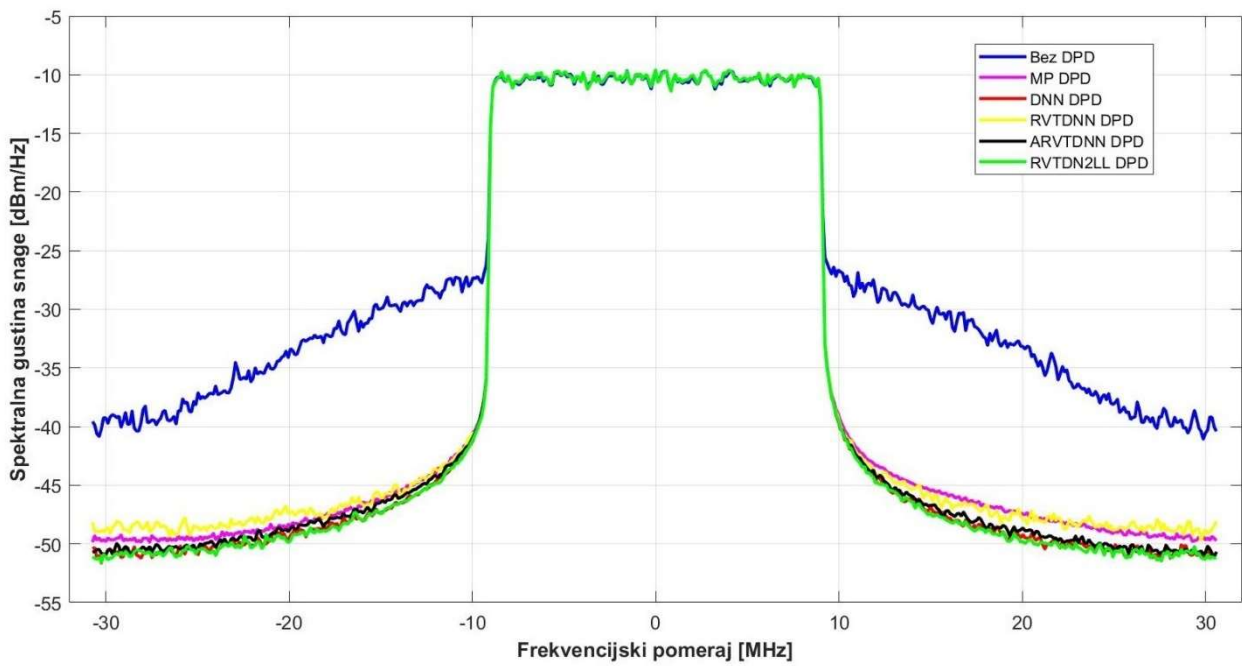
Izvršene su simulacije za 4x4, 16x16 i 64x64 FC HBF MIMO sistem sa 2 RF grane na predajnoj strani i 2 RF grane na prijemnoj strani. Broj pojačavača u predajniku ne zavisi od broja RF grana i jednak je broju izlaznih antenskih elemenata, tj. 4, 16 i 64 pojačavača u slučaju 4x4, 16x16 i 64x64 FC HBF MIMO sistema, respektivno. Ukupan broj faznih pomerača kod potpuno povezane arhitekture zavisi od broja RF grana (P) i broja izlaznih antenskih elemenata (N_T) i jednak je njihovom proizvodu $P \cdot N_T$. U slučaju 4x4, 16x16 i 64x64 FC HBF MIMO sistema sa 2 RF grane ukupan broj faznih pomerača u predajniku je 8, 32 i 128, respektivno. U slučaju 4x4, 16x16 i 64x64 FC HBF MIMO sistema sa 4 RF grane ukupan broj faznih pomerača u predajniku je 16, 64 i 256, respektivno. Dok je u slučaju 4x4, 16x16 i 64x64 FC HBF MIMO sistema sa 8 RF grana ukupan broj faznih pomerača u predajniku 32, 128 i 512, respektivno. Performanse i efikasnost primenjenih DPD modela realizovanih primenom izabranih neuralnih mreža upoređeni su sa MP DPD modelom opisanim u poglavlju 3.6.7. Za procenu performansi modela korišćena su dva parametra: normalizovana srednja kvadratna greška NMSE i amplituda vektora greške EVM.

Na slici 5.6 prikazana je spektralna gustina snage izlaznog signala bez digitalne predistorzije, i u slučaju korišćenja digitalne predistorzije primenom različitih neuralnih mreža, kao i primenom MP DPD modela. Dobijene vrednosti za NMSE i EVM za 4x4, 16x16 i 64x64 FC HBF MIMO


sistem sa 2 RF grane na predajnoj strani i 2 RF grane na prijemnoj strani prikazane su u tabelama 5.6, 5.7 i 5.8, respektivno.



a) 4x4



b) 16x16



Slika 5.6 – Spektralna gustina snage izlaznog signala FC HBF mMIMO predajnika: a) 4x4; b) 16x16; c) 64x64.

Tabela 5.6 – Performanse različitih DPD modela za 4x4 FC HBF mMIMO predajnik.

Tip DPD	EVM [%]	NMSE [dB]
Bez DPD	20.88	-
MP	1.29	-37.81
DNN	1.11	-39.14
RVTDNN	1.39	-37.11
ARVTDNN	1.19	-38.48
RVTDNN2L	0.91	-40.83

Tabela 5.7 – Performanse različitih DPD modela za 16x16 FC HBF mMIMO predajnik.

Tip DPD	EVM [%]	NMSE [dB]
Bez DPD	26.67	-
MP	1.99	-33.99
DNN	1.15	-38.78
RVTDNN	1.92	-34.32
ARVTDNN	1.45	-36.78
RVTDNN2L	1.03	-39.76

Tabela 5.8 – Performanse različitih DPD modela za 64x64 FC HBF mMIMO predajnik [31].

Tip DPD	EVM [%]	NMSE [dB]
Bez DPD	22.09	-
MP	2.04	-33.79
DNN	1.37	-37.25
RVTDNN	1.99	-33.98
ARVTDNN	1.70	-35.39
RVTDNN2L	1.23	-38.19

Može se primetiti da je linearizacija pojačavača značajno poboljšana sa NN DPD modelima u poređenju sa MP DPD modelom, posebno sa RVTDNN2L DPD modelom. Treba napomenuti da su posmatrani NN DPD modeli slični po složenosti, odnosno po broju FLOP-ova.

Kako je predmet ove doktorske disertacije razvoj modela digitalne predistorzije za masivne višeantenske predajnike, koji obično imaju desetine i stotine antena na predajnoj strani, u daljem radu će biti analiziran sistem za 64 antenska elementa na predajnoj strani i 64 antenska elementa na prijemnoj strani, odnosno 64x64 FC HBF mMIMO sistem.


5.4 Rezultati simulacija za predajnik sa više RF grana

Predložen RVTDNN2L DPD model, koji se pokazao kao najefikasniji model od svih prethodno testiranih NN DPD modela za digitalnu predistorziju FC HBF mMIMO predajnika sa dve RF grane, je zatim primenjen na potpuno povezan hibridni *beamforming* mMIMO sistem sa 4 RF grane na predajnoj strani i 4 RF grane na prijemnoj strani, kao i na potpuno povezan hibridni *beamforming* mMIMO sistem sa 8 RF grana na predajnoj strani i 8 RF grana na prijemnoj strani. Simulacije su odrađene sa istim ulaznim signalom kao u prethodnoj analizi. Za određivanje koeficijenata hibridnog *beamforming*-a za sistem sa više grana korišćen je *Spatially Sparse Precoding* algoritam, kao i u prethodnoj analizi.

Na slici 5.7 prikazana je spektralna gustina snage izlaznog signala za potpuno povezan hibridni *beamforming* mMIMO predajnik sa 2, 4 i 8 grana, dok su dobijene vrednosti za NMSE i EVM prikazane u tabeli 5.9.

Tabela 5.9 – Performanse različitih DPD modela za 64x64 FC HBF mMIMO predajnik sa više RF grana [31].

	2 RF grane	4 RF grane	8 RF grana
EVM bez DPD [%]	22.09	22.39	23.39
EVM sa RVTDNN2L DPD [%]	1.23	1.04	0.74
NMSE sa RVTDNN2L DPD [dB]	-38.19	-39.63	-42.60



Slika 5.7 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika sa više RF grana.

Može se primetiti da se EVM bez DPD povećava sa povećanjem broja RF grana. Ovo znači da se sa povećanjem broja RF grana povećava i nelinearna distorzija. Dobijeni rezultati simulacije, takođe, pokazuju da EVM i NMSE sa predloženim RVTDNN2L DPD modelom opadaju sa povećanjem broja RF grana. Ova poboljšanja EVM-a i NMSE-a znače da predloženi model bolje kompenzuje nelinearnu distorziju ukoliko se broj RF grana poveća. Razlog za ovo poboljšanje se može objasniti činjenicom da su RF signali međusobno više u korelaciji.

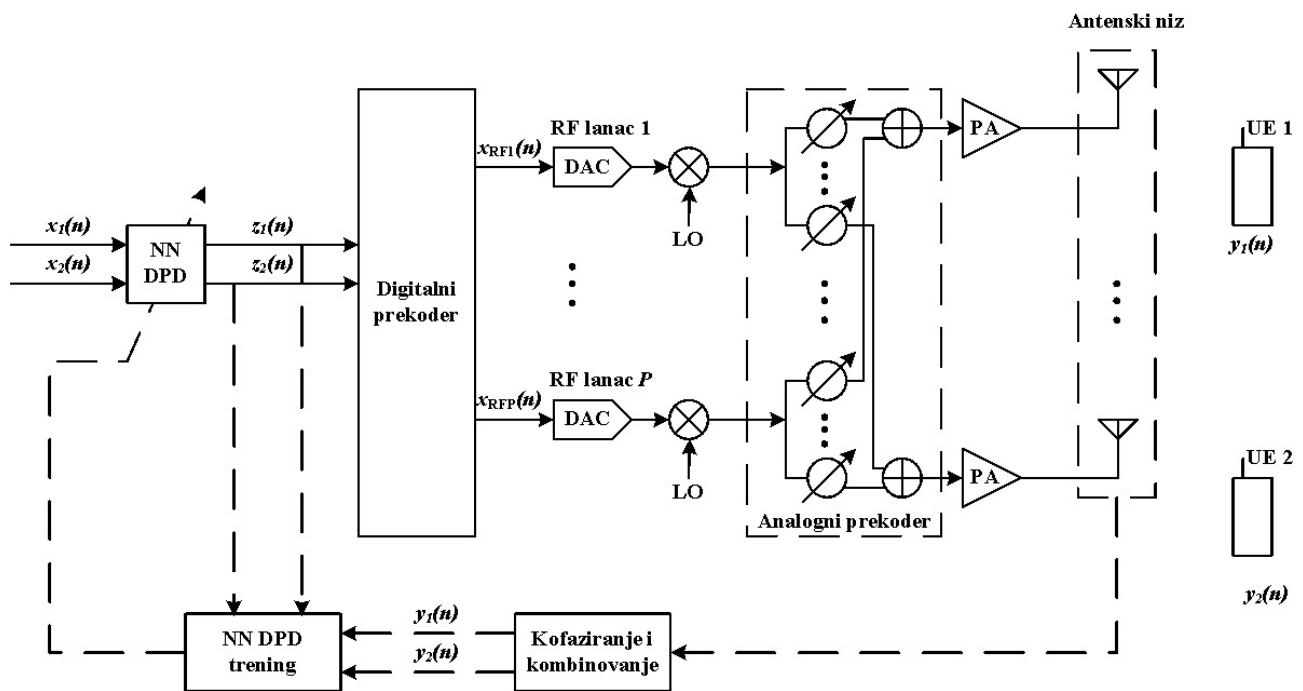
Kako sa povećanjem broja RF grana raste i cena implementacije fizičkog MIMO sistema, u praksi se, najčešće, koriste hibridni *beamforming* mMIMO predajnici sa 2 RF grane. Iz tog razloga je u daljim istraživanjima analiziran potpuno povezan 64x64 HBF mMIMO predajnik sa dve RF grane.

6. NN DPD ZA MU HBF mMIMO PREDAJNIKE

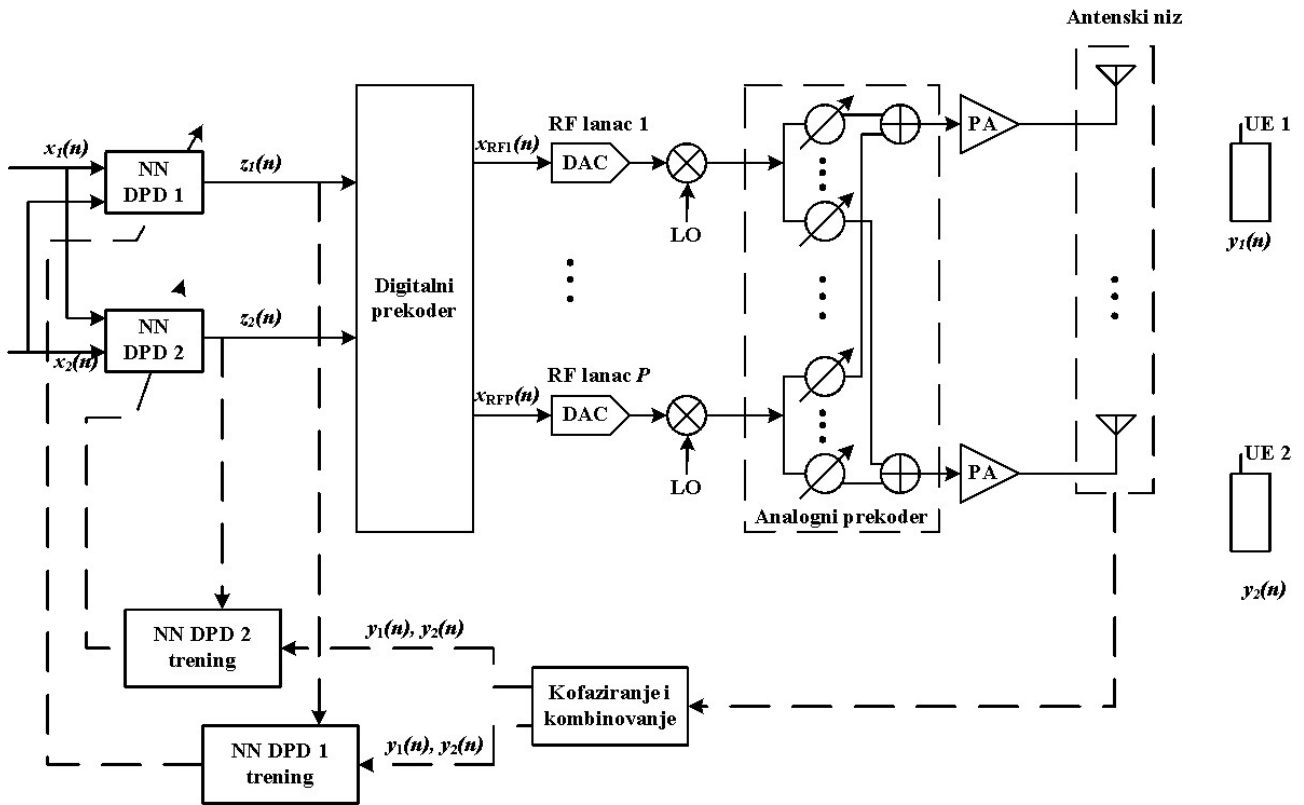
U ovoj poglavlju biće ispitane performanse predloženog RVTDDN2L DPD modela za kompenzaciju nelinearne distorzije kod potpuno povezanog hibridnog *beamforming* mMIMO predajnika sa više korisnika, tzv. *Multi-User* (MU) slučaj. U slučaju potpuno povezanog hibridnog *beamforming* mMIMO predajnika sa više korisnika prilikom izgradnje DPD modula potrebno je uzeti u obzir signale svih korisnika. Razlog je taj što se prilikom hibridnog *beamforming*-a podaci koji se šalju formiraju na osnovu podataka svih korisnika. U okviru ove doktorske disertacije razmatran je i simuliran potpuno povezan hibridni *beamforming* mMIMO sistem sa dva korisnika. Uz određene manje izmene, ovaj sistem se može prilagoditi za slučaj sa više od dva korisnika. Predložene su sledeće dve arhitekture:

- DPD sistem sa jednom RVTDDN2L mrežom sa ulaznim i izlaznim signalima za oba korisnika (arhitektura 1),
- DPD sistem sa dve RVTDDN2L mreže sa ulaznim signalima oba korisnika i izlaznim signalom za svakog korisnika posebno (arhitektura 2).

