



UNIVERZITET U NOVOM SADU  
FAKULTET TEHNIČKIH NAUKA U  
NOVOM SADU



ALEKSANDAR STANISAVLJEVIĆ

**NOVA METODA DETEKCIJE PROPADA NAPONA U MREŽI  
SA DISTRIBUIRANIM GENERATORIMA**

**DOKTORSKA DISERTACIJA**

Mentor

**Prof. dr Vladimir Katić**

Novi Sad, 2018.



УНИВЕРЗИТЕТ У НОВОМ САДУ • ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА  
21000 НОВИ САД, Трг Доситеја Обрадовића 6

## КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА

Redni broj, <b>RBR</b> :		
Identifikacioni broj, <b>IBR</b> :		
Tip dokumentacije, <b>TD</b> :	Monografska dokumentacija	
Tip zapisa, <b>TZ</b> :	Tekstualni štampani materijal	
Vrsta rada, <b>VR</b> :	Doktorska disertacija	
Autor, <b>AU</b> :	Aleksandar Stanisavljević	
Mentor, <b>MN</b> :	Profesor Vladimir Katić, redovni profesor	
Naslov rada, <b>NR</b> :	Nova metoda detekcije propada napona u mreži sa distribuiranim generatorima	
Jezik publikacije, <b>JP</b> :	Srpski	
Jezik izvoda, <b>JI</b> :	Srpski	
Zemlja publikovanja, <b>ZP</b> :	Republika Srbija	
Uže geografsko područje, <b>UGP</b> :	Vojvodina	
Godina, <b>GO</b> :	2018.	
Izdavač, <b>IZ</b> :	Autorski reprint	
Mesto i adresa, <b>MA</b> :	21000 Novi Sad, Fakultet tehničkih nauka, Trg Dositeja Obradovića 6	
Fizički opis rada, <b>FO</b> : (poglavlja/strana/ citata/tabela/slika/grafika/priloga)	7/140/141/14/34/0/2	
Naučna oblast, <b>NO</b> :	Elektrotehničko i računarsko inženjerstvo	
Naučna disciplina, <b>ND</b> :	Elektroenergetika	
Predmetne odrednice / ključne reči, <b>PO</b> :	Detakcija kvara, kvalitet električne energije, propadi napona, pametne mreže, harmonijska analiza, tranzijent, neuronske mreže, analiza kvara	
<b>UDK</b>		
Čuva se, <b>ČU</b> :	Biblioteka Fakulteta tehničkih nauka, Trg Dositeja Obradovića 6	
Važna napomena, <b>VN</b> :		
Izvod, <b>IZ</b> :	U ovoj doktorskoj disertaciji je predstavljena je nova metoda za detekciju propada napona, zasnovana na Rekurentnoj neuronskoj mreži i analizi u harmonijskom domenu. Metoda je namenjena za primenu u savremenim distributivnim mrežama koje sadrže obnovljive izvore, i u skladu sa tim je optimizovana i testirana. Pametna metoda postiže izuzetne rezultate u brzini detekcije, sa prosečnim vremenom detekcije manjim od 1 ms, uz izuzetnu pouzdanost (preko 97%). U doktorskoj disertaciji dokazana je i druga hipoteza, a to je da je moguće predvideti dubinu propada algoritmom zasnovanim na harmonijskoj analizi.	
Datum prihvatanja teme, <b>DP</b> :		
Datum odbrane, <b>DO</b> :		
Članovi komisije, <b>KO</b> :	Predsednik: Vladimir Strezoski, redovni profesor	
	Član: Boris Dumnić, vanredni profesor	
	Član: Stevan Grabić, vanredni profesor	
	Član: Saša Mujović, vanredni profesor	Potpis mentora
	Član, mentor: Vladimir Katić, redovni profesor	



УНИВЕРЗИТЕТ У НОВОМ САДУ • ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА  
21000 НОВИ САД, Трг Доситеја Обрадовића 6

## КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА

Accession number, ANO:	
Identification number, INO:	
Document type, DT:	Monographic publication
Type of record, TR:	Textual printed material
Contents code, CC:	PhD thesis
Author, AU:	Aleksandar Stanisavljević
Mentor, MN:	Professor Vladimir Katić
Title, TI:	Novel method for detection of voltage dips in the grid with distributed generation
Language of text, LT:	Serbian
Language of abstract, LA:	English
Country of publication, CP:	Republic of Serbia
Locality of publication, LP:	Vojvodina
Publication year, PY:	2018.
Publisher, PB:	Author's reprint
Publication place, PP:	21000 Novi Sad, Faculty of technical sciences, Trg Dositeja Obradovića 6
Physical description, PD: <small>(chapters/pages/ref./tables/pictures/graphs/appendixes)</small>	7/140/141/14/34/0/2
Scientific field, SF:	Electrical and computer engineering
Scientific discipline, SD:	Electrical power engineering
Subject/Key words, S/KW:	Fault detection, PQ analysis, Voltage dip, Smart grids, Harmonic analysis, Power system transients, Neural network, fault analysis
<b>UC</b>	
Holding data, HD:	The Library of Faculty of technical sciences, Trg Dositeja Obradovića 6
Note, N:	
Abstract, AB:	In this PhD thesis, a novel method for the detection of voltage dips (sags), based on the Recurrent Neural Network and analysis in the frequency domain, is presented. The method is intended for use in the modern distribution grids that contains renewable sources, and accordingly it is optimized and tested. The smart method achieves exceptional results in detection speed, with an average detection time of less than 1 ms and with high reliability (over 97%). In the PhD thesis, another hypothesis is proved, which claims that is possible to predict the depth of dip with algorithm based on the harmonic analysis.
Accepted by the Scientific Board on, ASB:	
Defended on, DE:	
Defended Board, DB:	President: Vladimir Strezoski, PhD, professor
	Member: Boris Dumnić, associate professor
	Member: Stevan Grabić, associate professor
	Member: Saša Mujović, associate professor
	Member, Mentor: Vladimir Katić, PhD, professor
	Mentor's sign



# REZIME

U cilju poboljšanja odziva i ponašanja sistema sa obnovljivim izvorima tokom propada napona u mreži, brza i pouzdana detekcija propada napona je neophodna. Primećeno je na osnovu analize velikog broja merenih propada napona, napona u simulacijama i u laboratorijskim uslovima da početak kvara je karakterisan specifičnim oblikom porasta seta drugog, trećeg, petog i sedmog harmonika. Ova nova karakteristika koja je primećena nazvana je harmonijski otisak i na osnovu nje je razvijena metoda za izuzetno brzu detekciju. Da bi se prepoznao ovaj karakteristični oblik, primenjena je Rekurentna neuronska mreža (RNN) i formirana je nova metoda za detekciju propada napona. RNN je napredni oblik neuronske mreže kod koje neuroni unutar mreže imaju međusobne veze, što joj daje prednost u odnosu na druge tipove neuronskih mreža, posebno kod dinamičke analize. Predložena metoda je testirana sa propadima napona izmerenim u realnim distributivnim mrežama, sa signalima dobijenim u simulacijama kao i sa signalima emuliranim i snimljenim u laboratorijskim uslovima. Detaljno su testirani brzina metode, pouzdanost i računaska kompleksnost (zahtevnost) metode.

Pored same detekcije, poznavanje uslova u mreži tokom poremećaja je takođe bitan faktor u radu različitih uređaja i algoritama u savremenim distributivnim mrežama, poput dinamičkog restauratora napona (Dynamic Voltage Restorer - DVR uređaja), uređaja za unapređenje kvaliteta energije (Unified Power Quality Conditioner (UPQC) kao i različitih kontrolnih algoritma distributivnih generatora koji su zaduženi za kontrolisanje rada tokom kvara u mreži i omogućavanja podrške elektroenergetskom sistemu tokom kvara. Kao deo algoritma za detekciju uslova u mreži detekcija propada napona obuhvata i proračun indikatora koji određuju ponašanje kontrolnih sistema gore pomenutih uređaja tokom poremećaja. Estimacija minimalne amplitude napona tokom propada napona (skraćeno MAN - minimalne vrednosti) koja je kao ključni parametar kvara definisana u IEEE standardu 1564-2014, je od izuzetne važnosti za pravovremenu i odgovarajuću podršku mreži. Postojanje korelacije, tj. veze između maksimuma seta od drugog, trećeg, petog i sedmog harmonika tokom tranzijenta i MAN vrednosti je po prvi put utvrđena, matematički formulisana i statistički dokazana. Na osnovu ove povezanosti formirana je metoda koja se velikom statističkom sigurnošću može da predvidi "težinu" kvara nekoliko desetina do nekoliko stotina milisekundi pre nego što kvar dostigne maksimalnu dubinu, tj vrednost MAN. Predložena metoda je testirana sa naponskim poremećajima izmerenim i snimljenim u realnim distributivnim mrežama, sa signalima dobijenim u simulacijama.