Blok šeme predloženih arhitektura su prikazane na slikama 6.1 i 6.2.



Slika 6.1 – Blok šema arhitekture 1 RVTDDN2L DPD modela za MU FC HBF mMIMO predajnik.



Slika 6.2 – Blok šema arhitekture 2 RVT-DNN2L DPD modela za MU-FC-HBF-mMIMO predajnik.

6.1 Formiranje RVT-DNN2L DPD modela

Za potrebe simulacija u slučaju sistema sa više korisnika korišćen je isti model pojačavača kao i u slučaju sistema sa jednim korisnikom, odnosno korišćen je NN model realnog pojačavača CFH 2162-P3 PA, pojačanja 14 dB i P1dB=37 dBm, modelovan u poglavlju 5.2.

Kao i u slučaju sistema sa jednim korisnikom, koeficijenti hibridnog *beamforming*-a generisani su pomoću *Spatially Sparse Precoding* algoritma, opisanog u poglavlju 3.3.1, koji vrši potragu za ortogonalnim podudaranjem. Korišćen je *Saleh-Valenzuela* model kanala, opisan u poglavlju 3.4.3, sa 6 klastera i 10 rasipača u svakom klasteru. Matematički model kanala definisan je impulsnim odzivom:

$$h(t) = \sum_{l=0}^5 \sum_{k=0}^9 \beta_{kl} \cdot e^{j\theta_{kl}} \cdot \delta(t - T_l - \tau_{kl}), \quad (6.1)$$

gde su: β_{kl} , θ_{kl} - amplituda i faza k -tog zraka u l -tom klasteru, respektivno, T_l - vreme dolaska l -tog klastera, τ_{kl} - kašnjenje dolaska k -tog zraka u odnosu na prvi zrak l -tog klastera.

U slučaju arhitekture 1 sa jednom RVT-DNN2L mrežom, prikazane na slici 6.1, ulazni signali u neuralnu mrežu su komponente signala u fazi I i kvadraturi Q oba korisnika, a izlazni signali su komponente signala u fazi I i kvadraturi Q za oba korisnika. Stoga neuralna mreža sadrži 4 neurona u ulaznom sloju i 4 neurona u izlaznom sloju. U slučaju arhitekture 2 sa dve RVT-DNN2L mreže, prikazane na slici 6.2, ulazni signali u svaku neuralnu mrežu su komponente signala u fazi I i kvadraturi Q oba korisnika, dok su izlazni signali iz svake mreže komponente signala u fazi I i kvadraturi Q za odgovarajućeg korisnika. Stoga neuralna mreža sadrži 4 neurona u ulaznom sloju i

2 neurona u izlaznom sloju. Simulacije su vršene sa različitim brojem neurona u skrivenim slojevima, kako bi se predložilo optimalno rešenje koje daje najbolje rezultate. Korišćena je *tansig* aktivaciona funkcija.

Neuralne mreže su trenirane korišćenjem LM algoritma, opisanog u poglavlju 4.3.2, sa inicijalnim vrednostima parametra učenja $\mu = 0.001$ i faktora uvećanja $\beta = 10$. Tokom treninga neuralne mreže korišćen je postupak unakrsne validacije, opisan u poglavlju 4.4.1.

Proces treniranja neuralne mreže izvršen je korišćenjem sledećeg algoritma:

1. Za dovedenu ulaznu vrednost izračunati izlaz iz neuralne mreže.
2. Izračunati funkciju troškova prema formuli:

$$MSE = \frac{1}{2N} \sum \left((I_{out1}(n) - I_{ref1}(n))^2 + (Q_{out1}(n) - Q_{ref1}(n))^2 \right) + \frac{1}{2N} \sum \left((I_{out2}(n) - I_{ref2}(n))^2 + (Q_{out2}(n) - Q_{ref2}(n))^2 \right). \quad (6.2)$$

3. Doneti odluku: ako nisu zadovoljene zahtevane performanse po pitanju vrednosti greške, izvršiti ažuriranje koeficijenata u skladu sa zadatim pravilom učenja i ponoviti proces.
4. Završiti treniranje mreže kada se postigne jedan od sledeća dva kriterijuma:
 - i. postignuta je zahtevana minimalna greška,
 - ii. postignut je maksimalan broj iteracija.


6.2 Rezultati simulacija

Za potrebe simulacija, generisana su dva nezavisna 64-QAM OFDM signala širine 20 MHz, sa razmakom podnosioca 15 kHz. Simulacije su izvršene za 64x64 FC HBF mMIMO sistem sa 2 korisnika, 2 RF grane na predaji i 2 RF grane na prijemu, za oba tipa arhitekture, prikazana na slikama 6.1 i 6.2.


Dobijene spektralne gustine snage izlaznog signala sa i bez primene digitalne predistorzije, za korisnika 1 i 2, za oba tipa predložene arhitekture, prikazane su na slikama 6.3 i 6.4, respektivno. Prikazani su dobijeni rezultati za tri različite kombinacije broja neurona u skrivenim slojevima, i to:

- 18 neurona u prvom skrivenom sloju i 9 neurona u drugom skrivenom sloju,
- 32 neurona u prvom skrivenom sloju i 15 neurona u drugom skrivenom sloju,
- 48 neurona u prvom skrivenom sloju i 21 neuron u drugom skrivenom sloju.

Dobijene vrednosti za EVM i NMSE su prikazane u tabelama 6.1 i 6.2, za prvog i drugog korisnika, respektivno. Iz dobijenih rezultata, može se primetiti da se u slučaju HBF mMIMO sistema sa više korisnika dobijaju nešto lošije performanse linearizacije, u odnosu na sistem sa jednim korisnikom. Stoga je potrebno dodatno povećati složenost RVTDDN2L DPD sistema za slučaj više korisnika, kako bi se efikasno linearizovali pojačavači, bilo povećanjem broja neurona u svakom sloju, ili uvođenjem drugog RVTDDN2L DPD bloka za drugog korisnika.



Slika 6.3 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika – korisnik 1.



Slika 6.4 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika – korisnik 2.

Tabela 6.1 – Performanse RVTDNN2L DPD modela za 64x64 FC HBF mMIMO predajnik – korisnik 1 [31].

RVTDNN2L	Arh 1		Arh 2	
	EVM [%]	NMSE [dB]	EVM [%]	NMSE [dB]
I=18, II=9	4.07	-27.81	3.16	-30.02
I=32, II=15	3.08	-30.22	2.13	-33.45
I=48, II=21	2.48	-32.11	1.78	-34.97

Tabela 6.2 – Performanse RVTDDNN2L DPD modela za 64x64 FC HBF mMIMO predajnik – korisnik 2 [31].

RVTDDNN2L	Arh 1		Arh 2	
	EVM [%]	NMSE [dB]	EVM [%]	NMSE [dB]
I=18, II=9	4.56	-26.81	3.47	-29.19
I=32, II=15	3.34	-29.52	2.24	-32.98
I=48, II=21	2.69	-31.40	1.97	-34.11

Analizom dobijenih rezultata može se primetiti da se bolji rezultati postižu primenom arhitekture 2 DPD modela realizovanog sa dve RVTDDNN2L mreže, u poređenju sa arhitekturom 1 DPD modela realizovanog primenom jedne RVTDDNN2L mreže. Sa druge strane, primena dve neuralne mreže dodatno povećava kompleksnost DPD modela, po pitanju broja koeficijenata i broja FLOP-ova. Stoga je potrebno razmotriti i analizirati performanse predloženih arhitektura u zavisnosti od kompleksnosti. Kompleksnost izabranih arhitektura DPD modela, u zavisnosti od broja neurona po slojevima, prikazana je u tabeli 6.3.

Tabela 6.3 – Kompleksnost različitih arhitektura RVTDDNN2L DPD modela [31].

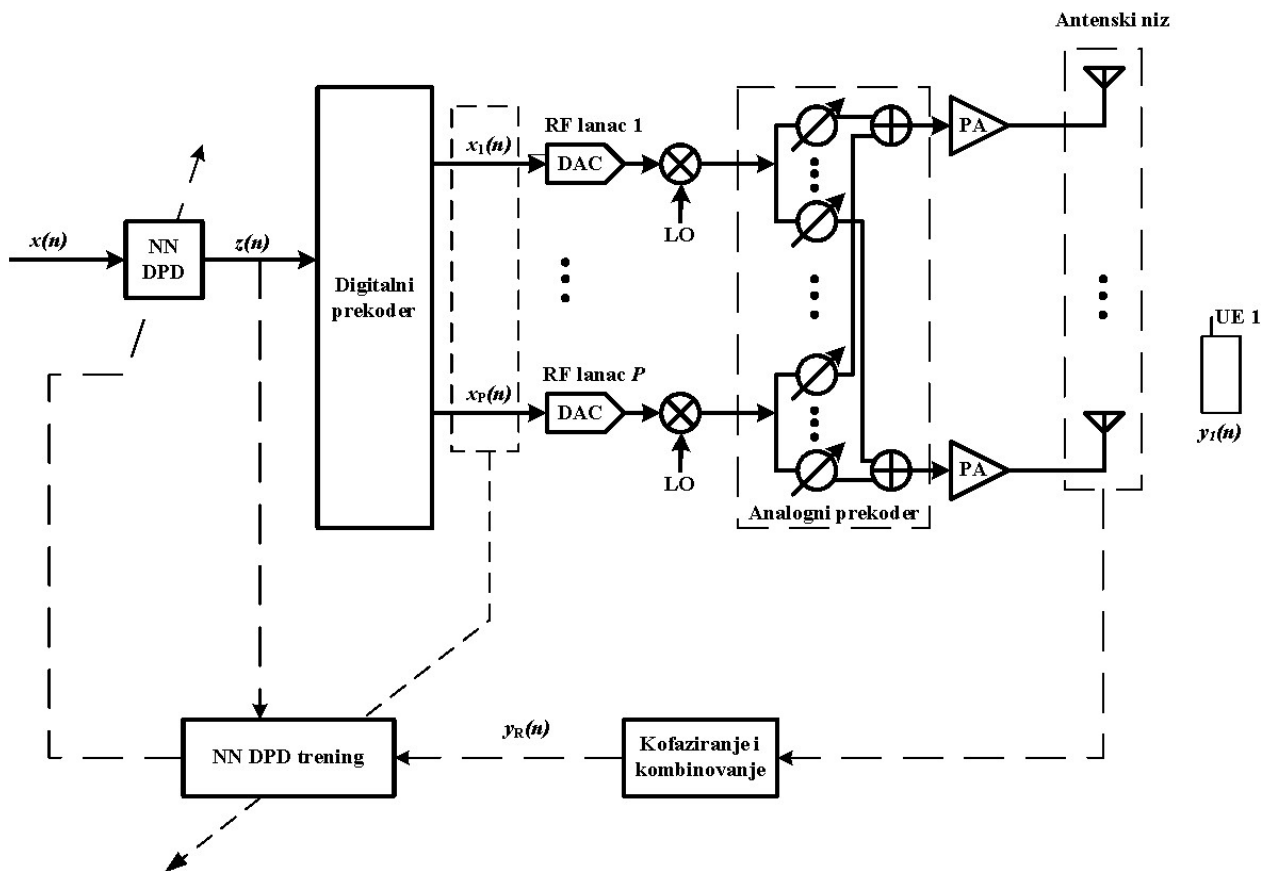
RVTDDNN2L	Arhitektura 1		Arhitektura 2	
	N_{coef}	FLOP	N_{coef}	FLOP
I=18, II=9	301	945	562	1818
I=32, II=15	719	2041	1374	3962
I=48, II=21	1357	3603	2626	7038

Analizom dobijenih rezultata, prikazanih u tabelama 6.1 i 6.2, a uzimajući u obzir i složenost sistema prikazanu u tabeli 6.3, može se zaključiti da se najbolji rezultati postižu primenom DPD arhitekture sa dve RVTDDNN2L mreže, sa 32 neurona u prvom skrivenom sloju i 15 neurona u drugom skrivenom sloju.

7. PROŠIREN NN DPD MODEL

U petom poglavlju opisan je i testiran model za digitalnu predistorziju hibridnog *beamforming* mMIMO predajnika primenom različitih tipova neuralnih mreža, pri čemu se RVTDNN2L mreža pokazala kao najefikasnija, odnosno primenom RVTDNN2L DPD modela postignute su najbolje performanse. Nakon toga, u šestom poglavlju potvrđena je efikasnost predloženog RVTDNN2L DPD modela za slučaj hibridnog *beamforming* mMIMO predajnika sa više korisnika. Kao što je već rečeno, izlazni signal iz hibridnog *beamforming* mMIMO predajnika, zavisi od koeficijenata *beamforming*-a. Kako se za konstrukciju RVTDNN2L DPD modela kao ulazni parametar, pored ulaznog signala koristi i izlazni signal iz predajnika, može se zaključiti da i parametri DPD bloka zavise od koeficijenata *beamforming*-a. Stoga je ideja dovesti dodatni signal koji sadrži informacije o koeficijentima *beamforming*-a, za treniranje neuralne mreže, kako bi se povećala tačnost NN DPD modela.

U ovom poglavlju predložen je proširen RVTDNN2L DPD model, kod koga se za potrebe treniranja NN mreže dovodi još jedan signal sa RF grana, tj. signal nakon digitalnog, a pre analognog *beamforming*-a. Blok šema modela prikazana je na slici 7.1.



Slika 7.1 – Blok šema proširenog RVTDNN2L DPD modela za SU FC HBF mMIMO predajnik.

Model digitalne predistorzije formira se korišćenjem ILA metode, u dva koraka. Prvi korak je kreiranje i treniranje predložene proširene RVDNN2L mreže. Drugi korak je primena istrenirane neuralne mreže za ažuriranje ulaznog signala u hibridni *beamforming* mMIMO predajnik.

Proces treniranja neuralne mreže vrši se primenom sledećeg algoritma:

1. Odrediti tip i strukturu neuralne mreže – Izabrana je RVDNN2L mreža sa dva skrivena sloja, 18 neurona u prvom i 9 neurona u drugom skrivenom sloju, i *tansig* aktivacionom funkcijom.
2. Prikupiti i pripremiti ulazno/izlazne podatke – Kao ulazni podaci u neuralnu mrežu uzete su komponente signala u fazi I i kvadraturi Q sa svake RF grane, kao i komponente u fazi I i kvadraturi Q kofaziranog i kombinovanog izlaznog signala sa svih pojačavača. Ukoliko sa $I_{out}(n)$ i $Q_{out}(n)$ označimo komponente u fazi i kvadraturi generisanog izlaznog signala, sa $I_{RFi}(n)$ i $Q_{RFi}(n)$ komponente u fazi i kvadraturi signala i -te RF grane, i sa $I_{in}(n)$ i $Q_{in}(n)$ komponente u fazi i kvadraturi dovedenog ulaznog signala, ulazni i izlazni vektor neuralne mreže se može matematički prikazati na sledeći način:

$$\mathbf{X}_n = [I_{out}(n), Q_{out}(n), I_{RF1}(n), Q_{RF1}(n), \dots, I_{RFP}(n), Q_{RFP}(n)], \quad (7.1)$$

$$\mathbf{Y}_n = [I_{in}(n), Q_{in}(n)]. \quad (7.2)$$

3. Definisati funkciju troškova, odnosno funkciju greške – Izabrana je MSE funkcija, koja se u svakoj iteraciji, za komponente u fazi i kvadraturi generisanog izlaznog signala $I_{out}(n)$ i $Q_{out}(n)$, i komponente u fazi i kvadraturi referentnog izlaznog signala $I_{ref}(n)$ i $Q_{ref}(n)$, računa po formuli:

$$MSE = \frac{1}{2N} \sum \left((I_{out}(n) - I_{ref}(n))^2 + (Q_{out}(n) - Q_{ref}(n))^2 \right). \quad (7.3)$$

4. Definisati optimizacioni algoritam – Izabran je LM algoritam sa parametrom učenja $\mu = 0.001$ i faktorom uvećanja $\beta = 10$.
5. Izvršiti treniranje neuralne mreže:
 - i. Za dovedenu ulaznu vrednost izračunati izlaz iz neuralne mreže.
 - ii. Izračunati funkciju troškova prema formuli (7.3).
 - iii. Doneti odluku: ako nisu zadovoljene zahtevane performanse po pitanju vrednosti greške, izvršiti ažuriranje koeficijenata u skladu sa zadatim pravilom učenja i ponoviti proces.
 - iv. Završiti treniranje mreže kada se postigne jedan od sledeća dva kriterijuma:
 - a. postignuta je zahtevana minimalna greška,
 - b. postignut je maksimalan broj iteracija.

Nakon procesa treniranja, neuralna mreža se koristi za modifikovanje ulaznog signala u predajnik u cilju smanjenja nelinearnosti, odnosno smanjenja distorzije signala.

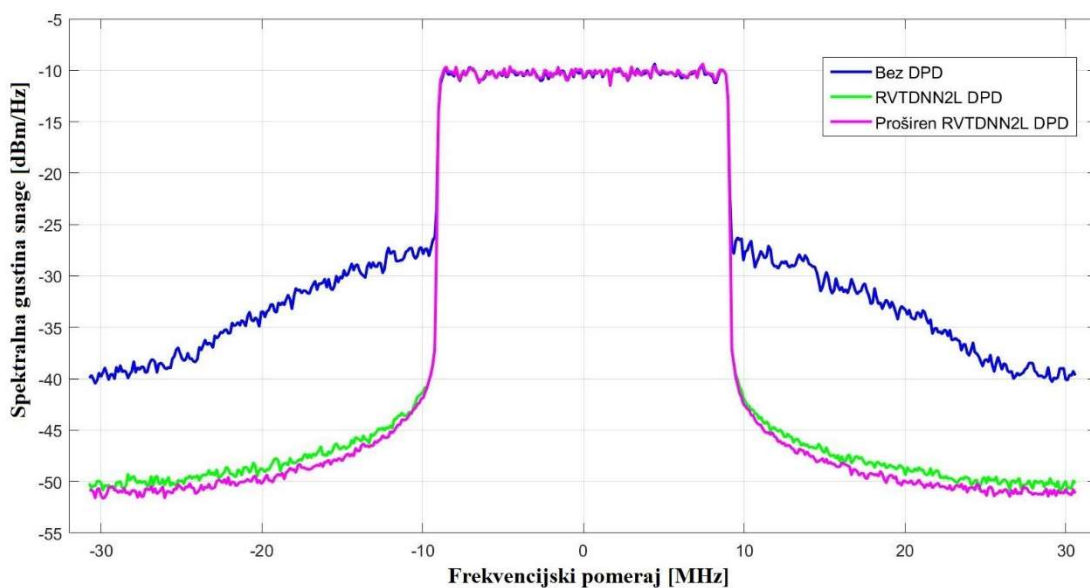
7.1 Rezultati simulacija za SU slučaj

Za potrebe simulacije, u programskom paketu *Matlab*, generisan je 64-QAM OFDM signal širine 20 MHz, sa razmakom podnosioca (*subcarrier*) 15 kHz. Generisani signal je propušten kroz potpuno povezan HBF mMIMO predajnik, u potpunosti realizovan u *Matlab*-u, pri čemu je korišćen model realnog pojačavača CFH 2162-P3 PA, pojačanja 14 dB i P1dB=37 dBm, modelovan RVTDDN2L mrežom sa dva skrivena sloja, 32 neurona u prvom i 15 neurona u drugom skrivenom sloju, i *tansig* aktivacionom funkcijom. Modelovanje ovog pojačavača opisano je u poglavlju 5.2. Kao i u petom poglavlju, za određivanje koeficijenata *beamforming*-a korišćen je *Spatially Sparse Precoding* algoritam, opisan u poglavlju 3.3.1, i *Saleh-Valenzuela* model kanala, opisan u poglavlju 3.4.3, sa 6 klastera i 5 rasipača u svakom klasteru, čiji je impulsni odziv:


$$h(t) = \sum_{l=0}^5 \sum_{k=0}^4 \beta_{kl} \cdot e^{j\theta_{kl}} \cdot \delta(t - T_l - \tau_{kl}), \quad (7.4)$$

gde su: β_{kl} , θ_{kl} - amplituda i faza k -tog zraka u l -tom klasteru, respektivno, T_l - vreme dolaska l -tog klastera, τ_{kl} - kašnjenje dolaska k -tog zraka u odnosu na prvi zrak l -tog klastera.

Na slici 7.2 prikazane su spektralne gustine snaga izlaznog signala 64x64 FC HBF mMIMO predajnika sa 2 RF grane bez digitalne predistorzije i u slučaju korišćenja digitalne predistorzije primenom predloženog proširenog RVTDDN2L DPD modela i primenom klasičnog RVTDDN2L DPD modela, koji se u petom poglavlju pokazao kao najefikasniji model. Na slici 7.3 dat je uporedni prikaz spektralne gustine snage izlaznog signala 64x64 FC HBF mMIMO predajnika sa 2 RF grane, u slučaju primene različitih modela neuralnih mreža analiziranih u petom poglavlju i predloženog proširenog RVTDDN2L DPD modela. Dobijene vrednosti za NMSE i EVM prikazane su u tabeli 7.1, dok je u tabeli 7.2 dat uporedni prikaz prametara i kompleksnosti proširenog i klasičnog RVTDDN2L DPD modela.



Slika 7.2 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika za klasičan i proširen RVTDDN2L DPD model.



Slika 7.3 – Uporedni prikaz spektralne gustine snage izlaznog signala 64x64 FC HBF mMIMO predajnika za svih šest analiziranih DPD modela.

Tabela 7.1 – Performanse različitih DPD modela za 64x64 FC HBF mMIMO predajnik.

Tip DPD	EVM [%]	NMSE [dB]
Bez DPD	22.16	-
MP	3.67	-28.72
DNN	1.84	-34.71
RVTDNN	2.88	-30.82
ARVTDNN	2.48	-32.11
RVTDNN2L	1.77	-35.02
Proširen RVTDNN2L	1.47	-36.64

Tabela 7.2 – Parametri i kompleksnost proširenog i klasičnog RVTDNN2L DPD modela.

Tip NN mreže	Ulazni podaci	Broj neurona u ulaznom sloju	Broj neurona u skrivenim slojevima	Aktivaciona funkcija	Broj neurona u izlaznom sloju	N_{coef}	FLOP
RVTDNN2L	I, Q	2	18 9	<i>tansig</i>	2	245	837
Proširen RVTDNN2L	$I, Q, I/Q$ RF lanca 1, I/Q RF lanca 2	6	18 9	<i>tansig</i>	2	296	977

Na osnovu dobijenih rezultata može se zaključiti da predložen proširen RVTDNN2L DPD model bolje kompenzuje nelinearnost potpuno povezanog hibridnog *beamforming* mMIMO predajnika, za slučaj sa jednim korisnikom. Ovo poboljšanje je postignuto na račun povećanja

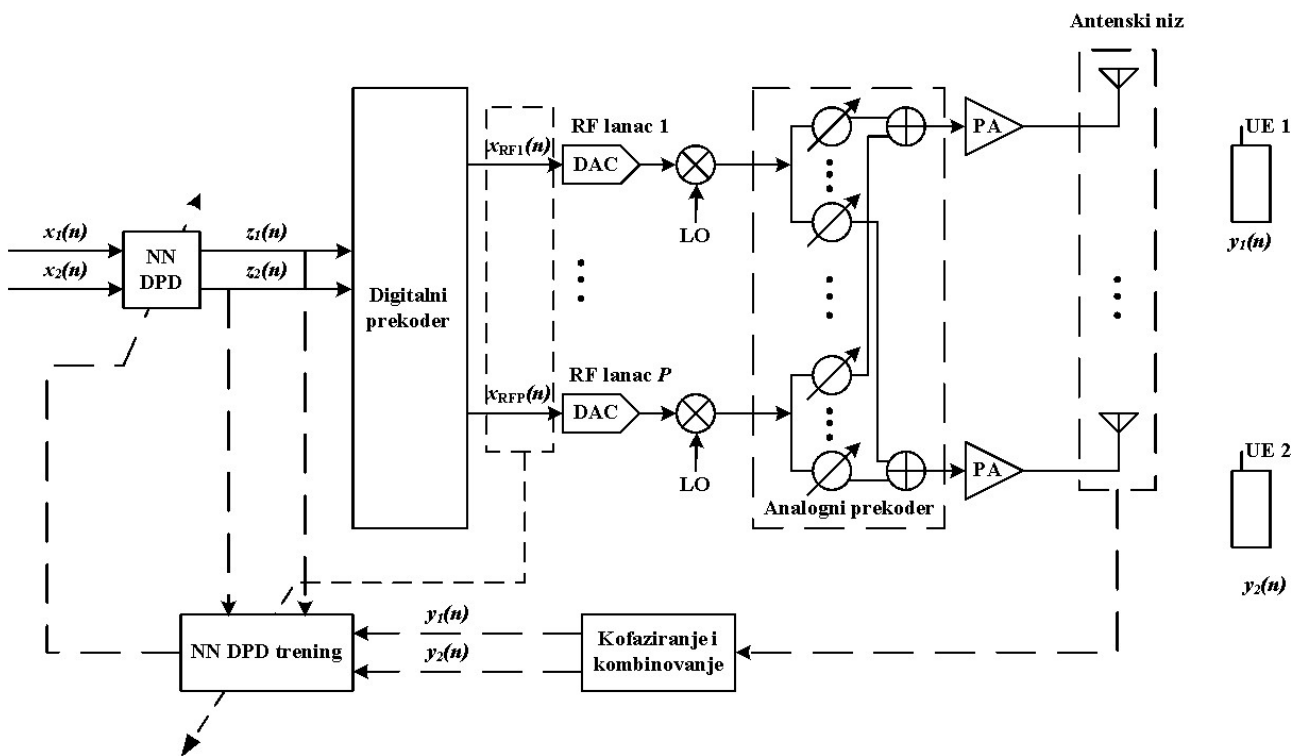
kompleksnosti modela. U zavisnosti od zahteva, vršiće se izbor neuralne mreže. U slučaju da kompleksnost neuralne mreže nije od presudnog značaja, već da je bitnija što bolja kompenzacija nelinearne distorzije, biće izabran proširen RVTDDNN2L DPD model.