# ABSTRACT

In order to improve the response and behavior of systems with renewable sources during network failure, a fast and reliable detection of voltage drop is necessary. It was noticed on the basis of the analysis of a large number of measured voltage dips, voltage recorded in simulations and in laboratory conditions that the beginning of the fault was characterized by a specific shape of the second, third, fifth and seventh harmonic. This new feature that is noticed is called the ‘‘Harmonic footprint’’, and based on this new feature method for extremely fast detection is developed. In order to recognize this characteristic form, the recurrent neural network is applied. A recurrent neural network is an advanced form of a neuronal network in which neurons within the network have interconnections. This feature gives it an advantage over other types of neural networks, especially in dynamic analysis. The proposed method was tested with voltage dips measured in real distribution networks, with signals obtained in simulations, as well as with signals emulated and recorded in laboratory conditions. The detection time of the method, reliability and calculation complexity were tested in detail.

In addition to the detection itself, knowledge of network conditions during faults is also an important factor in the operation of various devices and algorithms in modern distribution grids, such as Dynamic Voltage Restorer (DVR), the Unified Power Quality Conditioner (UPQC) as well as various control algorithms for distribution generators that are responsible for controlling low-voltage ride through and that are providing support to the power system. As part of the algorithm for detection of network conditions, the detection of voltage dip also includes the calculation of indicators that determine the behavior of the control systems of the above devices during of the minimum voltage amplitude (shortened MAN - minimum values), which is a key failure parameter defined in IEEE standard 1564-2014, with utmost importance for time precise and adequate network support. Connection (correlation) between the maximum of the set of the second, third, fifth and seventh harmonics during the transient and the MAN values were determined for the first time, mathematically formulated and statistically proven. Based on this connection the algorithm that can predict the severity of fault several tens or several hundred milliseconds before the failure reaches the MAN value were created. Method has statistical certainty of over 95%. The proposed method was tested with voltage disorders measured and recorded in real distribution networks and with signals obtained in simulations.

## Biografija

**Stanisavljević Aleksandar** rođen je u Beogradu 10.08.1988. Osnovnu školu i srednju tehničku školu "Nikola Tesla" završio je u Sremskoj Mitrovici.



Diplomirao je 2011 godine na Fakultetu tehničkih nauka u Novom Sadu, a master studije završio 2012 godine takođe na Fakultetu tehničkih nauka, odbranivši master rad "Uticaj distributivnih generatora i kondenzatora na vrednost struje kvara po IEC i IEEE standardima" sa ocenom 10, sa srednjom ocenom na master studijama 9.50. Radni odnos zasnovao je 2012 na Fakultetu tehničkih nauka kao istraživač pripravnik i iste godine upisuje doktorske studije. Godine 2016. izabran je u zvanje Asistent-Master, na Katedri za energetska elektroniku i pretvarače. Na fakultetu drži vežbe na studijskim programima osnovnih studija: E1 – Energetika, elektronika i telekomunikacije - iz predmeta Obnovljivi izvori i male elektrane i Softverski praktikum, Sabračaj –Elektrotehnika i električne mašine. Učestvovao je na brojnim međunarodnim konferencijama. Autor ili koautor je više od 20 naučnih radova, od kojih su dve publikacije u vrhunskim međunarodnim časopisima.

## ZAHVALNICA

Rad koji vodi do dobijanja doktorske disertacije ima svoje uspone i padove i zahteva veliku posvećenost i odricanje. Sve je mnogo lakše ako imate pomoć i podršku ljudi koji se trude da na tom putu i uspete, pre svega mentora, koji vas na ovom putu vodi i usmerava. Sa zadovoljstvom želim da izrazim veliku zahvalnost određenom broju ljudi, koji su na različite načine doprineli da moj put bude uspešan.

Veliku, sigurno najveću zahvalnost što je do ove disertacije došlo dugujem svom mentoru, Prof. dr Vladimiru Katiću, na usmeravanju mog istraživanja u pravom smeru, idejama iz koje su zajednički radovi kao i ova disertacija nastali, pruženoj prilici kao i savetima, komentarima, velikom strpljenju, mnogim satima provedenim u osmišljavanju i pisanju radova, kao i možda najbitnijem, prenetom znanju kako napisati rad.

Veliku zahvalnost dugujem i dr Iliji Kovačeviću na svim naučno-stručnim savetima, ali i vrlo bitnim životnim savetima koje sam dobio kao i ogromnoj podršci u mnogim segmentima života. Mogao bih sa ponosom reći i prijateljskim odnosom koji smo izgradili tokom godina provedenih u zajedničkom kabinetu.

Takođe, želim da se zahvalim kolegama dr Borisu Dumniću i Banetu Popadiću na značajnoj i nezamenljivoj pomoći tokom istraživanja i radu u laboratoriji.

Želim da se zahvalim i svim članovima komisije koji su svojim sugestijama doprineli da disertacija bude jasnija i kvalitetnija.

Takođe, zahvalnost dugujem i profesoru Math Bollen-u na ustupljenim rezultatima merenih naponskih poremećaja i propada napona, bez kojih bi testiranje metoda predstavljenih u ovoj disertaciji bilo mnogo komplikovanije i nepotpuno.

Na kraju, svoju veliku zahvalnost želim da izrazim i svojim roditeljima, bratu, devojci Ivani, Srđanu i drugim prijateljima na svakodnevnoj bezrezervnoj podršci i ljubavi.

*Aleksandar Stanisavljević*



# SADRŽAJ

Rezime .....	i
Abstract.....	ii
Spisak korišćenih skraćenica.....	viii
Spisak slika .....	x
Spisak tabela.....	xiii
<b>POGLAVLJE 1</b>	
<b>UVOD .....</b>	<b>1</b>
1.1 Uvodna razmatranja .....	2
1.1.1 Uzroci nastanka i tipični kvarovi u elektroenergetskom sistemu.....	2
1.1.2 Propadi napona kao posledica kratkih spojeva i drugih poremećaja u mreži .....	6
1.2 Predmet i cilj istraživanja.....	15
1.3 Struktura rada .....	17
<b>POGLAVLJE 2</b>	
<b>PREGLED STANJA U OBLASTI.....</b>	<b>19</b>
2.1 Uvod .....	20
2.2 Pregled i klasifikacija metoda za detekciju i analizu poremećaja napona .....	20
2.3 Standardne metode .....	22
2.4 Metode bazirane na obradi signala .....	23
2.4.1 Neparametarske metode.....	23
2.4.2 Parametarske metode.....	29
2.4.3 Hibridne metode.....	30
2.5 Metode bazirane na veštačkoj inteligenciji.....	32
2.6 Kritička analiza postojećih metoda.....	34
2.7 Zaključak .....	36
<b>POGLAVLJE 3</b>	
<b>SAVREMENE DISTRIBUTIVNE MREŽE SA DISTRIBUIRANIM GENERATORIMA.....</b>	<b>39</b>
3.1 Uvod .....	40
3.2 Pametne mreže .....	42
3.3 Mikro mreže .....	43
3.4 Modeli distributivnih mreža.....	44
3.4.1 Distributivne test mreže .....	45

3.4.2 IEEE test mreže .....	45
3.5 Druge test mreže.....	48
3.5.1 Texas A&M engineering test mreže .....	48
3.5.2 Electric Power Research Institute test grids .....	48
3.5.3 Test mreže koje sadrže i HVDC .....	49
3.6 Zaključak .....	51
<b>POGLAVLJE 4</b>	
<b>HARMONIJSKI OTISAK.....</b>	<b>52</b>
4.1 Definisane "Harmonijskog otiska" .....	53
4.2 Primeri, izgled i matematička formulacija harmonijskog otiska .....	53
<b>POGLAVLJE 5</b>	
<b>PAMETNA METODA ZA DETEKCIJU PN ZASNOVANA NA RNN I HARMONIJSKOM OTISKU..</b>	<b>60</b>
5.1 Predlog pametne metode za detekciju PN .....	61
5.2 Opis načina testiranja .....	64
5.2.1 Kompjuterske simulacije.....	64
5.2.2 Laboratorijska postavka .....	67
5.2.3 Naponski poremećaji izmereni u realnim distributivnim mrežama .....	69
5.3 Rezultati pametne metode za detekciju .....	69
5.4 Rezultati računarskih simulacija .....	69
5.5 Rezultati analize signala merenih u realnim distributivnim mrežama .....	71
5.6 Rezultati testiranja signalima dobijenim u laboratorijskim uslovima.....	78
5.7 Ocenjivanje predložene metode .....	80
5.8 Zaključak .....	80
<b>POGLAVLJE 6</b>	
<b>MOGUĆNOST PREDIKCIJE DUBINE PROPADA NA OSNOVU HARMONIJSKOG OTISKA.....</b>	<b>82</b>
6.1 Uvod .....	83
6.2 Algoritmi za estimaciju i praćenje amplitude napona .....	83
6.3 Originalnost i prednosti predložene metode za predikciju .....	87
6.4 Analiza zavisnosti parametara – teorijske osnove.....	87
6.4.1 Pearson-ov koeficijent korelacije.....	88
6.4.2 P-vrednost.....	88
6.4.3 S – standardna greška regresije.....	88
6.4.4 R-Sq.....	88