7.2 Rezultati simulacija za MU slučaj

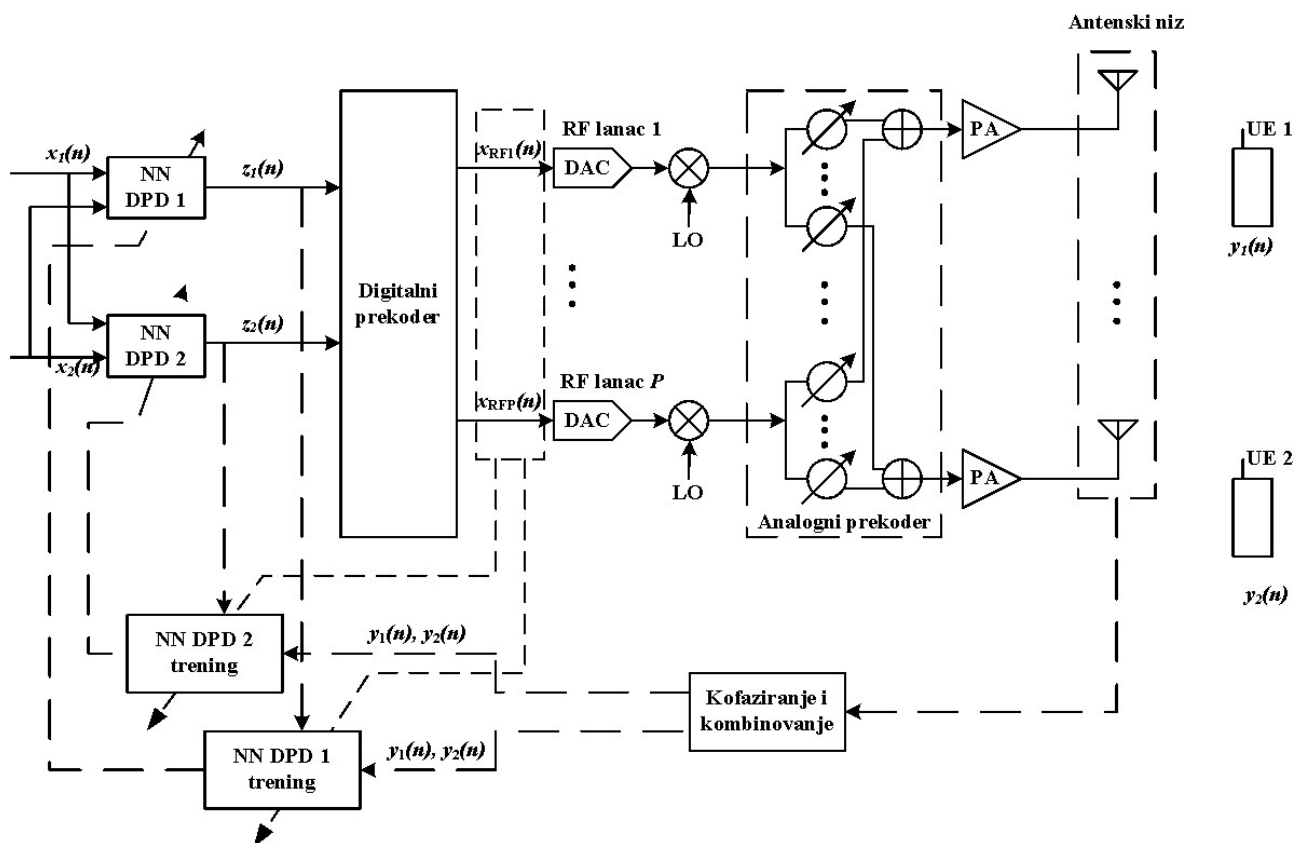
U šestom poglavlju predložene su dve arhitekture DPD sistema za slučaj hibridnog *beamforming* mMIMO predajnika sa dva korisnika. U ovom poglavlju će biti primenjen proširen RVTDDNN2L DPD model na predložene dve arhitekture, odnosno biće analizirane sledeće dve arhitekture:

- DPD sistem sa jednom proširenom RVTDDNN2L mrežom sa ulaznim signalima sa oba RF lanca i signalima za oba korisnika i izlaznim signalima za oba korisnika (arhitektura 1),
- DPD sistem sa dve proširene RVTDDNN2L mreže sa ulaznim signalima sa oba RF lanca i signalima oba korisnika i izlaznim signalom za svakog korisnika posebno (arhitektura 2).

Blok šeme predloženih arhitektura prikazane su na slikama 7.4 i 7.5.



Slika 7.4 – Blok šema arhitekture 1 proširenog RVTDDNN2L DPD modela za MU FC HBF mMIMO predajnik.




Slika 7.5 – Blok šema arhitekture 2 proširenog RVT-DNN2L DPD modela za MU-FC-HBF mMIMO predajnik.

Za potrebe simulacije, generisana su dva 64-QAM OFDM signala širine 20 MHz, sa razmakom podnosioca (*subcarrier*) 15 kHz. Generisani signali su propušteni kroz potpuno povezan hibridni *beamforming* mMIMO predajnik, u potpunosti realizovan u *Matlab*-u, pri čemu je korišćen model realnog pojačavača CFH 2162-P3 PA, pojačanja 14 dB i P1dB=37 dBm, modelovan RVT-DNN2L mrežom sa dva skrivena sloja, 32 neurona u prvom i 15 neurona u drugom skrivenom sloju, i *tansig* aktivacionom funkcijom. Modelovanje ovog pojačavača opisano je u poglavlju 5.2. Kao i u šestom poglavlju, za određivanje koeficijenata *beamforming*-a korišćen je *Spatially Sparse Precoding* algoritam, opisan u poglavlju 3.3.1, i *Saleh-Valenzuela* model kanala, opisan u poglavlju 3.4.3, sa 6 klastera i 10 rasipača u svakom klasteru, čiji je impulsni odziv:


$$h(t) = \sum_{l=0}^5 \sum_{k=0}^9 \beta_{kl} \cdot e^{j\theta_{kl}} \cdot \delta(t - T_l - \tau_{kl}), \quad (7.5)$$

gde su: β_{kl} , θ_{kl} - amplituda i faza k -tog zraka u l -tom klasteru, respektivno, T_l - vreme dolaska l -tog klastera, τ_{kl} - kašnjenje dolaska k -tog zraka u odnosu na prvi zrak l -tog klastera.


Na slikama 7.6 i 7.7 prikazane su spektralne gustine snaga izlaznog signala 64x64 FC-HBF mMIMO predajnika sa 2 RF grane za korisnika 1 i 2, respektivno. Prikazane su spektralne gustine snage izlaznog signala bez digitalne predistorzije i u slučaju korišćenja digitalne predistorzije primenom proširenog RVT-DNN2L DPD modela i klasičnog RVT-DNN2L DPD modela. Dobijene vrednosti za NMSE i EVM prikazane su u tabelama 7.3 i 7.4, za korisnika 1 i 2 respektivno.




a) I=18, II=9





b) I=32, II=15



Slika 7.6 – Spektralna gustina snage izlaznog signala 64x64 FC HBF mMIMO predajnika – korisnik 1: a) $I=18, II=9$, b) $I=32, II=15$, c) $I=48, II=21$.





Slika 7.7 – Spektralna gustina snage izlaznog signala 64×64 FC HBF mMIMO predajnika – korisnik 2: a) $I=18, II=9$, b) $I=32, II=15$, c) $I=48, II=21$.

Tabela 7.3 – Performanse proširenog i klasičnog RVTDDN2L DPD modela za 64x64 FC HBF mMIMO predajnik sa dva korisnika – korisnik 1.

Tip DPD	EVM [%]		NMSE [dB]	
	Arh 1	Arh 2	Arh 1	Arh 2
Bez DPD	17.32		-	
RVTDDN2L I=18, II=9	6.11	3.53	-24.27	-29.04
Proširen RVTDDN2L I=18, II=9	5.07	2.71	-25.89	-31.37
RVTDDN2L I=32, II=15	3.39	2.26	-29.39	-32.93
Proširen RVTDDN2L I=32, II=15	2.93	2.16	-30.66	-33.31
RVTDDN2L I=48, II=21	2.61	1.89	-31.68	-34.46
Proširen RVTDDN2L I=48, II=21	2.51	1.52	-32.03	-36.34

Tabela 7.4 – Performanse proširenog i klasičnog RVTDDN2L DPD modela za 64x64 FC HBF mMIMO predajnik sa dva korisnika – korisnik 2.

Tip DPD	EVM [%]		NMSE [dB]	
	Arh 1	Arh 2	Arh 1	Arh 2
Bez DPD	18.53		-	
RVTDDN2L I=18, II=9	6.41	3.59	-23.87	-28.88
Proširen RVTDDN2L I=18, II=9	5.41	3.35	-25.34	-29.48
RVTDDN2L I=32, II=15	3.67	2.29	-28.71	-32.81
Proširen RVTDDN2L I=32, II=15	3.17	2.23	-29.97	-33.03
RVTDDN2L I=48, II=21	2.81	1.96	-31.03	-34.17
Proširen RVTDDN2L I=48, II=21	2.66	1.69	-31.51	-35.42

Analizom dobijenih rezultata može se primetiti da se bolji rezultati postižu primenom proširenog RVTDDN2L modela u poređenju sa klasičnim RVTDDN2L modelom, što je bilo i očekivano. Ovo poboljšanje postignuto je uz neznatno povećanje kompleksnosti mreže. Takođe, može se primetiti, kao i u slučaju klasičnog RVTDDN2L DPD modela analiziranog u šestom poglavlju, da se bolji rezultati postižu primenom arhitekture 2 DPD modela realizovanog sa dve proširene RVTDDN2L mreže, u poređenju sa arhitekturom 1 DPD modela realizovanog primenom jedne proširene RVTDDN2L mreže. Kao što je već rečeno, primena dve neuralne mreže dodatno povećava kompleksnost DPD modela po pitanju broja koeficijenta i broja FLOP-ova, te je stoga potrebno razmotriti i analizirati performanse predloženih arhitektura u zavisnosti od kompleksnosti. Kompleksnost izabranih arhitektura DPD modela, za klasičan i proširen RVTDDN2L model, u zavisnosti od broja neurona po slojevima, prikazana je u tabeli 7.5.

Tabela 7.5 – Kompleksnost različitih arhitektura klasičnog i proširenog RVTDNN2L DPD modela.

RVTDNN2L	RVTDNN2L		Proširen RVTDNN2L	
	N_{coef}	FLOP	N_{coef}	FLOP
Arhitektura 1 I=18, II=9	301	945	373	1089
Arhitektura 2 I=18, II=9	562	1818	706	2106
Arhitektura 1 I=32, II=15	719	2041	847	2297
Arhitektura 2 I=32, II=15	1374	3962	1630	4474
Arhitektura 1 I=48, II=21	1357	3603	1549	3987
Arhitektura 2 I=48, II=21	2626	7038	3010	7806

Analizom dobijenih rezultata, prikazanih u tabelama 7.3 i 7.4, a uzimajući u obzir i složenost modela prikazanu u tabeli 7.5, može se zaključiti da se optimalni rezultati postižu primenom DPD arhitekture sa dve proširene RVTDNN2L mreže, sa 32 neurona u prvom skrivenom sloju i 15 neurona u drugom skrivenom sloju. Ukoliko je potrebno postići što bolje performanse DPD sistema, odnosno veću kompenzaciju nelinearne distorzije, koristiće se DPD arhitektura sa dve proširene RVTDNN2L mreže sa većim brojem skrivenih neurona, odnosno konfiguracija od 48 neurona u prvom skrivenom sloju i 21 neurona u drugom skrivenom sloju. Treba napomeniti da dodatno povećanje broja skrivenih neurona dovodi do povećanja kompleksnosti, koje nije linearno srazmerno smanjenju nelinearne distorzije, te stoga to nije i optimalno rešenje.

8. ZAKLJUČAK

Oblast telekomunikacija predstavlja veoma važnu infrastrukturnu granu i njen brz i intenzivan razvoj poslednjih godina predstavlja jedan od glavnih pokretača ekonomskog napretka modernog društva. Razvoj radio-komunikacija, kao jedne od značajnijih sfera telekomunikacija, a naročito razvoj mobilnog širokopojasnog pristupa postaje sve važniji u svakodnevnom životu. Savremeno društvo ima potrebu za permanentnim pristupom informacijama na bilo kom mestu i u bilo kom trenutku. Korisnici mobilnih širokopojasnih mreža već imaju mogućnost da putem pametnih telefona pretražuju Internet, šalju i primaju *e-mail*-ove, muzičke fajlove i video snimke gde god da se nalaze, ali njihovi zahtevi su da ova komunikacija bude što brža i što pouzdanija. Teži se kontinuiranom poboljšanju kvaliteta i sigurnosti života, otuda i potreba za povezivanjem različitih pametnih uređaja i senzora u domaćinstvima, automobilima, mašinama, ali i na ljudskom telu, putem mobilnih mreža. Stoga su pred mobilne mreže i sisteme novih generacija postavljeni visoki zahtevi i očekivanja, koja se mogu ispuniti samo uz efikasnu upotrebu spektra i energije.

Posmatrajući tendencije budućih pravaca razvoja mobilnih mreža i sistema, evidentna je potreba za upotrebom novih *massive Multiple Input Multiple Output* (mMIMO) tehnologija u kombinaciji sa hibridnim formiranjem i usmeravanjem snopa (*hybrid beamforming*), kao i primena širokopojasnih pojačavača koji predstavljaju glavne potrošače energije u mobilnim mrežama. Kako bi se postigla ušteda energije i ostvarila maksimalna energetska efikasnost, pojačavač se pobuđuje tako da radi u oblasti blizu zasićenja. Radom pojačavača u ovoj oblasti, odnosno u nelinearnom delu prenosne karakteristike, dolazi do pojave nelinearne distorzije signala, koja dovodi do degradacije kvaliteta prenosa signala i narušavanja performansi sistema. Ovaj problem se uspešno rešava primenom različitih tehnika linearizacije pojačavača. Među brojnim tehnikama linearizacije pojačavača koje se mogu sresti u literaturi, digitalna predistorzija (DPD) našla je najveću primenu.

Imajući u vidu sve navedene činjenice, digitalna predistorzija kod hibridnih *beamforming* mMIMO predajnika predstavlja značajnu i izazovnu oblast istraživanja. U naučno-stručnoj literaturi postoji veliki broj modela za digitalnu predistorziju u širokopojasnim sistemima. Ipak i pored značajnog broja predloženih DPD modela, ne postoji jedinstveno rešenje, i postoji rastuća potreba za razvijanjem novih, efikasnih i sofisticiranih DPD modela.

Istovremeno, oblast veštačkih neuralnih mreža doživela je veliku ekspanziju i našla primenu u svim oblastima modernog života. Neuralne mreže (NN) se koriste u rešavanju velikog broja inženjerskih problema, imaju visoku tačnost modelovanja i prilagodljivost, veoma dobro aproksimiraju nelinearne funkcije, i stoga se nameću kao efikasno i sofisticirano rešenje za razvoj različitih modela digitalne predistorzije. Izvestan broj istraživačkih radova bavi se primenom neuralnih mreža za linearizaciju pojačavača, ali ne i problematikom linearizacije pojačavača kod hibridnih *beamforming* mMIMO predajnika primenom neuralnih mreža. Stoga je cilj ove doktorske disertacije bio razvoj efikasnog modela digitalne predistorzije kod hibridnog *beamforming* mMIMO predajnika primenom neuralnih mreža. Kako je razvijanje sofisticiranog i efikasnog DPD modela primenom neuralnih mreža (NN DPD model) kompleksan problem, koji zahteva da se u obzir uzmu različiti elementi iz oblasti digitalne predistorzije i iz oblasti veštačkih neuralnih mreža, u okviru prve faze istraživačkog rada izvršeno je sveobuhvatno proučavanje naučno-stručne literature iz ove dve oblasti. Napravljen je uporedni pregled postojećih rešenja digitalne predistorzije kod mMIMO predajnika, uz kratak osvrt na njihove prednosti i moguće nedostatke pri primeni u širokopojasnim sistemima nove generacije.

U okviru ove doktorske disertacije analizirana je mogućnost primene neuralnih mreža za digitalnu predistorziju kod hibridnih *beamforming* mMIMO predajnika i predložena su dva efikasna NN DPD modela: *Real-Valued Time-Delay Neural Network with 2 hidden Layers* (RVTDNN2L) DPD model i proširen RVTDNN2L DPD model. Kako bi se pronašao optimalan model digitalne predistorzije kod hibridnih *beamforming* mMIMO predajnika, pored predložena dva NN DPD modela, analizirano je više različitih modela neuralnih mreža: *Deep Neural Network* (DNN), *Real-Valued Time-Delay Neural Network* (RVTDNN) i *Augmented Real-Valued Time-Delay Neural Network* (ARVDNN). Izvršeno je međusobno poređenje predloženih NN DPD modela, kako po pitanju efikasnosti linearizacije, tako i po pitanju kompleksnosti samog rešenja. Efikasnost različitih NN DPD modela je upoređena na osnovu vrednosti sledeća dva parametra: normalizovane srednje kvadratne greške (NMSE) i amplitude vektora greške (EVM). Kompleksnost analiziranih NN DPD modela upoređena je na osnovu broja koeficijenata potrebnih za konstrukciju modela i na osnovu broja FLOP-ova (*FLoating point Operations Per Second*), koji predstavlja meru računarske kompleksnosti, odnosno predstavlja meru za broj i tip korišćenih računarskih operacija.

Istraživanje u okviru ove doktorske disertacije zasnovano je na analizi digitalne predistorzije kod potpuno povezane (FC) arhitekture hibridnog *beamforming* 64x64 mMIMO predajnika, koja omogućava veću spektralnu efikasnost u poređenju sa drugim mogućim tipom arhitekture hibridnog *beamforming* mMIMO predajnika, takozvane delimično povezane (SA) arhitekture. Potpuno povezana arhitektura podrazumeva da je svaki antenski element povezan na svaki od P RF lanaca predajnika, i kao takva ima i veću kompleksnost u odnosu na delimično povezanu arhitekturu, kod koje je na jedan RF lanac povezan podskup od L antenskih elemenata. Analiziran je tzv. *direct-end feedback* DPD algoritam, kod koga se povratna informacija potrebna za algoritam digitalne predistorzije dovodi direktno sa kraja predaje, odnosno direktno sa izlaza svih antenskih elemenata. Predloženi NN DPD modeli implementirani su u programskom paketu *Matlab* (R2021a).

Kako bi rezultati simulacija i analize predloženih NN DPD modela bili što približniji situaciji kod realnog mMIMO predajnika, korišćen je NN model realnog dvostepenog pojačavača, modelovan na osnovu stvarnih izmerenih vrednosti pojačavača CFH 2162-P3 na centralnoj frekvenciji 2140 MHz, i ulaznog signala širine 20 MHz. Izvršena je verifikacija predloženih NN DPD modela, kako za sistem sa jednim korisnikom (SU), tako i za sistem sa više korisnika (MU), kod koga se signali koji se šalju ka svakom pojedinačnom korisniku formiraju na osnovu signala svih korisnika i kod koga je neophodno prilikom konstrukcije modela digitalnog predistortera uzeti u obzir podatke svih korisnika u sistemu. Za potrebe simulacija generisan je 64-QAM OFDM signal širine 20 MHz u programskom paketu *Matlab*.

Na osnovu sprovedenih simulacija u *Matlab*-u i detaljne analize dobijenih rezultata, izvršena je validacija smanjenja nelinearne distorzije kod SU i MU hibridnog *beamforming* mMIMO predajnika, primenom predloženih DPD modela: RVTDNN2L DPD i proširenog RVTDNN2L DPD. Analizom dobijenih rezultata, donet je zaključak da svi razmatrani NN DPD modeli daju bolje rezultate u pogledu smanjenja nelinearne distorzije u odnosu na postojeće polinomijalne modele. Pokazano je da predloženi RVTDNN2L DPD i proširen RVTDNN2L DPD model daju znatno bolje rezultate u odnosu na ostale razmatrane NN DPD modele slične kompleksnosti. Takođe je analiziran i uticaj broja RF grana, pri čemu je pokazano da se sa povećanjem broja RF grana povećava i nelinearna distorzija bez primene DPD, dok se primenom predloženog RVTDNN2L DPD modela sa povećanjem broja RF grana smanjuje nelinearna distorzija. Rezultati sprovedenih simulacija su pokazali da se predložen RVTDNN2L DPD model može efikasno primeniti za poboljšanje linearizacije pojačavača kod potpuno povezanog hibridnog *beamforming* mMIMO predajnika sa proizvoljnim brojem RF grana.

Ostvareni naučni doprinosi u okviru ove doktorske disertacije su sledeći:

- Predloženi su i optimizovani novi modeli digitalne predistorzije za kompenzaciju nelinearne distorzije kod hibridnog *beamforming* mMIMO predajnika primenom neuralnih mreža. Izvršena je implementacija predloženih modela u programskom paketu *Matlab* i validacija smanjenja nelinearne distorzije koju unose pojačavači kod hibridnog *beamforming* mMIMO predajnika.
- Predloženi su i optimizovani novi modeli digitalne predistorzije za kompenzaciju nelinearne distorzije kod hibridnog *beamforming* mMIMO predajnika sa više korisnika primenom neuralnih mreža. Izvršena je implementacija predloženih modela u programskom paketu *Matlab* i validacija smanjenja nelinearne distorzije koju unose pojačavači kod hibridnog *beamforming* mMIMO predajnika sa više korisnika.
- Izvršen je sistematičan i detaljan pregled postojeće literature iz oblasti digitalne predistorzije signala.
- Izvršen je sistematičan i detaljan pregled postojeće literature iz oblasti veštačkih neuralnih mreža.

Kao rezultat svih navedenih doprinosa, ova doktorska disertacija nudi kvalitativno unapređenje efikasnosti kompenzacije nelinearne distorzije kod predajnika u savremenim bežičnim sistemima, prvenstveno kod potpuno povezanog hibridnog *beamforming* mMIMO predajnika.

Rezultati dobijeni u okviru ove doktorske disertacije mogu naći široku primenu u kompenzaciji nelinearne distorzije signala u savremenim bežičnim sistemima, pri čemu se otvaraju višestruke mogućnosti za dalji istraživački rad. Jedan od mogućih pravaca daljeg istraživačkog rada jeste analiza i ispitivanje mogućnosti primene nekog drugog tipa neuralne mreže. Konvolucione neuralne mreže (*Convolutional Neural Network* – CNN) i rekurentne neuralne mreže (*Recurrent Neural Network* – RNN) su se pokazale posebno efikasnim u rešavanju različitih inženjerskih problema, te se prirodno nameće pitanje mogućnosti njihove primene i u oblasti digitalne predistorzije signala kod mMIMO predajnika. Iako su se rekurentne neuralne mreže pokazale veoma dobre u rešavanju problema obrade prirodnog govora i obrade različitih vremenskih nizova, postavlja se pitanje koliko bi bile efikasne za rešavanje problema digitalne predistorzije zbog složenijeg algoritma treninga usled postojanja povratnih putanja u odnosu na *feedforward* neuralne mreže kod kojih je tok podataka u jednom smeru. Ovo zahteva dodatan istraživački rad i ispitivanje opravdanosti povećanja kompleksnosti sistema u cilju ostvarivanja dobitka po pitanju performansi, odnosno poboljšanja nelinearne distorzije. Sa druge strane, konvolucione neuralne mreže se uglavnom koriste za rešavanje problema klasifikacije i obrade slike. Stoga je potrebno pronaći način kako prilagoditi izlazni sloj konvolucionih neuralnih mreža, tako da se dobije kontinualni signal umesto diskretne odluke. Drugi problem sa kojim je potrebno suočiti se pri primeni CNN mreža u digitalnoj predistorziji jeste problem strukture ulaznih podataka u mrežu. Naime, ulazni podaci u konvolucione mreže su slike, dok su ulazni podaci za potrebe digitalne predistorzije vremenski nizovi. Stoga je potrebno pažljivo izabrati algoritam mapiranja ulaznih podataka u podatke pogodne za konvolucionu obradu, kako ne bi došlo do gubitka podataka koji bi doveli do grešaka u predikciji izlaznog signala.

Još jedan od mogućih pravaca daljeg istraživačkog rada, koji se nameće posmatranjem tipa povratnih informacija koje se koriste za kreiranje modela predistortera, jeste ispitivanje digitalne predistorzije kod tzv. *Over-The-Air* (OTA) DPD modela. Ovaj model je hardverski manje kompleksan iz razloga što ne uzima povratne signale direktno sa pojačavača, čime se eliminiše potreba za korišćenjem dodatnih komponenti poput kaplera i modula za kofaziranje i kombinovanje. Kao što je istaknuto u ovoj doktorskoj disertaciji nedostatak OTA DPD modela jeste

postavljanje dodatne antene u dalekom polju koja služi za posmatranje i prikupljanje povratnih informacija za digitalnu predistorziju, te stoga ovaj model nije analiziran u ovom trenutku. I pored toga u naučno-stručnoj literaturi postoji izvestan broj radova koji razmatraju polinomijalne OTA DPD modele kod mMIMO predajnika. Iz tog razloga, budući naučno-istraživački rad bi išao i u pravcu ispitivanja mogućnosti primene predloženih NN DPD modela na OTA DPD arhitekturu. Takođe, od značaja bi bilo i uporediti rezultate koji bi se dobili za oba tipa povratnih informacija (*direct-end feedback* i *OTA*), sa stanovišta postignute kompenzacije nelinearne distorzije, kao i sa stanovišta zahtevane kompleksnosti modela kako bi se postigla zadovoljavajuća kompenzacija nelinearne distorzije.

Literatura

- [1] “Ericsson Mobility Report” Ericsson, Stockholm, Sweden. EAB-22:010742 Uen Rev D, November 2022. [Online]. Available: <https://www.ericsson.com/4ae28d/assets/local/reports-papers/mobility-report/documents/2022/ericsson-mobility-report-november-2022.pdf>
- [2] Harri Holma, Antti Toskala, Takehiro Nakamura, „5G Technology: 3GPP New Radio,“ JohnWiley & Sons Ltd. 2020.
- [3] 3GPP Technical Report 21.915. 3rd Generation Partnership Project; Technical Specification Group Services and System Aspects; Release 15 Description; Summary of Rel-15 Work Items. v15.0.0 (Release 15); ETSI: Sophia Antipolis, France, 2019.
- [4] IEEE 5G Initiative Roadmap Committee Members, “IEEE 5G and Beyond Roadmap Whitepaper,” October 2017. [Online]. Available: <https://futurenetworks.ieee.org/images/files/pdf/ieee-5g-roadmap-white-paper.pdf>
- [5] Erik Dahlman, Stefan Parkvall and Johan Sköld, „4G LTE-Advanced Pro and The Road to 5G,“ Elsevier Ltd. 2016. ISBN: 978-0-12-804575-6, <https://doi.org/10.1016/C2015-0-01834-2>
- [6] Emil Björnson; Jakob Hoydis; Luca Sanguinetti, „Massive MIMO Networks: Spectral, Energy, and Hardware Efficiency,“ Now Publishers Inc, 2017. ISBN: 978-1680839852
- [7] Larsson, E.G.; Edfors, O.; Tufvesson, F.; Marzetta, T.L. „Massive MIMO for next generation wireless systems,“ IEEE Commun. Mag. 2014, 52, 186–195
- [8] A. Singh, and S. Joshi, " A Survey on Hybrid Beamforming in MmWave Massive MIMO System," in Journal of Scientific Research, vol. 65, no. 1, pp. 201-213, January 2021.
- [9] A. F. Molisch et al., "Hybrid Beamforming for Massive MIMO: A Survey," in IEEE Communications Magazine, vol. 55, no. 9, pp. 134-141, September 2017.
- [10] 5GPPP, "5G Vision: The 5G Infrastructure Public Private Partnership - The next generation of communication networks and services", February 2015.
- [11] GSMA, “2019 Mobile Industry SDG Impact Report,” Tech. Rep., Sep. 2019. [Online]. Available: <https://www.gsma.com/betterfuture/wp-content/uploads/2019/10/2019-09-24-a60d6541465e86561f37f0f77ebce0f7-1.pdf>
- [12] D. López-Pérez et al., "A Survey on 5G Radio Access Network Energy Efficiency: Massive MIMO, Lean Carrier Design, Sleep Modes, and Machine Learning," in IEEE Communications Surveys & Tutorials, vol. 24, no. 1, pp. 653-697, Firstquarter 2022, doi: 10.1109/COMST.2022.3142532
- [13] Huawei Technologies Co., Ltd., “Green 5G: Building a sustainable world,” Tech. Rep., Aug. 2020. [Online]. Available: https://www-file.huawei.com/-/media/corp2020/pdf/public-policy/green_5g_building_a_sustainable_world_v1.pdf?la=en