6.4.5 R-Sq (adj.) .....	89
6.5 Rezultati ispitivanja predložene metode predikcije.....	89
6.5.1 Analiza korelacija bazirana na snimcima propada napona iz distributivnih mreža.....	89
6.5.2 Rezultati analize korelacija .....	90
6.6 Predikcijska funkcija (funkcija predviđanja).....	90
6.7 Algoritam za predikciju MAN-a.....	94
6.8 Primena MAN predikcijske funkcije .....	96
6.9 Diskusija i testiranje .....	97
6.10 Testiranje metode za predikciju u računarskim simulacijama .....	101
6.11 Zaključak .....	105
<b>POGLAVLJE 7</b>	
<b>ZAKLJUČAK I PRAVCI DALJEG ISTRAŽIVANJA .....</b>	<b>106</b>
7.1 Zaključak disertacije .....	107
7.2 Pravci daljeg istraživanja .....	109
<b>LITERATURA .....</b>	<b>110</b>
<b>SPISAK PUBLIKACIJA AUTORA.....</b>	<b>124</b>
<b>PRILOZI .....</b>	<b>127</b>
P.1 Rezultati korišćeni za formiranje i testiranje funkcije za predikciju .....	128
P.2 Neuronske mreže.....	134
P.2.1 Struktura modela neuronske mreže .....	134
P.2.2 Obučavanje modela neuronske mreže .....	136

# SPISAK KORIŠĆENIH SKRAĆENICA

## Srpske skraćenice

PN	Propad napona
DG	Distributivni generator
ES	Elektroenergetski sistem
DM	Distributivne mreže
FL	Fazi logika (fuzzy)
MAN	Minimalna amplituda tokom propada napona
KF	Kalman filter
DIA	Detekcija i analiza
MRA	Multirezoluciona analiza
HO	Harmonijski otisak
NP	Naponski poremećaj

## Engleske skraćenice

PQ	Power quality – Kvalitet električne energije
LVRT	Voltage ride-trough – Uslovi smanjene amplitude napona
UPS	Uninterruptible Power supply- neprekidan izvor napajanja
UPQC	Unified Power Quality Conditioner – uređaj za unapređenje kvaliteta energije
DVR	Dynamic Voltage Restorer - dinamički restaurator napona
GTI	Grid-tie inverter - invertor povezan na (elektroenergetsku) mrežu
P	Active power – aktivna energija
Q	Reactive power – reaktivna energija
DC	Direct current – jednosmerna struja

AC	Alternating current – naizmenična struja
p.u.	Per unit – po jedinici mere
AC	Alternating current – naizmenična struja
RMS	Root mean square – efektivna vrednost napona
$E_{vs}$	Voltage dip energy - energija propada napona
LSTM	Long short-term memory unit – duge kratko-pamteće memorijske jedinice
HDU2357	Harmonic distortion of voltage – 2 <sup>nd</sup> , 3 <sup>rd</sup> , 5 <sup>th</sup> and 7 <sup>th</sup> harmonics – Harmonici napona, set koji se sastoji od drugog, trećeg, petog i sedmog harmonika
WT	Wavelet transform – wavelet transformacija
NN	Neural network - neuronska mreža
AI	Artificial intelligence – veštačka inteligencija
PNN	Probabilistic neural network – neuronska mreža sa verovatnoćom
FFML	Feedforward multilayer back propagation – tip neuronske mreže
LVQ	Learning vector quantization - tip neuronske mreže
PSO	Particle swarm optimization – optimizacija metodom roja čestica
STFT	Short-Time Fourier Transform – metoda koja je varijacija FFT
HPF	High pass filter – filter koji propušta visoke frekvencije signala
DFIG	Doubly-fed induction generator – dvostruko napajan indukcion generator
IGBT	Insulated-gate bipolar transistor – bipolarni tranzistor sa izolovanim gejtom
PV	Photovoltaic – fotonaponska (solarna) elektrana
MPPT	Maximum Power Point Tracking – praćenje tačke maksimalne snage
PLL	Phase-locked loop – fazno zatvorena petlja
VDC	Voltage DC – DC napon
MH DU2357	Maximum of harmonic distortion of voltage – 2 <sup>nd</sup> , 3 <sup>rd</sup> , 5 <sup>th</sup> and 7 <sup>th</sup> harmonics – Maksimalna vrednost odabranog seta harmonika napona tokom tranzijenta
RTS	Reliability Test System – test sistem namenjen testiranju pouzdanosti

## SPISAK SLIKA

Broj slike	Naziv	Broj stranice
1.1	Tipovi kvara	4
1.2	ABC klasifikacija propada napona	7
1.3	Prikaz propada napona	8
1.4	Pravila za klasifikaciju poremećaja napona definisana standardom IEEE 1159	9
1.5	Dužina vremena nakon propada napona u mreži koju distribuirani izvori moraju da ostanu priključeni na mrežu	11
1.6	Uslovi za podršku mreži u uslovima kvara, za vetro turbine	12
1.7	Pojednostavljena struktura DG sistema povezanog na mrežu, sa prikazanim blokom za detekciju i analizu propada napona	13
1.8	Šematski prikaz algoritma za detekciju i analizu poremećaja u mreži	14
2.1	Klasifikacija metoda za detekciju i analizu naponskih poremećaja	22
2.2	Algoritam za formiranje RFFT metode.	25
3.1	Fazni diagram IEEE test mreža	47
3.2	CIGRE B4 DC test mreža	50
4.1	(a.) Naponski signal u sve tri faze, (b.) HDU2357 u sve tri faze za kvar #6 iz Tabele P1.	54
4.2	HDU2357 uvećan i obeležen period početka poremećaja	55
4.3	Izgled HO za nekoliko različitih kvarova iz tabele P1 (#1, #2, #5, #6, #8, #9) kao i izgled polinomske krive kojom se oblik HO može približno opisati	56

4.4	Prikaz izgleda signala HDU2357 na samom početku kvara, kao i krive Exp2 modela za kvar #8	58
4.5	Prikaz izgleda signala HDU2357 na samom početku kvara, kao i krive Exp2 modela za kvar #6	59
4.6	Prikaz izgleda signala HDU2357 na samom početku kvara, kao i krive Exp2 modela za kvar #9	59
5.1	Struktura RNN prilagođena detekciji naponskih poremećaja	61
5.2	Uprošćen model IEEE13 test mreže sa dodatim distribuiranim izvorima	65
5.3	Simulink model modifikovane IEEE13 test mreže sa distribuiranim generatorima	67
5.4	Izgled laboratorijske opreme	68
5.5	Laboratorijski rezultati za kvar #1	70
5.6	Rezultati analize realnih signala za kvar #8	72
5.7	Rezultati analize signala dobijenih u laboratoriji za kvar #1 iz tabele 8.4	79
6.1	Fitovani grafik poklapanja predikcione funkcije sa stvarnim vrednostima	91
6.2	Residuali u odnosu na fitovane vrednosti	92
6.3	Fitovani grafik poklapanja funkcije predikcije sa stvarnim vrednostima samo za propade C tipa	93
6.4	Reziduali u odnosu na fitovane vrednosti, samo za propade C tipa	94
6.5	Strukturalna blok šema rada algoritma za predikciju MAN	96
6.6	Uprošćena šema strukture kontrolnog algoritma za LVRT kod DG-ova povezanih na mrežu, sa dodatkom algoritma za predikciju propada napona	97
6.7	a) Naponski signal, b) HDU2357 i c) RMS napona, za kvar #1	99

	iz tabele P1	
6.8	a) Naponski signal, b) HDU2357 i c) RMS napona, za kvar #2.8 iz tabele 6.3	100
6.9	Rezultati testiranja u simulaciji za kvar #5 iz tabele 6.5	104



## SPISAK TABELA

Broj tabele	Naziv	Broj stranice
2.1	Pregled osnovnih osobina metoda za DIA-u naponskih poremećaja	36
3.1	Glavne osobine IEEE test mreža	46
3.2	EPRI test mreže	49
4.1	Koeficijenti za polinomski model HO	56
4.2	Koeficijenti za eksponencijalni Exp2 model za kvar #8	57
5.1	Rezultati simulacija	71
5.2	Rezultati analize signala iz realnih mreža	73
5.3	Rezultati analize realnih signala radi utvrđivanja pouzdanosti detekcije bazirane na RNN metodi	73
5.4	Rezultati testova sa signalima snimljenim u laboratoriji	78
6.1	Statistički rezultati analize 106 kvarova	90
6.2	Statistički rezultati analize 30 signala koji sadrže C tip kvara	93
6.3	Rezultati testiranja funkcije predikcije sa 10 merenja koja su odvojena za testiranje	98
6.4	Rezultati testiranja funkcije predikcije sa 2 merenja koja su odvojena za testiranje a koja sadrže propade napona C tipa	101
6.5	Rezultati simulacija za predikciju dubine propada napona	102



# **POGLAVLJE 1**

---

## **UVOD**

## 1.1 UVODNA RAZMATRANJA

Cilj elektroenergetskog sistema se može definisati kao „transport električne energije od generatorskih jedinica do potrošača” i kao „održavanje naponskog nivoa potrošača unutar određenih granica“. Decenijama su se istraživanja i obrazovanje koncentrisali na prvi zahtev. Pouzdanost i kvalitet električne energije su retko bili problem. Pouzdanost se posmatrala sa stanovišta da je visoka i da će uskoro biti i daleko viša [1].