- [14] L. Guan and A. Zhu, "Green Communications: Digital Predistortion for Wideband RF Power Amplifiers," in *IEEE Microwave Magazine*, vol. 15, no. 7, pp. 84-99, November-December 2014, DOI: 10.1109/MMM.2014.2356037
- [15] M. Čabarkapa, N. Nešković, M. Prokin, Đ. Budimir, „Modelovanje ponašanja pojačavača snage i digitalna predistorzija za 4G bežične komunikacijske sisteme”, 60. Konferencija za elektroniku, telekomunikacije, računarstvo, automatiku i nuklearnu tehniku ETRAN 2016.
- [16] D. Bondar, „Advanced Digital Predistortion of Power Amplifiers for Mobile and Wireless Communications”, PhD Thesis, University of Westminster, London, UK, 2009.
- [17] L. Liu, W. Chen, L. Ma and H. Sun, "Single-PA-feedback digital predistortion for beamforming MIMO transmitter," 2016 IEEE International Conference on Microwave and Millimeter Wave Technology (ICMMT), June 2016, pp. 573-575.
- [18] M. Abdelaziz, L. Anttila, A. Brihuega, F. Tufvesson and M. Valkama, "Digital Predistortion for Hybrid MIMO Transmitters," in *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 3, pp. 445-454, June 2018.
- [19] A. Brihuega, L. Anttila, M. Abdelaziz, T. Eriksson, F. Tufvesson and M. Valkama, "Digital Predistortion for Multiuser Hybrid MIMO at mmWaves," in *IEEE Transactions on Signal Processing*, vol. 68, pp. 3603-3618, May 2020.
- [20] X. Liu et al., "Beam-Oriented Digital Predistortion for 5G Massive MIMO Hybrid Beamforming Transmitters," in *IEEE Transactions on Microwave Theory and Techniques*, vol. 66, no. 7, pp. 3419-3432, July 2018.
- [21] X. Liu, W. Chen, L. Chen, F. M. Ghannouchi and Z. Feng, "Power Scalable Beam-Oriented Digital Predistortion for Compact Hybrid Massive MIMO Transmitters," in *IEEE Transactions on Circuits and Systems I: Regular Papers*, vol. 67, no. 12, pp. 4994-5006, Dec. 2020.
- [22] W. Qiao, G. Li, Y. Zhang, H. Li and F. Liu, "A Band-limited Digital Predistortion Method for Hybrid MIMO Transmitters," 2019 International Conference on Microwave and Millimeter Wave Technology (ICMMT), May 2019.
- [23] X. Liu, W. Chen, J. Chu, F. M. Ghannouchi and Z. Feng, "Multi-Stream Spatial Digital Predistortion for Fully-Connected Hybrid Beamforming Massive MIMO Transmitters," in *IEEE Transactions on Circuits and Systems I: Regular Papers*, vol. 68, no. 7, pp. 2998-3011, July 2021.
- [24] R. Hongyo, Y. Egashira, T. M. Hone and K. Yamaguchi, "Deep Neural Network-Based Digital Predistorter for Doherty Power Amplifiers," in *IEEE Microwave and Wireless Components Letters*, vol. 29, no. 2, pp. 146-148, Februar 2019, DOI: 10.1109/LMWC.2018.2888955.
- [25] D. Wang, M. Aziz, M. Helaoui and F. M. Ghannouchi, "Augmented Real-Valued Time-Delay Neural Network for Compensation of Distortions and Impairments in Wireless Transmitters," in *IEEE Transactions on Neural Networks and Learning Systems*, vol. 30, no. 1, pp. 242-254, Jan. 2019, DOI: 10.1109/TNNLS.2018.2838039.
- [26] Z. Liu, X. Hu, T. Liu, X. Li, W. Wang and F. M. Ghannouchi, "Attention-Based Deep Neural Network Behavioral Model for Wideband Wireless Power Amplifiers," in *IEEE Microwave and Wireless Components Letters*, vol. 30, no. 1, pp. 82-85, Jan. 2020, doi: 10.1109/LMWC.2019.2952763.

- [27] X. Hu, Z. Liu, W. Wang, M. Helaoui and F. M. Ghannouchi, "Low-Feedback Sampling Rate Digital Predistortion Using Deep Neural Network for Wideband Wireless Transmitters," in IEEE Transactions on Communications, vol. 68, no. 4, pp. 2621-2633, April 2020, doi: 10.1109/TCOMM.2020.2966718.
- [28] P. Jaraut et al., "Augmented Convolutional Neural Network for Behavioral Modeling and Digital Predistortion of Concurrent Multiband Power Amplifiers," in IEEE Transactions on Microwave Theory and Techniques, vol. 69, no. 9, pp. 4142-4156, Sept. 2021, doi: 10.1109/TMTT.2021.3075689.
- [29] X. Hu et al., "Convolutional Neural Network for Behavioral Modeling and Predistortion of Wideband Power Amplifiers," in IEEE Transactions on Neural Networks and Learning Systems, vol. 33, no. 8, pp. 3923-3937, Aug. 2022, doi: 10.1109/TNNLS.2021.3054867.
- [30] D. Phartiyal and M. Rawat, "LSTM-Deep Neural Networks based Predistortion Linearizer for High Power Amplifiers," 2019 National Conference on Communications (NCC), 2019, pp. 1-5, DOI: 10.1109/NCC.2019.8732178.
- [31] **T. Muškatirović-Zekić**, N. Nešković, Dj. Budimir „Efficient Neural Network DPD Architecture for Hybrid Beamforming mMIMO“, Electronics, 12 (3), 597, January 2023, <https://doi.org/10.3390/electronics12030597>, ISSN: 2079-9292.
- [32] A. Mohammadi and F. M. Ghannouchi, „RF Transceiver Design for MIMO Wireless Communications“, New York: Springer, 2012.
- [33] F. Ghannouchi, “ Behavioral Modeling and Predistortion of Wideband Wireless Transmitters” John Wiley & Sons, 2015.
- [34] M. Cabarkapa, „Digital Predistortion of RF Amplifiers Using Baseband Injection for Mobile Broadband Communications”, PhD Thesis, University of Westminster, London, UK, 2014.
- [35] M. Bozic, „Joint compensation of I/Q impairments and PA nonlinearity in mobile broadband wireless transmitters”, PhD Thesis, University of Westminster, London, UK, 2016.
- [36] X. Feng, „Efficient baseband digital predistortion techniques for linearizing power amplifier by taking into account nonlinear memory effect“, PhD Thesis, Universite de Nantes, France, 2015.
- [37] A. S. Tehrani, „Behavioral modeling of wireless transmitters for distortion mitigation“, PhD Thesis, Chalmers University of technology, Gothenburg, Sweden 2012.
- [38] J. Chani-Cahuana, „Digital Predistortion for the Linearization of Power Amplifiers“, Thesis for The Degree of Licentiate of Engineering, University of Waterloo, Canada, 2015.
- [39] F. Mkadem, „Behavioural Modeling and Linearization of RF Power Amplifier using Artificial Neural Networks“, Master Thesis, University of Waterloo, Canada, 2010.
- [40] F. Mkadem, „Behavioral Modeling and Digital Predistortion of Wide- and Multi-Band Transmitter Systems“, PhD Thesis, University of Waterloo, Canada, 2014.
- [41] F. M. Ghannouchi and O. Hammi, "Behavioral modeling and predistortion," in IEEE Microwave Magazine, vol. 10, no. 7, pp. 52-64, December 2009, doi: 10.1109/MMM.2009.934516.

- [42] A. Zhu, J. Pedro, and T. Cunha, "Pruning the Volterra series for behavioral modeling of power amplifiers using physical knowledge," *IEEE Trans. Microw. Theory Tech.*, vol. 55, no. 5, pp. 813–821, May 2007.
- [43] A. Zhu, J. C. Pedro, and T. J. Brazil, "Dynamic deviation reduction-based behavioral modeling of RF power amplifiers," *IEEE Trans. Microw. Theory Tech.*, vol. 54, no. 12, pp. 4323–4332, December 2006.
- [44] R. Raich, H. Qian, and G. T. Zhou, "Orthogonal polynomials for power amplifier modeling and predistorter design," *IEEE Trans. Veh. Technol.*, vol. 53, pp. 1468–1479, September 2004.
- [45] D. Morgan, Z. Ma, J. Kim, M. Zierdt, and J. Pastalan, "A generalized memory polynomial model for digital predistortion of RF power amplifiers," *IEEE Trans. Signal Process.*, vol. 54, pp. 3852–3860, October 2006.
- [46] A.S. Tehrani, C. Haiying, S. Afsardoost, T. Eriksson, M. Isaksson and C. Fager, "A comparative analysis of the complexity/accuracy tradeoff in power amplifier behavioral models," *IEEE Trans. Microw. Theory Tech.*, vol. 58, no. 6, pp. 1510-1520, June 2010.
- [47] C. Yu , Q. Lu, H. Sun, X. Wu and X.-W. Zhu, " Digital Predistortion of Ultra-Broadband mmWave Power Amplifiers with Limited Tx/Feedback Loop/Baseband Bandwidth", *Wireless Communications and Mobile Computing*, vol. 2018, March 2018.
- [48] C. Yu, L. Guan and A. Zhu, "Band-Limited Volterra Series-Based Behavioral Modeling of RF Power Amplifiers", *IEEE MTT-S International Microwave Symposium, IMS '12*, pp. 1–3, Canada, June 2012.
- [49] C. Yu, L. Guan, E. Zhu and A. Zhu, "Band-Limited Volterra Series-Based Digital Predistortion for Wideband RF Power Amplifiers", *IEEE Transactions on Microwave Theory and Techniques*, vol. 60, no. 12, pp. 4198–4208, December 2012.
- [50] L. Guan, C. Yu and A. Zhu, "Bandwidth-constrained Least Squares-based Model Extraction for Band-limited Digital Predistortion of RF Power Amplifiers" Conference Paper, in *Workshop INMMiC*, Dublin, Ireland, September 2012.
- [51] G. Yang, F. Liu, C. Zhao, Z. Wang, L. Li and H. Wang, "Frequency Domain Data Based Model Extraction for Band-Limited Digital Predistortion of Wideband RF Power Amplifiers" *International Journal of RF and Microwave Computer-Aided Engineering*, pp. 412–420, August 2013.
- [52] L. Ding, F. Mujica and Z. Yang, "Digital Predistortion using Direct Learning with Reduced Bandwidth Feedback," in *Proc. IEEE Int. Microw. Symp.*, pp. 1–3, Jun. 2013.
- [53] Y. Liu, W. Pan, S. Shao and Y. Tang, "A New Digital Predistortion for Wideband Power Amplifiers With Constrained Feedback Bandwidth", *IEEE Microwave And Wireless Components Letters*, vol. 23, no. 12, pp. 683–685, December 2013.
- [54] Y. Liu, W. Pan, S. Shao, and Y. Tang, "A New Digital Predistortion Using Indirect Learning with Constrained Feedback Bandwidth for Wideband Power Amplifiers", *IEEE MTT-S Int. Microw. Symp. Dig.*, pp. 1–3, Jun. 2014.

- [55] Y. Ma, Y. Yamao, Y. Akaiwa and K. Ishibashi, "Wideband Digital Predistortion Using Spectral Extrapolation of Band-Limited Feedback Signal" IEEE Transactions on Circuits and Systems, vol. 61, no. 7, pp. 2088–2097, 2014.
- [56] W. Tao, H. Wang, C. Zhou, G. Li and F. Liu, "A Random Demodulation Based Reduced Sampling Rate Method for Wideband Digital Predistortion," in Proceedings of the Asia-Pacific Microwave Conference, APMC '15, China, December 2015.
- [57] Z. Wang, W. Chen, G. Su, F. M. Ghannouchi, Z. Feng and Y. Liu, "Low Feedback Sampling Rate Digital Predistortion for Wideband Wireless Transmitters," IEEE Transactions on Microwave Theory and Techniques, vol. 64, no. 11, pp. 3528–3539, November 2016.
- [58] C. Yu, Y. Guo, and A. Zhu, "A Band-limited 2-D Digital Predistorter for Concurrent Dual-band RF Transmitters", IEEE International Wireless Symposium (IWS), March 2014.
- [59] S. Deb, M. Tanio, S. Hori, N. Tawa, Y. Wada, and K. Kunihiro, "Band-limited Digital Predistortion with Band-switching Feedback Architecture for 5G mmWave Power Amplifiers", 48th European Microwave Conference (EuMC), September 2018.
- [60] W. Qiao, G. Li, Y. Zhang, H. Li, and F. Liu, "A Band-limited Digital Predistortion Method for Hybrid MIMO Transmitters", International Conference on Microwave and Millimeter Wave Technology (ICMMT), May 2019.
- [61] C. Yu, Q. Lu, H. Yin, J. Cai, J. Chen, X.-W. Zhu, and W. Hong, "Linear-Decomposition Digital Predistortion of Power Amplifiers for 5G Ultrabroadband Applications", IEEE Transactions on Microwave Theory and Techniques, vol. 68, no. 7, pp. 2833 - 2844, July 2020.
- [62] T. Muškatirović-Zekić, M. Čabarkapa, N. Nešković, Đ. Budimir. „Pregled postojećih DPD modela sa ograničenom širinom propusnog opsega“, Zbornik radova - 65. Konferencija za elektroniku, telekomunikacije, računarstvo, automatiku i nuklearnu tehniku ETRAN 2021, pp. 604-609, September 2021, ISBN 978-86-7466-894-8
- [63] M. Božić, M. Čabarkapa, N. Nešković, „Kompenzacija nelinearne distorzije u MIMO OFDM bežičnim komunikacionim sistemima“, 19th Telecommunications Forum (TELFOR) 2011, pp. 425-428, November 2011, ISBN 978-1-4577-1500-6/11.
- [64] T. Bovan, M. Čabarkapa, N. Nešković, M. Prokin, Đ. Budimir, „Analiza neželjenih efekata u multi-frekvencijskim MIMO predajnicima“, INFOTEH-JAHORINA Vol. 16, pp. 165-168, March 2017.
- [65] T. Bovan, M. Čabarkapa, N. Nešković, A. Nešković, Đ. Budimir, „Analiza neželjenih efekata u MIMO predajnicima sa više antenna“, 25th Telecommunications Forum (TELFOR) 2017, November 2017, ISBN 978-1-5386-3073-0/17.
- [66] H. Nosrati, „Adaptive MIMO Arrays: Antenna Selection, Combination and Sharing“, PhD Thesis, The University of New South Wales, Sydney, Australia, 2019.
- [67] P. Taghikhani, „Active Transmitter Antenna Array Modeling for MIMO Applications“, Thesis for The Degree of Licentiate of Engineering, Chalmers University of Technology, Göteborg, Sweden 2020.
- [68] M. Jordão, R. Caldeirinha, A.S.R. Oliveira, N.B. Carvalho, „A Survey on Over-The-Air Linearization Methods for MIMO Systems“, Energies 2021, <https://doi.org/10.3390/en14082225>

- [69] M. Dukić, „Principi telekomunikacija“, Akademska Misao, 2014, ISBN: 978-86-7466-504-6
- [70] **T. Muškatirović-Zekić**, M. Čabarkapa, N. Nešković, Đ. Budimir, „Kompenzacija nelinearne distorzije kod *hybrid beamforming* MIMO predajnika“, 21st International Symposium INFOTEH-JAHORINA, pp. 72-76, March 2022.
- [71] “Introduction to Hybrid Beamforming” The MathWorks, Inc. [Online]. Available: <https://www.mathworks.com/help/phased/ug/introduction-to-hybrid-beamforming.html>
- [72] O. El Ayach et al., “Spatially Sparse Precoding in Millimeter Wave MIMO Systems,” IEEE Trans. Wireless Commun., vol. 13, no. 3, pp. 1499-1513, March 2014.
- [73] X. Zhang, A. Molisch, and S.-Y. Kung, “Variable-Phase-Shift Based RF-Baseband Codesign for MIMO Antenna Selection,” IEEE Trans. Signal Processing, vol. 53, no. 11, pp. 4091-4103, November 2005.
- [74] A. Adhikary et al., “Joint Spatial Division and Multiplexing - The Large-Scale Array Regime,” IEEE Trans. Info. Theory, vol. 59, no. 10, pp. 6441-6463, October 2013.
- [75] Z. Li, S. Han, and A. F. Molisch, “Hybrid Beamforming Design for Millimeter-Wave Multi-User Massive MIMO Downlink,” IEEE ICC '16, Kuala Lumpur, Malaysia, May 2016.
- [76] Z. Wang, M. Li, Q. Liu and A. L. Swindlehurst, "Hybrid Precoder and Combiner Design With Low-Resolution Phase Shifters in mmWave MIMO Systems," in IEEE Journal of Selected Topics in Signal Processing, vol. 12, no. 2, pp. 256-269, May 2018, doi: 10.1109/JSTSP.2018.2819129.
- [77] A. Koc and T. Le-Ngoc, "Full-Duplex mmWave Massive MIMO Systems: A Joint Hybrid Precoding/Combining and Self-Interference Cancellation Design," in IEEE Open Journal of the Communications Society, vol. 2, pp. 754-774, 2021, March 2021, doi: 10.1109/OJCOMS.2021.3069672.
- [78] S. Huang, Y. Ye and M. Xiao, "Learning-Based Hybrid Beamforming Design for Full-Duplex Millimeter Wave Systems," in IEEE Transactions on Cognitive Communications and Networking, vol. 7, no. 1, pp. 120-132, March 2021, doi: 10.1109/TCCN.2020.3019604.
- [79] J. Du, W. Xu, C. Zhao and L. Vandendorpe, "Hybrid Beamforming Design for Multiuser Massive MIMO-OFDM Systems," 2018 15th International Symposium on Wireless Communication Systems (ISWCS), Lisbon, Portugal, October 2018, pp. 1-6, doi: 10.1109/ISWCS.2018.8491217.
- [80] X. Yu, J. Shen, J. Zhang, and K. B. Letaief, “Alternating minimization algorithms for hybrid precoding in millimeter wave MIMO systems,” IEEE J. Sel. Topics Signal Process., vol. 10, no. 3, pp. 485-500, April 2016
- [81] T. Lin, J. Cong, Y. Zhu, J. Zhang and K. Ben Letaief, "Hybrid Beamforming for Millimeter Wave Systems Using the MMSE Criterion," in IEEE Transactions on Communications, vol. 67, no. 5, pp. 3693-3708, May 2019, doi: 10.1109/TCOMM.2019.2893632.
- [82] D. H. N. Nguyen, L. B. Le, T. Le-Ngoc and R. W. Heath, "Hybrid MMSE Precoding and Combining Designs for mmWave Multiuser Systems," in IEEE Access, vol. 5, pp. 19167-19181, 2017, doi: 10.1109/ACCESS.2017.2754979.

- [83] P. Almers, E. Bonek, A. Burr, et al. "Survey of Channel and Radio Propagation Models for Wireless MIMO Systems." *J Wireless Com Network*, February 2007, <https://doi.org/10.1155/2007/19070>
- [84] A. L. Imoize, A. E. Ibhaze, A. A. Atayero, K. V. N. Kavitha, "Standard Propagation Channel Models for MIMO Communication Systems", *Wireless Communications and Mobile Computing*, vol. 2021, Article ID 8838792, 36 pages, February 2021, <https://doi.org/10.1155/2021/8838792>
- [85] W. Yamada, N. Kita, T. Sugiyama, "Ray-tracing-based Technique for Reducing Computational Complexity of MIMO Propagation Channel Estimation", *NTT Technical Review*, February 2011
- [86] M. Amro, A. Landolsi, S. Zummo, M. Grieger, M. Danneberg and G. Fettweis, "Ray-tracing wireless channel modeling and verification in Coordinated Multi-Point systems," *12th International Symposium on Modeling and Optimization in Mobile, Ad Hoc, and Wireless Networks (WiOpt)*, Hammamet, Tunisia, pp. 16-21, May 2014, doi: 10.1109/WIOPT.2014.6850273.
- [87] Da-Shan Shiu, G. J. Foschini, M. J. Gans and J. M. Kahn, "Fading correlation and its effect on the capacity of multielement antenna systems," in *IEEE Transactions on Communications*, vol. 48, no. 3, pp. 502-513, March 2000, doi: 10.1109/26.837052.
- [88] A. Abdi and M. Kaveh, "A space-time correlation model for multielement antenna systems in mobile fading channels," in *IEEE Journal on Selected Areas in Communications*, vol. 20, no. 3, pp. 550-560, April 2002, doi: 10.1109/49.995514.
- [89] M. Patzold and J. A. Hogstad, "A space-time channel simulator for MIMO channels based on the geometrical one-ring scattering model," *IEEE 60th Vehicular Technology Conference, VTC2004-Fall*, Los Angeles, CA, USA, pp. 144-149 Vol. 1, September 2004, doi: 10.1109/VETECS.2004.1399949.
- [90] M. Zhang, P. J. Smith and M. Shafi, "An Extended One-Ring MIMO Channel Model," in *IEEE Transactions on Wireless Communications*, vol. 6, no. 8, pp. 2759-2764, August 2007, doi: 10.1109/TWC.2007.05659.
- [91] Y. Ma and M. Patzold, "A Wideband One-Ring MIMO Channel Model Under Non-Isotropic Scattering Conditions," *VTC Spring 2008 - IEEE Vehicular Technology Conference, Marina Bay, Singapore*, pp. 424-429, May 2008, doi: 10.1109/VETECS.2008.100
- [92] A. A. M. Saleh and R. Valenzuela, "A Statistical Model for Indoor Multipath Propagation," in *IEEE Journal on Selected Areas in Communications*, vol. 5, no. 2, pp. 128-137, February 1987, doi: 10.1109/JSAC.1987.1146527.
- [93] F. Grejták and A. Prokes, "UWB - Ultra Wideband Characteristics and the Saleh-Valenzuela Modeling," *Acta Electrotechnica et Informatica; Kosice* Vol. 13, Iss. 2, pp. 32-38., 2013 DOI:10.2478/aei-2013-0026.
- [94] Y.S. Cho, J. Kim, W.Y. Yang, C.G. Kang, „MIMO-OFDM Wireless Communications with MATLAB,“ John Wiley & Sons (Asia) Pte Ltd.: Singapore, 2010; ISBN: 9780470825617
- [95] M. K. Çolakoğlu and M. Şafak, „On the MIMO Channel Capacity Predicted by Kronecker and Müller Models“, *Wireless Pers Commun* 47, 91–100, October 2008, <https://doi.org/10.1007/s11277-007-9393-x>.

- [96] C. Oestges, "Validity of the Kronecker Model for MIMO Correlated Channels," 2006 IEEE 63rd Vehicular Technology Conference, Melbourne, VIC, Australia, pp. 2818-2822, May 2006, doi: 10.1109/VETECS.2006.1683382.
- [97] S. Wu, C. -X. Wang, E. -H. M. Aggoune and M. M. Alwakeel, "A novel Kronecker-based stochastic model for massive MIMO channels," 2015 IEEE/CIC International Conference on Communications in China (ICCC), Shenzhen, China, pp. 1-6, November 2015, doi: 10.1109/ICCChina.2015.7448642.
- [98] Z. A. Khan, E. Zenteno, P. Händel and M. Isaksson, "Digital Predistortion for Joint Mitigation of I/Q Imbalance and MIMO Power Amplifier Distortion," in IEEE Transactions on Microwave Theory and Techniques, vol. 65, no. 1, pp. 322-333, January 2017, doi: 10.1109/TMTT.2016.2614933.
- [99] S. Amin, P.N. Landin, P. Händel, D. Rönnow, "Behavioral Modeling and Linearization of Crosstalk and Memory Effects in RF MIMO Transmitters". IEEE Transactions on Microwave Theory and Techniques, 62, 810–823, March 2014.
- [100] P. Jaraut, M. Rawat and F. M. Ghannouchi, "Composite Neural Network Digital Predistortion Model for Joint Mitigation of Crosstalk, I/Q Imbalance, Nonlinearity in MIMO Transmitters," in IEEE Transactions on Microwave Theory and Techniques, vol. 66, no. 11, pp. 5011-5020, November 2018, doi: 10.1109/TMTT.2018.2869602.
- [101] Y. Li, CF. Cheang, PI. Mak and RP. Martins, „Joint-digital-predistortion for wireless transmitter’s I/Q imbalance and PA nonlinearities using an asymmetrical complexity-reduced Volterra series model“, Analog Integr Circ Sig Process 87, 35–47 (2016), March 2016, <https://doi.org/10.1007/s10470-016-0724-2>
- [102] Y. Wu, U. Gustavsson, A. G. I. Amat and H. Wymeersch, "Low Complexity Joint Impairment Mitigation of I/Q Modulator and PA Using Neural Networks," in IEEE Journal on Selected Areas in Communications, vol. 40, no. 1, pp. 54-64, January 2022, doi: 10.1109/JSAC.2021.3126024.
- [103] **T. Muškatirović-Zekić**, M. Čabarkapa, N. Nešković and D. Budimir, "An Overview of Digital Predistortion Solutions for Hybrid Beamforming MIMO Transmitters," 2021 29th Telecommunications Forum (TELFOR), Belgrade, Serbia, pp. 1-4, November 2021, doi: 10.1109/TELFOR52709.2021.9653422.
- [104] X. Wang, C. Yu, Y. Li, W. Hong and A. Zhu, "Real-Time Single Channel Over-the-Air Data Acquisition for Digital Predistortion of 5G Massive MIMO Wireless Transmitters," 2019 IEEE MTT-S International Wireless Symposium (IWS), Guangzhou, China, 2019, pp. 1-3, doi: 10.1109/IEEE-IWS.2019.8804102.
- [105] X. Wang, Y. Li, C. Yu, W. Hong and A. Zhu, "Digital Predistortion of 5G Massive MIMO Wireless Transmitters Based on Indirect Identification of Power Amplifier Behavior With OTA Tests," in IEEE Transactions on Microwave Theory and Techniques, vol. 68, no. 1, pp. 316-328, Jan. 2020, doi: 10.1109/TMTT.2019.2944828.
- [106] M. Abdelaziz, L. Anttila, and M. Valkama, "Reduced-complexity digital predistortion for massive MIMO," in 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pp. 6478–6482, March 2017

- [107] M. Abdelaziz, L. Anttila, A. Kiayani, and M. Valkama, "Decorrelation-Based Concurrent Digital Predistortion With a Single Feedback Path," *IEEE Transactions on Microwave Theory and Techniques*, vol. PP, no. 99, pp. 1–14, June 2017
- [108] S. Haykin, „Neural Networks: A Comprehensive Foundation“, Prentice-Hall, New Jersey, January 1998, ISBN: 978-0132733502
- [109] W.S. McCulloch, W. Pitts, "A logical calculus of the ideas immanent in nervous activity", *Bulletin of Mathematical Biophysics* 5, pp. 115-133, 1943
- [110] D. O. Hebb, "The Organization of Behavior“, New York: Wiley, 1949, DOI: 10.1016/s0361-9230(99)00182-3
- [111] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain" *Psychological review* 65 6: 386-408, 1958
- [112] B. Widrow and M. E. Hoff, "Adaptive Switching Circuits," 1960 IRE WESCON Convention Record, pp. 96-104, 1960
- [113] T. Kohonen, "Correlation Matrix Memories," in *IEEE Transactions on Computers*, vol. C-21, no. 4, pp. 353-359, April 1972, doi: 10.1109/TC.1972.5008975.
- [114] T. Kohonen, "Self-Organization and Associative Memory", 3rd Edition, Springer Berlin, Heidelberg, 1989, eBook ISBN: 978-3-642-88163-3
- [115] S. Grossberg, "Adaptive pattern classification and universal recoding: I. Parallel development and coding of neural feature detectors," *Biological Cybernetics*, Vol. 23, pp. 121–134, 1976.
- [116] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proceedings of the National Academy of Sciences*, Vol. 79, pp. 2554–2558, 1982.
- [117] J. J. Hopfield, "Neurons with graded response have collective computational properties like those of two-state neurons," *Proceedings of the National Academy of Sciences*, vol. 81, pp. 3088–3092, 1984.
- [118] D. E. Rumelhart and J. L. McClelland, „Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1: Foundations“, Cambridge, MA: MIT Press, 1986.
- [119] M.T. Hagan, H.B. Demuth, M.H. Beale, O. De Jesús, „Neural Network Design“, Martin Hagan, September 2014, ISBN: 978-0971732117
- [120] O.I. Abiodun, A. Jantan, A.E. Omolara, K.V. Dada, N.A. Mohamed, H.Arshad, " State-of-the-art in artificial neural network applications: A survey," in *Heliyon*, Volume 4, Issue 11, November 2018, <https://doi.org/10.1016/j.heliyon.2018.e00938>.
- [121] S.A. Nabavi, A. Aslani, M.A. Zaidan, M. Zandi, S. Mohammadi and N.H. Motlagh, "Machine Learning Modeling for Energy Consumption of Residential and Commercial Sectors," in *Energies* 2020, 13(19), 5171, October 2020, <https://doi.org/10.3390/en13195171>.
- [122] M. T. Hagan and M. B. Menhaj, "Training feedforward networks with the Marquardt algorithm," in *IEEE Transactions on Neural Networks*, vol. 5, no. 6, pp. 989-993, November 1994, doi: 10.1109/72.329697.