Promena u načinu razmišljanja se pojavila u ranim osamdesetim (oko 1980. godine). Početak ubrzanog razvoja kao i široke primene u industriji računarske i druge nove opreme i u oblasti elektroenergetike, kao i razvoj komercijalnih elektroenergetskih sistema je doveo do širenja ideje o kvalitetu električne energije kao bitnom problemu. Postalo je jasno da oprema redovno ima prekide u radu zbog naponskih poremećaja, ali takođe je primećeno i da potrošači imaju uticaj na mnoge poremećaje u naponu i struji u elektroenergetskoj mreži. Iako su počeci razvoja u oblasti kvaliteta električne energije davno završeni, ova tema je nastavila da se razvija i istražuje i sigurno je da će se taj trend nastaviti i u budućnosti, usled toga da su zahtevi za kvalitetom i pouzdanošću napajanja potrošača postali vrlo bitni u uslovima dereguliranih tržišta električnom energijom.

Kvar je bilo koje stanje koje se ne može definisati kao normalno ili stacionarno stanje u mreži. Stacionarno stanje elektroenergetskog sistema je kada je sistem u balansiranom trofaznom naizmjeničnom režimu rada. Ipak, usled iznenadnih spoljašnjih ili promena unutar samog elektroenergetskog sistema, ovo stanje može biti narušeno.

Kada izolacija u nekom delu elektroenergetskog sistema izgubi svoju ulogu i provodni objekti dođu u kontakt sa vodovima, kratak spoj ili kvar nastaju u tom trenutku. Kratak spoj je u IEC 60 909 standardu definisan kao nastanak (slučajno ili namerno) provodne veze između relativno malu otpornost ili impedansu između dve ili više tačaka električnog kola koje u normalnom stanju su na različitim potencijalima [2].

### 1.1.1 Uzroci nastanka i tipični kvarovi u elektroenergetskom sistemu

Uzroci nastanka kvarova mogu biti različiti, kao na primer:

- Kvarovi i slabljenje izolacije,
- Udar groma,


- Jaki vetrovi,
- Pad stabala i grana drveća preko vodova,
- Kratki spojevi koje mogu izazvati ptice,
- Ulazak manjih životinja u transformatorske stanice i druga postrojenja,
- Prekid vodova usled preopterećenja,
- Itd.

Kvarovi u elektroenergetskom sistemu mogu se podvesti pod jedan od sledeća tri tipa, koji su u sledećem nabrojanju dati po redosledu koji oslikava njihovu učestanost pojavljivanja:

- Kvar (kratak spoj) jedne faze sa zemljom,
- Kvar (kratak spoj) između dve faze,
- Kvar (kratak spoj) dve faze sa zemljom,
- Uravnotežen trofazni kvar (kratak spoj).

Prva tri tipa kvara predstavljaju "teške" neuravnotežene kvarove koji mogu izazvati teške posledice u mreži. Kvarovi jedne faze sa zemljom su veoma česti, posebno u distributivnim mrežama na niskom i srednjem naponu gde postoji uzemljenje. Za trofazni kratak spoj sva tri napona na mestu kratkog spoja su 0 i provodnici su simetrično opterećeni. Kod kvara između dve faze struja kratkog spoja je manja nego kod trofaznog kvara. Dvofazni kvarovi dešavaju se najčešće u mrežama sa izolovanom neutralnom tačkom [2].

Na slici 1.1 šematski su prikazani najbitniji tipovi kratkih spojeva u trofaznim elektroenergetskim mrežama: a. Uravnotežen trofazni kvar, b. Kvar (kratak spoj) između dve faze, c. Kvar (kratak spoj) dve faze sa neutralnim provodnikom, d. Kvar između faze i U voda, e. Kvar između dva fazna voda i zemlje, f. Kvar dve faze sa kontaktom ka uzemljenju i g. Kvar jedne faze sa zemljom. Fazni vodovi su označeni sa L1, L2 i L3, N je neutralni vod dok je U zaštitni (uzemljeni) vod.



Slika 1.1 Tipovi kvara: a. Uravnotežen trofazni kvar, b. Kvar (kratak spoj) između dve faze, c. Kvar (kratak spoj) dve faze sa neutralnim provodnikom, d. Kvar između faze i U voda, e. Kvar između dva fazna voda i zemlje, f. Kvar dve faze sa kontaktom ka uzemljenju i g. Kvar jedne faze sa zemljom

Za potrebe izračunavanja struja kratkih spojeva, potrebno je razlikovati kvarove koji su blizu generatora ili koji su udaljeni od generatora.

- **Kratki spojevi blizu generatora**

Kada je vrednost inicijalne tj. tranzijentne vrednosti struje kratkog spoja veća od dvostruke vrednosti nominalne struje u bar jednom od sinhronih ili asinhronih mašina u trenutku nastanka kvara, smatra se da se radi o kratkom spoju blizu generatora.

Uslovi koji treba da su ispunjeni da bi se kratak spoj mogao smatrati da je blizu generatora:

$$I_k'' > 2I_{ng} \quad (1.1)$$

Ili takođe kada je:

$$I_k'' > I_a > I_k \quad (1.2)$$

Gde je  $I_k''$  inicijalna struja kratkog spoja,  $I_{ng}$  nominalna struja generatora u stacionarnom stanju,  $I_a$  struja prekidanja (cut-off current),  $I_k$  struja kratkog spoja (u ustaljenom stanju kvara).

- **Kratki spojevi udaljeni od generatora**

U slučajevima kada je dvostruka nominalna struja u svim generatorima veća nego struja kratkog spoja, smatra se da je kratak spoj udaljen od generatora.

Uslovi koji treba da su ispunjeni da bi se kratak spoj mogao smatrati da je blizu generatora:

$$I_k'' < 2I_{ng} \quad (1.3)$$

Ili takođe kada je:

$$I_k'' = I_a = I_k \quad (1.4)$$

Kratki spojevi sa zemljom dovode do toga da na mestu kratkog spoja vrednost napona je 0, što je ranije već rečeno. Međutim, kada se posmatraju lokacije u mreži na određenoj

udaljenosti od samog kvara može se primetiti da vrednost napona na ovim mestima nije 0, već je napon umanjene vrednosti u odnosu na nominalnu vrednost. Ovakvi padovi napona se nazivaju propadi napona.

### **1.1.2 Propadi napona kao posledica kratkih spojeva i drugih poremećaja u mreži**

Ova doktorska disertacija se najviše bavi sa problemima kvaliteta električne energije koji prvenstveno pogađaju potrošače, a to su prekidi napajanja i propadi napona. Tokom prekida napajanja amplituda napona pada na nulu, što je verovatno najgore stanje kvaliteta električne energije koji je moguć. U toku propada napona napon nije nula, ali je značano ispod vrednosti koja je nominalna. Ova dva problema kvaliteta su uzročnici najvećeg broja neželjenih prekida u radu potrošača i industrijske opreme.

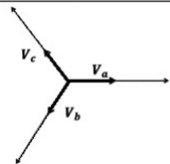
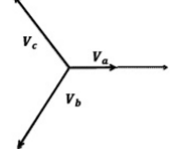
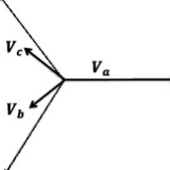
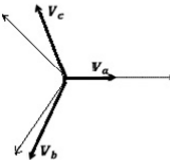
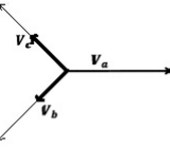
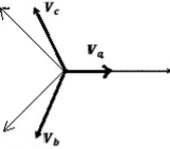
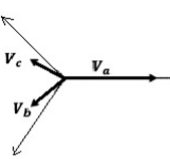
Smanjenje amplitude napona (propad napona - PN) i prekidi u napajanju jedni od glavnih problema u oblasti kvaliteta električne energije. Ove vrste poremećaja izazivaju mnoge probleme i negativne efekte u radu potrošača električne energije, kao i prekide u radu ili kvarove opreme koja je osetljiva na varijacije u naponu. U elektroenergetskim sistemima, posebno u industrijskim sistemima oko 92% od svih poremećaja u napajanju električnom energijom kao uzrok imaju propade napona [3].