- [123] M. F. Møller, "A scaled conjugate gradient algorithm for fast supervised learning," *Neural Networks*, vol. 6, no. 4, pp. 525–533, January 1993.
- [124] B. Jang, M. Kim, G. Harerimana and J. W. Kim, "Q-Learning Algorithms: A Comprehensive Classification and Applications," in *IEEE Access*, vol. 7, pp. 133653-133667, 2019, doi: 10.1109/ACCESS.2019.2941229.
- [125] J.M.Ashfaq, A. Iqbal, „Introduction to Support Vector Machines and Kernel Methods. 2019. Available online: <https://www.researchgate.net/publication/332370436> (accessed on 15 April 2023).
- [126] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, R. R. Salakhutdinov, "Improving neural networks by preventing co-adaptation of feature detectors", *Computer Vision and Pattern Recognition*, Jul 2012.
- [127] Kc Santosh, N. Das and S. Ghosh, „Deep Learning Models for Medical Imaging“, Academic Press, 2021, ISBN 978-0-12-823504-1.
- [128] T. Liu et al., "Digital Predistortion Linearization with Deep Neural Networks for 5G Power Amplifiers," 2019 European Microwave Conference in Central Europe (EuMCE), Prague, Czech Republic, pp. 216-219, May 2019
- [129] C. Tarver, L. Jiang, A. Sefidi and J. R. Cavallaro, "Neural Network DPD via Backpropagation through a Neural Network Model of the PA," 2019 53rd Asilomar Conference on Signals, Systems, and Computers, Pacific Grove, CA, USA, pp. 358-362, November 2019, doi: 10.1109/IEEECONF44664.2019.9048910.
- [130] C. Tarver, A. Balatsoukas-Stimming and J. R. Cavallaro, "Design and Implementation of a Neural Network Based Predistorter for Enhanced Mobile Broadband," 2019 IEEE International Workshop on Signal Processing Systems (SiPS), Nanjing, China, pp. 296-301, October 2019, doi: 10.1109/SiPS47522.2019.9020606.
- [131] J. Sun, J. Wang, L. Guo, J. Yang and G. Gui, "Adaptive Deep Learning Aided Digital Predistorter Considering Dynamic Envelope," in *IEEE Transactions on Vehicular Technology*, vol. 69, no. 4, pp. 4487-4491, April 2020, doi: 10.1109/TVT.2020.2974506.
- [132] Y. Wu, U. Gustavsson, A. G. i. Amat and H. Wymeersch, "Residual Neural Networks for Digital Predistortion," *GLOBECOM 2020 - 2020 IEEE Global Communications Conference*, Taipei, Taiwan, 2020, pp. 01-06, doi: 10.1109/GLOBECOM42002.2020.9322327.
- [133] M. Li, Z. Cai, Y. Yao, C. Xu, Y. Jin and X. Wang, "Complex-Valued Pipelined Chebyshev Functional Link Recurrent Neural Network for Joint Compensation of Wideband Transmitter Distortions and Impairments," in *IEEE Access*, vol. 8, pp. 159828-159838, September 2020, doi: 10.1109/ACCESS.2020.3020880.
- [134] M. Tanio, N. Ishii and N. Kamiya, "Efficient Digital Predistortion Using Sparse Neural Network," in *IEEE Access*, vol. 8, pp. 117841-117852, June 2020, doi: 10.1109/ACCESS.2020.3005146.
- [135] G. Li, Y. Zhang, H. Li, W. Qiao and F. Liu, "Instant Gated Recurrent Neural Network Behavioral Model for Digital Predistortion of RF Power Amplifiers," in *IEEE Access*, vol. 8, pp. 67474-67483, April 2020, doi: 10.1109/ACCESS.2020.2986816.

- [136] A. Brihuega, L. Anttila and M. Valkama, "Neural-Network-Based Digital Predistortion for Active Antenna Arrays Under Load Modulation," in *IEEE Microwave and Wireless Components Letters*, vol. 30, no. 8, pp. 843-846, August 2020, doi: 10.1109/LMWC.2020.3004003.
- [137] P. Jaraut, M. Helaoui, W. Chen, M. Rawat, N. Boulejfen and F. M. Ghannouchi, "Review of the Neural Network based Digital Predistortion Linearization of Multi-Band/MIMO Transmitters," 2021 *IEEE MTT-S International Wireless Symposium (IWS)*, 2021, pp. 1-3, DOI: 10.1109/IWS52775.2021.9499466.
- [138] **T. Muškatirović-Zekić**, N. Nešković i Đ. Budimir, "Primena neuralnih mreža za kompenzaciju nelinearne distorzije u mobilnim sistemima nove generacije," 2022 40ti Simpozijum o novim tehnologijama u poštanskom i telekomunikacionom saobraćaju – PosTel 2022, Beograd, Srbija, pp. 241-248, November 2022, doi: 10.37528/FTTE/9788673954165/POSTEL.2022.025.
- [139] M. Cabarkapa, N. Neskovic and D. Budimir, "A Generalized 2-D Linearity Enhancement Architecture for Concurrent Dual-Band Wireless Transmitters," in *IEEE Transactions on Microwave Theory and Techniques*, vol. 61, no. 12, pp. 4579-4590, Dec. 2013, doi: 10.1109/TMTT.2013.2287679.
- [140] **Tamara Muškatirović-Zekić**, Milan Čabarkapa, Nataša Nešković and Djurdj Budimir, "Compensation of nonlinear distortion in hybrid beamforming MIMO transmitters", *International Journal of Electrical Engineering and Computing*, June 2022, DOI: <https://doi.org/10.7251/IJEEC2206026Z>
- [141] 3GPP Technical Report 38.901. Study on Channel Model for Frequencies from 0.5 to 100 GHz. v16.1.0 (Release 16); ETSI: Sophia Antipolis, France, 2019.

Prilog 1 – Kod za generisanje koeficijenata za hibridni *beamforming* u *Matlab-u*

```

Nt = 64;
NtRF = 2;
Nr = 64;
NrRF = 2;
Ns = 1;

rng(4096);
c = 3e8;
fc = 2.14e9;
lambda = c/fc;
txarray = phased.PartitionedArray(...
    'Array',phased.URA([sqrt(Nt) sqrt(Nt)],lambda/2),...
    'SubarraySelection',ones(NtRF,Nt),'SubarraySteering','Custom');
rxarray = phased.PartitionedArray(...
    'Array',phased.URA([sqrt(Nr) sqrt(Nr)],lambda/2),...
    'SubarraySelection',ones(NrRF,Nr),'SubarraySteering','Custom');

Ncl = 6;
Nray = 5;
angspread = 10;
Nscatter = Nray*Ncl;

txclang = [rand(1,Ncl)*120-60;rand(1,Ncl)*60-30];
rxclang = [rand(1,Ncl)*120-60;rand(1,Ncl)*60-30];
txang = zeros(2,Nscatter);
rxang = zeros(2,Nscatter);
for m = 1:Ncl
    txang(:,(m-1)*Nray+(1:Nray)) = randn(2,Nray)*sqrt(angspread)+txclang(:,m);
    rxang(:,(m-1)*Nray+(1:Nray)) = randn(2,Nray)*sqrt(angspread)+rxclang(:,m);
end
g = (randn(1,Nscatter)+1i*randn(1,Nscatter))/sqrt(Nscatter);
txpos = getElementPosition(txarray)/lambda;
rxpos = getElementPosition(rxarray)/lambda;
H = scatteringchanmtx(txpos,rxpos,txang,rxang,g);
At = steervec(txpos,txang);
Ar = steervec(rxpos,rxang);
snr_param = 0; % SNR in dB
snr = db2pow(snr_param);
[Fbb,Frff,Wbb,Wrf] = omphybweights(H,Ns,NtRF,At,NrRF,Ar,1/snr);

F=Fbb*Frff;
W=Wrf*Wbb;
save('HBF_2RF_64x64.mat','Fbb','Frff','H','Wrf','Wbb');

```

Prilog 2 – Kod za generisanje OFDM signala u *Matlab-u*

```
function [OFDMsignal]= createOFDM(Ndata, Nused_sc, FFT, M, m)

Nsim=Ndata/Nused_sc;
G=1/2^m;
CPx=G*FFT;
P1=zeros(Ndata,1);
P1 = randi(M-1, Ndata, 1);
Map = qammod(P1,M);
    I1=imag(Map);
    Q1=real(Map);
C1=I1.^2+Q1.^2;
U=mean(C1);
V=sqrt(U);
I=I1/V;
Q=Q1/V;
X1=[I Q];
X2=zeros(Ndata,1);
X2=X1(:,1)+i*X1(:,2);
X3=zeros(FFT,1);
x4=zeros(FFT,1);
m=zeros((FFT-Nused_sc),1);
for ii=0:(Nsim-1)
    X3=[X2(ii*Nused_sc/2+1 : Nused_sc/2+ii*Nused_sc/2,1); m; X2(Nused_sc/2+ii*Nused_sc+1 :
Nused_sc+ii*Nused_sc,1)];
    x4=ifft(X3,FFT);
    x5(ii*(FFT+CPx)+1 : CPx+ii*(FFT+CPx),1)=x4(FFT-CPx+1 : FFT,1);
    x5(CPx+ii*(FFT+CPx)+1 : FFT+CPx+ii*(FFT+CPx),1)=x4;
end;

OFDMsignal = x5(:)';
```

Biografija autora

Tamara Muškatirović-Zekić rođena je 22. septembra 1982. godine u Beogradu. Osnovnu školu „Isidora Sekulić“ u Beogradu završila je 1997. godine kao đak generacije i nosilac Vukove diplome. „Matematičku gimnaziju“ u Beogradu završila je 2001. godine kao nosilac Vukove diplome.

Osnovne studije na Elektrotehničkom fakultetu u Beogradu upisala je 2001. godine. Diplomirala je na odseku za Elektroniku, telekomunikacije i automatiku, smer Telekomunikacije 2006. godine, sa prosečnom ocenom 9.50 i ocenom 10 za Diplomski rad na temu „Adaptivni antenski nizovi“.

Doktorske studije na Elektrotehničkom fakultetu u Beogradu, modul Telekomunikacije, upisala je 2011. godine.

Od 2007. godine zaposlena je u Regulatornoj agenciji za elektronske komunikacije i poštanske usluge. Tokom profesionalne karijere radila je na poslovima ocenjivanja usaglašenosti radio i telekomunikacione terminalne opreme, pregledu projektne dokumentacije telekomunikacionih mreža, izradi tehničke dokumentacije, opštih zakonskih i podzakonskih akata iz oblasti elektronskih komunikacija, kao i na poslovima tehničkog pregleda telekomunikacionih objekata. Trenutno obavlja poslove višeg savetnika za fiksne i satelitske radio-komunikacije, u okviru kojih vrši analizu zahteva za nove dodele frekvencija, učestvuje u radu državnih i međunarodnih organizacija i institucija iz oblasti telekomunikacija i saraduje sa regulatornim i stručnim telima drugih država.

Član je Inženjerske komore Srbije od 2010. godine i poseduje licencu odgovornog projektanta telekomunikacionih mreža i sistema.

U dosadašnjem stručnom i naučnom radu, objavila je jedan rad u međunarodnom časopisu sa SCI liste, dva rada u domaćim časopisima, četrnaest radova u zbornicima međunarodnih konferencija i jedan rad u zborniku konferencija nacionalnog značaja.

Izjava o autorstvu

Ime i prezime autora Tamara Muškatirović-Zekić

Broj indeksa 2011/5008

Izjavljujem

da je doktorska disertacija pod naslovom

Modeli digitalne predistorzije za hibridne masivne višeantenske

predajnike sa formiranjem snopa primenom neuralnih mreža

- rezultat sopstvenog istraživačkog rada;
- da disertacija u celini ni u delovima nije bila predložena za sticanje druge diplome prema studijskim programima drugih visokoškolskih ustanova;
- da su rezultati korektno navedeni i
- da nisam kršila autorska prava i koristila intelektualnu svojinu drugih lica.

Potpis autora

U Beogradu, 07.06.2023.

Tamara Muškatirović-Zekić

Izjava o istovetnosti štampane i elektronske verzije doktorskog rada

Ime i prezime autora Tamara Muškatirović-Zekić

Broj indeksa 2011/5008

Studijski program Elektrotehnika i računarstvo

Naslov rada Modeli digitalne predistorzije za hibridne masivne višecentenske predajnike sa formiranjem snopa primenom neuralnih mreža

Mentor dr Nataša Nešković

Izjavljujem da je štampana verzija mog doktorskog rada istovetna elektronskoj verziji koju sam predala radi pohranjivanja u **Digitalnom repozitorijumu Univerziteta u Beogradu**.

Dozvoljavam da se objave moji lični podaci vezani za dobijanje akademskog naziva doktora nauka, kao što su ime i prezime, godina i mesto rođenja i datum odbrane rada.

Ovi lični podaci mogu se objaviti na mrežnim stranicama digitalne biblioteke, u elektronskom katalogu i u publikacijama Univerziteta u Beogradu.

Potpis autora

U Beogradu, 07.06.2023.

Tamara Muškatirović-Zekić

Izjava o korišćenju

Ovlašćujem Univerzitetsku biblioteku „Svetozar Marković“ da u Digitalni repozitorijum Univerziteta u Beogradu unese moju doktorsku disertaciju pod naslovom:

Modeli digitalne predistorzije za hibridne masivne višeantenske

predajnike sa formiranjem snopa primenom neuralnih mreža

koja je moje autorsko delo.

Disertaciju sa svim priložima predala sam u elektronskom formatu pogodnom za trajno arhiviranje.

Moju doktorsku disertaciju pohranjenu u Digitalnom repozitorijumu Univerziteta u Beogradu i dostupnu u otvorenom pristupu mogu da koriste svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (Creative Commons) za koju sam se odlučila.

1. Autorstvo (CC BY)
2. Autorstvo – nekomercijalno (CC BY-NC)
3. Autorstvo – nekomercijalno – bez prerada (CC BY-NC-ND)
4. Autorstvo – nekomercijalno – deliti pod istim uslovima (CC BY-NC-SA)
5. Autorstvo – bez prerada (CC BY-ND)
6. Autorstvo – deliti pod istim uslovima (CC BY-SA)

(Molimo da zaokružite samo jednu od šest ponuđenih licenci.
Kratak opis licenci je sastavni deo ove izjave.)

Potpis autora

U Beogradu, 07.06.2023.

Marina Mijalković Zekić

-
1. **Autorstvo.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence, čak i u komercijalne svrhe. Ovo je najslobodnija od svih licenci.
 2. **Autorstvo – nekomercijalno.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca ne dozvoljava komercijalnu uporebu dela.
 3. **Autorstvo – nekomercijalno – bez prerada.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, bez promena, preoblikovanja ili upotrebe dela u svom delu, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca ne dozvoljava komercijalnu uporebu dela. U odnosu na sve ostale licence, ovom licencom se ograničava najveći obim prava korišćenja dela.
 4. **Autorstvo – nekomercijalno – deliti pod istim uslovima.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence i ako se prerada distribuira pod istom ili sličnom licencom. Ova licenca ne dozvoljava komercijalnu uporebu dela i prerada.
 5. **Autorstvo – bez prerada.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, bez promena, preoblikovanja ili upotrebe dela u svom delu, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca dozvoljava komercijalnu uporebu dela.
 6. **Autorstvo – deliti pod istim uslovima.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence i ako se prerada distribuira pod istom ili sličnom licencom. Ova licenca dozvoljava komercijalnu uporebu dela i prerada. Slična je softverskim licencama, odnosno licencama otvorenog koda.