Prema IEEE standardu 1159-2009 propadi napona su definisani kao redukcija napona u rasponu od 0.1-0.9 p.u. nominalne vrednosti napona, kada je frekvencija sistema nominalna, i kada je trajanje poremećaja u rasponu od pola periode do jednog minuta [4]. Novi IEEE 1564-2014 standard definiše parametre po kojima se može prepoznati PN. U ovom standardu PN je definisan kao čest i ozbiljan PQ problem koji može izazvati probleme u radu i oštećenje elektroenergetske i druge opreme.

Postoje različiti tipovi kao i različite klasifikacije PN-a u zavisnosti od uzroka nastajanja (kvarovi na prenosnom sistemu, udar groma, povezivanje velikih potrošača ili motora), ili u zavisnosti od tipova kvara, dubine propada, itd. Jedan od metoda klasifikacije propada, svrstavajući propade u 7 različitih kategorija (A, B, C, D, E, F, G), takozvana ABC klasifikacija, predstavljen je u [1] kao i na slici 1.2 IEEE standard 1564-2014 opisuje odgovarajuće karakteristike i osobine koje je potrebno prepoznati kod propada napona [5]. Propadi napona su opisani i prepoznati kao ozbiljan i vrlo čest problem u oblasti kvaliteta energije, sa izuzetno skupim posledicama. Studije su pokazale da ukupni troškovi prekida




rada usled PQ poremećaja (propada, prekida napajanja električnom energijom, harmonika, itd.) može biti od 150 000 \$ [6] i dostići i do 10% ukupne zarade kompanije [7].

Tip	Naponi	Fazni diagrami
A	$V_a = V$ $V_b = -\frac{1}{2}V - j\frac{\sqrt{3}}{2}V$ $V_c = -\frac{1}{2}V + j\frac{\sqrt{3}}{2}V$	
B	$V_a = V$ $V_b = -\frac{1}{2}E - j\frac{\sqrt{3}}{2}E$ $V_c = -\frac{1}{2}E + j\frac{\sqrt{3}}{2}E$	
C	$V_a = E$ $V_b = -\frac{1}{2}E - j\frac{\sqrt{3}}{2}V$ $V_c = -\frac{1}{2}E + j\frac{\sqrt{3}}{2}V$	
D	$V_a = V$ $V_b = -\frac{1}{2}V - j\frac{\sqrt{3}}{2}E$ $V_c = -\frac{1}{2}V + j\frac{\sqrt{3}}{2}E$	
E	$V_a = E$ $V_b = -\frac{1}{2}V - j\frac{\sqrt{3}}{2}V$ $V_c = -\frac{1}{2}V + j\frac{\sqrt{3}}{2}V$	
F	$V_a = V$ $V_b = -\frac{1}{2}V - j\left(\frac{\sqrt{3}}{6}V + \frac{\sqrt{3}}{3}E\right)$ $V_c = -\frac{1}{2}V + j\left(\frac{\sqrt{3}}{6}V + \frac{\sqrt{3}}{3}E\right)$	
G	$V_a = \frac{2}{3}E + \frac{1}{3}V$ $V_b = \left(-\frac{1}{3}E - \frac{1}{6}V\right) - j\frac{\sqrt{3}}{2}V$ $V_c = \left(-\frac{1}{3}E - \frac{1}{6}V\right) + j\frac{\sqrt{3}}{2}V$	

Slika 1.2 ABC klasifikacija propada napona

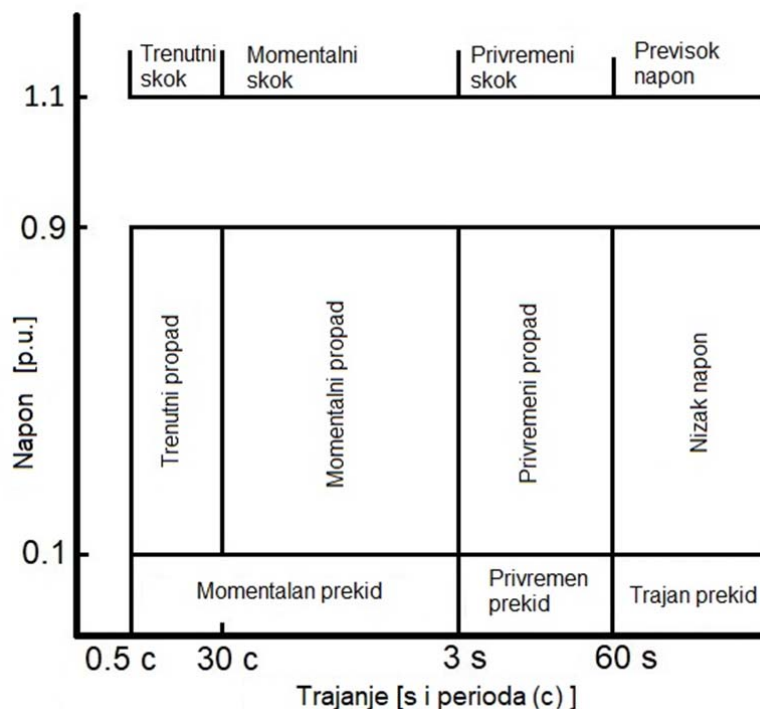
Na slici 1.3 prikazan je izgled signala napona prilikom propada napona u mreži. Na slici se mogu razlikovati tri dela tokom trajanja propada: tranzijentni deo, ustaljeno stanje i oporavak naponskih prilika nakon prestanka kvara.



Slika 1.3 Prikaz propada napona a. Signal napona, b. RMS napona

IEEE standardi za monitoring stanja u mreži ne definiše kako veličina napona i dužina nekog događaja treba da budu estimirani. Uopšteno je prihvaćeno da je dubina propada napona (u standardu "magnitude of voltage dip") najmanja vrednost efektivne vrednosti (RMS) napona u bilo kojoj fazi, u slučaju da je došlo do propada ili do potpunog prekida napajanja. Da bi se definisao naponski nivo nekog poremećaja, potrebno je prvo znati koji je poremećaj u pitanju. Dužina propada ili prekida napajanja je definisana kao vremenski

interval tokom kojeg je RMS napona ispod definisane granice. Naponski poremećaji po standardu IEEE 1159 se definišu na način kao što je predstavljeno u slici 1.4.



Slika 1.4 Pravila za klasifikaciju poremećaja napona definisana standardom IEEE 1159

Negativni efekti PN-a i drugih poremećaja u naponu su primećeni i detaljno opisani u literaturi i mnogim knjigama [1,7–10]. Posebno su primećeni problemi u radu računara, kompjuterske opreme u industriji, digitalnih industrijskih elektromotornih pogona i sličnih uređaja. Iz ovih razloga dodatni uslovi su postavljeni proizvođačima opreme koja je osetljiva na poremećaje napona. Ovi uslovi su različiti uslovi tolerancije koju oprema mora da ima na različite poremećaje: CBEMA/ICIT curves, SEMI F47 [11], IEC Std. 61000-4-11/34 [12].

U cilju da bi se omogućio rad uređaja i u uslovima smanjenog napona (Voltage ride-through - LVRT) i ublažili efekti na elektronsku opremu, nekoliko mogućih rešenja je razvijeno: korišćenje serijskih i paralelnih kontrolera (Series and Shunt controllers) [1], neprekidnih izvora napajanja (Uninterruptible Power supply (UPS)) i sličnih uređaja zasnovanih na skladištenju energije [1,6], ili primena uređaja za unapređenje kvaliteta energije (Unified Power Quality Conditioner (UPQC)) [1,10,13], aktivnog filtera snage

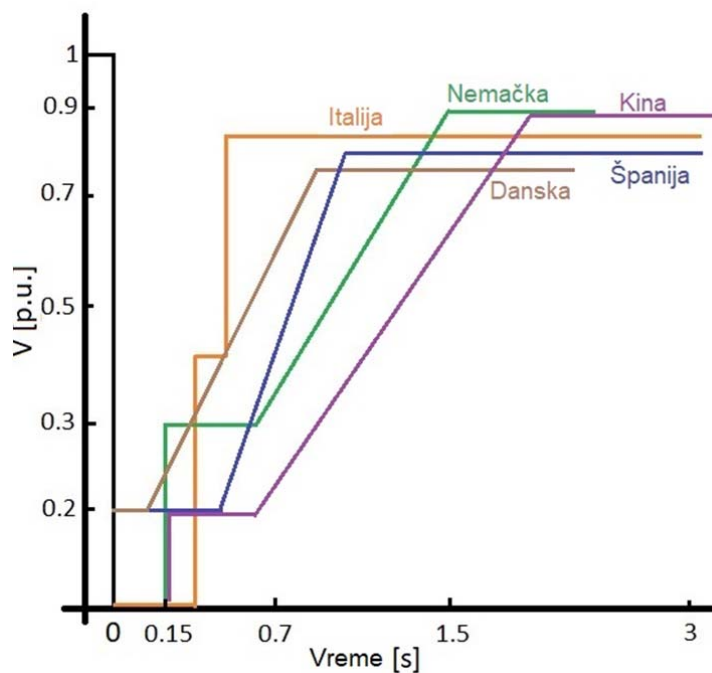
(Series active power filter). dinamičkog restauratora napona (Dynamic Voltage Restorer (DVR) [1,9,13,14] ili druge opreme za kompenzaciju propada napona [15].

Takođe, tokom godina došlo je i do promene u pravcu razvoja i unapređenja u samim distributivnim mrežama (DM). Klasični elektroenergetski sistemi (ES) su funkcionisali na način da je proizvedena električna energija, koja se proizvodila samo u velikim elektranama, distribuirana do potrošača, sa samo jednim pravcem toka energije. Električna energija nije proizvedena u distributivnim mrežama, i mreže su se sastojale isključivo od pasivnih komponenata kao što su potrošači, vodovi, transformatori, itd [16]. U savremenim DM sve više su zastupljeni distribuirani izvori energije (DER), koji se najčešće mogu svrstati u obnovljive izvore energije. Ovi izvori energije, najčešće koristeći energiju sunca i vetra su usloveli i pojavu velikog broja uređaja energetske elektronike (invertora) povezanih na mrežu (Grid-tie inverter (GTI)). Ovi uređaji energetske elektronike mogu biti u DC/AC pretvarači, kao kod PV sistema, ili AC/DC konvertori u slučajevima industrijskih ili kućnih potrošača i uređaja, ili AC/DC/AC konvertori (back-to-back), koji se najčešće primenjuju u vetroelektranama. Kod bilo koja od tri navedena slučaja, ovako povezani izvori električne energije nemaju inerciju, tj. predstavljaju neineracione generatorske sisteme (non-inertia generation). Ovakav rad u slučajevima velikog učešća energije dobijene iz neineracionih generatorskih sistema može ugroziti stabilnost mreže [17]. Kao moguće rešenje ovog problema je predstavljen koncept emulacije inercije, koji se može implementirati u kontrolu uređaja energetske elektronike koji povezuju DER izvore sa mrežom, slično konceptu virtuelne sinhronne mašine [18]. Loša strana ovakvog rešenja je što zahteva mnogo kompleksiji kontrolni algoritam kao i brzu detekciju stanja u mreži, posebno u slučaju kvarova i naglih poremećaja.

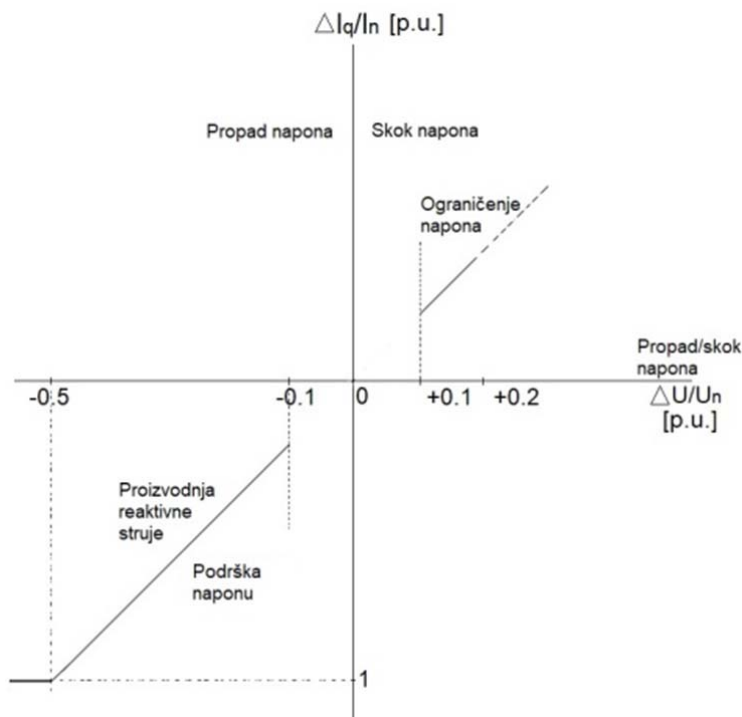
U slučajevima PN-a snažni tranzistori invertorskih jedinica se nalaze pod povećanim strujnim opterećenjem, određen broj perioda [10,19] (1 perioda – 20 ms), i zbog toga brza detekcija kao i precizno i pouzdano praćenje dubine propada je postalo važan deo posmatranja (monitoringa) stanja u mreži. Ono što dodatno komplikuje i otežava rad ovih uređaja je i to što u savremenim pravilima o radu distributivnih sistema, posebno u državama koje imaju veliki broj kao i veliku instalisanu snagu DER izvora je propisano da GTI-ovi moraju da obezbede podršku mreži i tokom poremećaja i kvarova. To znači, da u slučaju PN-a, GTI-ovi moraju da nastavu da rade određen period vremena i da injektuju u mrežu određenu količinu aktivne i reaktivne energije, u zavisnosti od dubine propada napona

[20,21]. Takođe, integracija uređaja energetske elektronike je jedan od glavnih izvora PQ poremećaja [22].

Pravila o radu distributivnog sistema su preporuke i pravila koja izdaju države a u njima se, između ostalog definišu i načini i uslovi koje DER-ovi moraju ispuniti pre priključenja na mrežu, kao i na koji način moraju da rade kada su priključeni u smislu kvaliteta predate električne energije mreži, proizvodnje aktivne snage (i u određenim slučajevima i reaktivne snage), sklopne i zaštitne opreme, itd. Ovi uslovi se menjaju u skladu sa promenama u mreži, a u vezi sa obnovljivim izvorima u zemljama gde energija dobijena iz distributivnih generatora čini značajan udeo, propisano je i koliko vremenski DG mora da radi u slučaju kvara (slika 1.5) kao i koliko aktivne i reaktivne energije mora da proizvede u cilju podrške mreži (slika 1.6), u zavisnosti od dubine propada. Sa slike 1.6 se može videti da je količina proizvedene reaktivne energije direktno zavisna od dubine propada sve dok vrednost napona ne opadne na 0.5 od nominalne vrednosti, nakon čega je potrebno u mrežu predavati čisto reaktivnu energiju. Ovakvi uslovi se pre svega odnose na priključenje vetroelektrana, dok se očekuje i ubrzano istražuje i da se ovakvi uslovi usvoje i za PV sisteme [20,21,23,24].

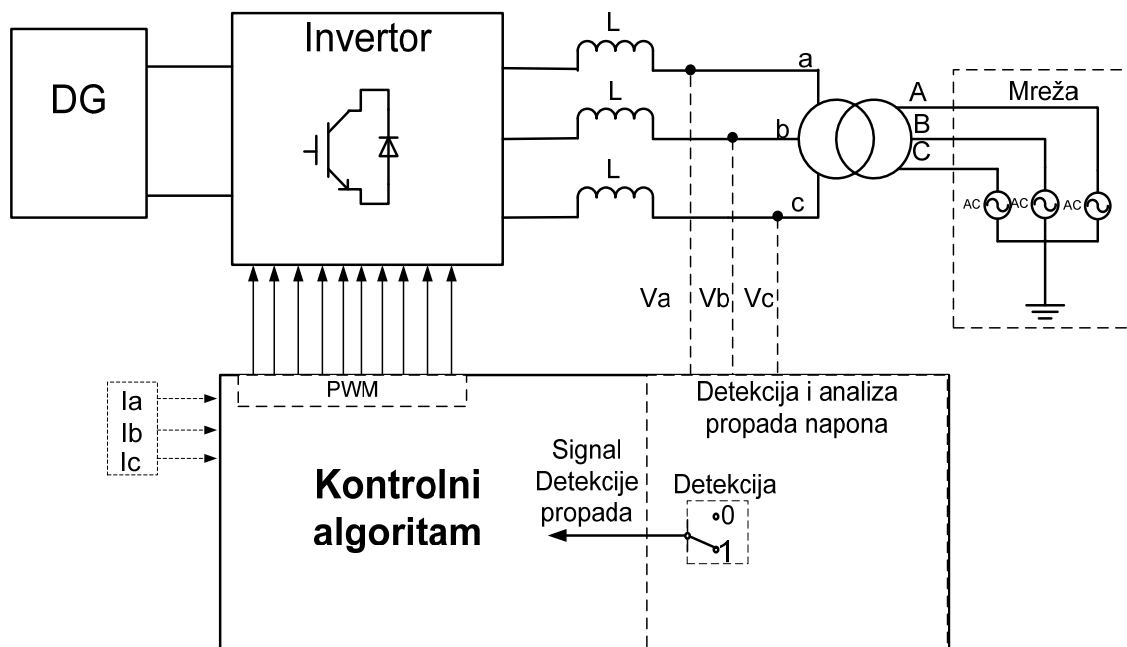


Slika 1.5 Dužina vremena nakon propada napona u mreži koju distribuirani izvori moraju da ostanu priključeni na mrežu [21,25]



Slika 1.6 Uslovi za podršku mreži u uslovima kvara, za vetro turbine [26]

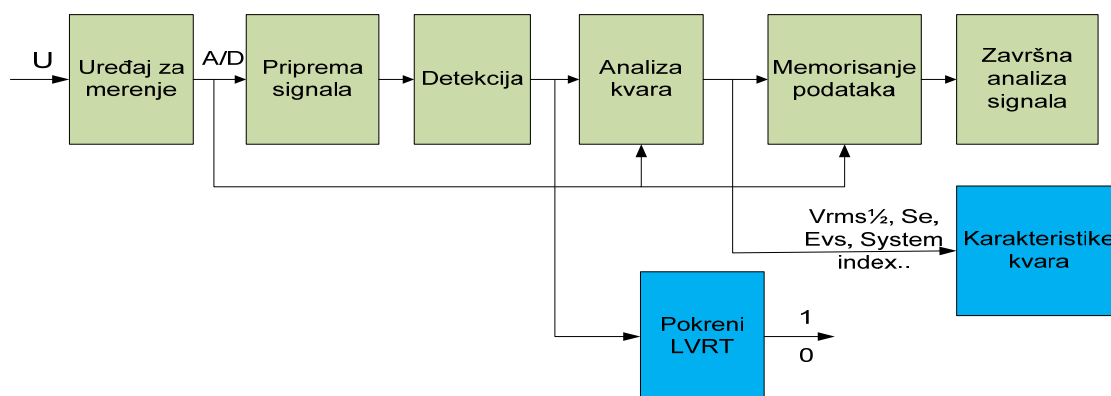
Moderne kontrolne metode za LVRT imaju integrisano upravljanje prekostrujnom zaštitom GTI-ja tokom kvara, podršku naponu u mreži generisanjem aktivne energije (P) ili reaktivne energije (Q) u skladu sa pravilima o radu distributivnog sistema, kao i kontrolu napona jednosmernog (DC) linka i ublažavanje oscilacija snage u cilju sprečavanja oštećenja kondenzatora u DC kolu [21,23,27–30]. U cilju da bi se ispunili svi zadaci koji se postavljaju pred kontrolu ovih uređaja energetske elektronike, kontrolni algoritam se u nekim aspektima deli u dva odvojena dela i na dva načina se konstruiše: kontrola u normalnom režimu rada mreže i kontrola tokom LVRT [31–37]. Kontrola koja je specijalizovana za rad u LVRT režimu počinje sa radom kada blok za detekciju da signal, kao što je prikazano na slici 1.7. Ovi algoritmi zahtevaju brz i pouzdan deo (blok za detekciju), koji je prvi korak i koji pokreće niz postupaka LVRT kontrolnog algoritma. U [23] je rečeno da kontrolni sistem invertora povezanog na mrežu treba da prebaci svoj način rada i kontrolu iz normalnog režima u LVRT režim što je pre ostvarivo, i da je zbog toga ključno da detekcija bude brza i pouzdana.



Slika 1.7 Pojednostavljena struktura DG sistema povezanog na mrežu, sa prikazanim blokom za detekciju i analizu propada napona

Detekcija i analiza (DIA) naponskih poremećaja je kompleksan skup radnji koji se može podeliti u nekoliko faza, U prvu fazu analize PN-a spada merenje mrežnih veličina. U zavisnosti od konkretne primene, vrste samih uređaja kao i opreme kojom se meri, merenje može obuhvatiti nekoliko dodatnih zadataka, kao što je promena broja odbiraka signala (sampling), primena različitih filtara u cilju otklanjanja šuma i smetnji iz signala, analogno/digitalnu konverziju, itd. Nakon ovoga, digitalni signal napona se analizira nekom od metoda, jer nije moguće izvršiti detekciju i analizu direktno iz signala [38]. Kao primer za detekciju propada napona u standardima IEEE 1564-2014 [5] i IEC 61000-4-30 [39] definisana je kao standard metoda RMS  $\frac{1}{2}$  periode, tj. definisano je da veličinu napona treba porediti sa RMS vrednošću izračunatu na signalu dužine cele periode, a da se računanje vrši u intervalima od pola periode. Kada se poremećaj detektuje, ova informacija se prosleđuje do kontrole invertora koji u skladu sa podatkom o stanju u mreži startuje LVRT i bira odgovarajući profil za proizvodnju snage [23].

Nakon detekcije iz signala treba izračunati parametar koji su potrebni za uspešan rad kontrole. Prvo se izračunavaju takozvani indikatori pojedinačnog poremećaja (single-event indices ili single-event characteristics). Ovi indikatori sadrže uglavnom neki vid amplitude napona (u slučaju propada dubinu) i trajanje. Najbitniji parametar koji određuje i formiranje referenci za podršku mreži je određivanje dubine propada. Pored ova dva osnovna indikatora, u zavisnosti od tipa poremećaja i metoda analize iz signala se dalje mogu estimirati drugi parametri kao što su fazni pomeraj, energija propada napona (voltage dip energy (Evs)), opasnost koju propad napona predstavlja (voltage dip severity (Se)), indeks sistema (parametar koji predstavlja kvalitet struje ili napona), različiti harmonici ili harmonijski spektri, vrsta i tip kvara, estimirana udaljenost mesta gde se meri signal do mesta gde se kvar dogodio, itd [38]. Dalje ovi parametri se mogu koristiti za dijagnostiku stanja u mreži, proračun dodatnih parametara ili uzroka nastajanja samog kvara, unapređenje kontrole ili u algoritmima za PQ klasifikaciju. Šematski prikaz klasičnog algoritma za detekciju i analizu je prikazan na slici 1.8.



Slika 1.8 – Šematski prikaz algoritma za detekciju i analizu poremećaja u mreži

Detekcija (segmentacija) i analiza poremećaja u mreži je takođe i prvi korak u algoritmima koji se bave detekcijom i klasifikacijom PQ poremećaja u mreži (PQ monitoring ili PQ klasifikacija). Kako su poremećaji napona najčešći i uobičajeno najteži PQ poremećaj, metod opisan u ovom radu se može koristiti i kao deo algoritma za detekciju i klasifikaciju PQ poremećaja u mreži. Moderni algoritmi za PQ monitoring uobičajeno se sastoje od nekoliko različitih algoritama, gde svaki algoritam je specifičan i ima svoju ulogu, kao što je detekcija propada i skokova napona, analiza harmonika, flikera, utvrđivanje lokacije kvara, analiza



događaja koji je doveo do kvara i klasifikacija, itd. Kako kompleksnost ES raste, povećava se i količina prikupljenih podataka koja se meri iz mreže, što čini detekciju i dalju analizu PQ poremećaja teško ostvarivim zadatkom za postojeće algoritme. Pametan algoritam za detekciju i određivanje ključnih parametara poremećaja u što kraćem vremenskom intervalu bi omogućio dalje unapređivanje svih pomenutih uređaja i algoritama.

Za sve prethodno navedene primere, za opremu koja služi za kompenzaciju PN (UPS, DVR, UPQC, itd.), kao i za kontrolne algoritme za LVRT kod DG-a i PQ monitoring metode, prvi korak u rešavanju i ublažavanju problema naponskih poremećaja, kao i drugih PQ poremećaja, je uspešna i brza detekcija. U sledećem koraku, nakon detekcije potrebno je odrediti osnovne parametre propada na osnovu kojih se formira dalja upravljačka strategija.

## 1.2 PREDMET I CILJ ISTRAŽIVANJA

Predmet istraživanja kandidata je fokusiran na problem kreiranja optimalnog algoritma koji bi sa velikom preciznošću, pouzdanošću i brzinom mogao da detektuje propade napona i estimira osnovne parametre kvara koji ga definišu, u kontrolnom kolu invertora povezanog na distributivnu mrežu koja sadrži obnovljive izvore energije. U ovakvim mrežama koje su uobičajene i predstavljaju realno stanje distributivnih mreža današnjice, uređaji energetske elektronike su veza ovih izvora sa mrežom. U budućnosti može se sa velikom sigurnošću očekivati značajan porast uređaja energetske elektronike u distributivnim mrežama, posebno kako se elektroenergetske mreže budu razvijale ka konceptu pametnih mreža (smart grids).

### **Hipoteza I:**

*Detekciju propada napona u savremenim distributivnim mrežama je moguće uraditi unutar vremenskog intervala od 1 ms, posmatrano od početka kvara u mreži. Ovo je moguće ispuniti korišćenjem harmonijske analize, konkretno praćenjem specijalno odabranog seta harmonika.*

### **Hipoteza II:**

*Na osnovu specijalno odabranog seta harmonika moguće je sa velikom statističkom sigurnošću ( $\geq 95\%$ ) predikovati dubinu propada napona tokom tranzijentnog perioda kvara.*

Predmet istraživanja je fokusiran na detekciju i osnovnu analizu propada napona posmatrano sa mesta integracije obnovljivih izvora u distributivnoj mreži, kao i unapređenje analize poremećaja korišćenjem različitih naprednih statističkih analiza i veštačke inteligencije (Artificial intelligence - AI), pre svega neuronskih mreža sposobnih za prepoznavanje složenih šablona. Da bi detekcija bila brza precizna i brza, dodatno je iskorišćena neuronska mreža koja omogućava praćenje oblika signala koji se javlja na samom početku nastanka kvara, i brže prenosi kroz mrežu nego promene u amplitudi napona. Način na koji je moguće ostvariti detekciju koja ispunjava ove uslove je koristeći analizu signala u realnom vremenu [38,40]. Analiza signala koja je predmet ovog rada će se obavljati u frekventnom domenu, a kao transformacija iz vremenskog u frekventni domen koristiće se Redukovana Furijeova transformacija (RFFT) koja je prilagođena upotrebi u energetici i delo je autora [41].

Harmonici napona su prisutni u mreži, u normalnom stanju, ali je veličina ovih harmonika ograničena [42]. Tokom trajanja kvara, posebno u tranzijentnom periodu, vrednost određenih harmonika je značajno uvećana, čak i po nekoliko desetina puta. Zbog toga, najčešće korišćene metode koje su prezentovane poslednjih godina svoj rad zasnivaju na harmoniskoj estimaciji. Poseban deo istraživanja je i određivanje optimalnog seta harmonika, kao i načina obrade i izdvajanja potrebnih parametara signala, koji u velikom broju slučajeva za različite propade napona daju sigurnu i brzu detekciju. Glavni deo istraživanja je formiranje napredne metode za detekciju propada napona, koja će biti maksimalno prilagođena i imati sve potrebne prednosti kako bi se detekcija propada u distributivnoj mreži, implementiranoj u kolo invertora povezanog na mrežu, mogla obaviti sa izuzetnom brzinom i pouzdanošću.

Metode za detekciju i analizu naponskih poremećaja u mreži imaju širok domen primene u različitim uređajima i metodama za analizu kvaliteta:

- Oprema koja je namenjena za kompenzaciju, ublažavanje ili rešavanje problema propada ili potpunog nestanka napona u mreži: UPS, DVR, UPQC, itd.
- Algoritmi namenjeni za PQ monitoring elektroenergetskog sistema
- Kao deo kontrole DG za podršku LVRT režimu rada.

U skladu sa prethodno navedenim primenama, osnovne karakteristike i zahtevi koje optimalne metode za detekciju i analizu naponskih poremećaja treba da ispuni su:

- Da metoda ima najveću moguću brzinu detekcije. Brzina je postignuta posmatranjem optimalnog seta harmonika koji svoju karakterističnu promenu ima pre nego što se propad u potpunosti razvije, tj. odabrani harmonici se brže prenose kroz mrežu nego što je to slučaj sa redukcijom amplitude napona.
- Da bude izuzetno precizna. Da bi se zadovoljila ova opcija koristi se deo koji se bazira na veštačkoj inteligenciji, Rekurentna neuronska mreža u kombinaciji sa LSTM.
- Da bude robusna. Da bi se obezbedila robusnost i mala mogućnost greške, pažljivo je odabran set propada na osnovu kojih je neuronska mreža obučena da prepozna početak propada. Za ovo su iskorišćena merenja iz stvarnih distributivnih mreža na nekoliko naponskih nivoa. Analizirano je ukupno 680 signala, od kojih 127 sadrže neku vrstu naponskih poremećaja, od kojih su 110 propadi napona. 10 karakterističnih signala sa propadima je odabrano za obučavanje neuronske mreže, i ukupno 100 prolaza i analiza kroz odabrani set signala je uradila neuronska mreža. Procenjena pouzdanost nakon obučavanja same neuronske mreže je 97.8 %, a nakon testiranja na realnim signalima iz mreže uspešno su detektovani poremećaji u 97.56% testiranih slučajeva [43].

Kao deo metode koja vrši detekciju i analizu, tj. kao druga hipoteza ovoga rada, pokazano je i da je moguće prilikom samog nastajanja poremećaja predvideti opasnost koju on predstavlja po ES i opremu, na osnovu toga što će se predvideti maksimalna dubina propada napona, tj. minimalni napon tokom propada (MNTP). Ovaj podatak može omogućiti različitim zaštitnim sistemima i sistemima za ublažavanje propada napona bolju reakciju i dodatno vreme za kontrolu od samog podatka o praćenju trenutnog stanja i vrednosti amplitude napona. MNTP je definisana u IEEE standardu 1564-2014 [5] kao minimalna vrednost RMS napona izračunatog RMS  $\frac{1}{2}$  metodom, koja je zabeležena tokom poremećaja.

### 1.3 STRUKTURA RADA

Rad je organizovan kroz 7 poglavlja od kojih svaka čini po jednu logičku celinu. Poglavlja se nastavljaju jedna na drugo, i zajedno prezentuju kompletan istraživački rad na razvoju pametne metode za detekciju i osnovnu analizu naponskih poremećaja, kao i opis i dokazivanje mogućnosti predikcije jednog od dva osnovna parametra propada, a to je dubina propada napona. U prvom poglavlju dat je opširan uvod u kratke spojeve i tematiku

naponskih poremećaja, sa posebnim osvrtom na propade napona i prekide napajanja, koji su i najčešći i najteži tip poremećaja koji može da se desi u ES. U ovom poglavlju date su i dve hipoteze na kojima se zasniva ovaj rad, kao i razlozi i moguće primene algoritama koji su opisani u ovom radu. U drugom poglavlju dat je opširan pregled literature sa originalnom klasifikacijom koja obuhvata sve najbitnije metode iz ove oblasti, kao i kritički osvrt na metode, i originalno poređenje većeg broja metoda u primeni kao deo distributivnih mreža sa distribuiranim generatorima. U trećem poglavlju dat je opis i promene koje su ključne za savremene distributivne mreže, koje su okruženje u kome su testirane metode predstavljene u ovom radu, kao i pregled najbitnijih distributivnih test mreža. U četvrtom poglavlju definisan je harmonijski otisak, jedinstveni harmonijski oblik koji se pojavljuje prilikom kvara u mreži, ako se posmatra specijalno odabran set nižih harmonika. U petom poglavlju data je primena harmonijskog otiska u kombinaciji sa Rekurentnom neuronskom mrežom za detekciju propada napona u savremenim distributivnim mrežama, zatim predstavljeni su rezultati ove metode za detekciju kao i njena evaluacija kroz definisanu kriterijumsku funkciju. U sledećem, šestom poglavlju predstavljena je mogućnost predikcije MNTP, na osnovu detaljne statističke analize i korišćenja harmonijskog otiska, dati su rezultati ove metode kao i algoritam za primenu. Sedmo poglavlje je zaključak, i ono sadrži i definisane pravce daljeg istraživanja. Posle toga je poglavlje literatura, zatim spisak publikacija autora i kao poslednje poglavlje su prilozi koji sadrže dodatne rezultate kao i principsko objašnjenje rada neuronskih mreža.

## **POGLAVLJE 2**

---

### **PREGLED STANJA U OBLASTI**

## 2.1 UVOD

U ovom poglavlju će biti prikazan detaljan pregled literature koja se tiče detekcije i analize PN kao i drugih poremećaja napona, sa najpoznatijim metodama koje su objavljene u relevantnoj naučnoj literaturi. Glavni akcenat biće stavljen na metode koje se zasnivaju na harmonijskoj estimaciji kao alatu za detekciju i analizu PN, kao i na metodama koje se baziraju na naprednim (pametnim) algoritmima, tj. sadrže neku vrstu veštačke inteligencije.

Kada vrednost napona opadne ispod 90% u odnosu na nominalnu vrednost napona smatra se da se dogodio propad napona. Standardni metod koji se koristi za detekciju propada napona je RMS (Root-mean-square) metod. Ovaj metod je standardizovan i već dugo godina se koristi u praksi [1]. Vreme koje je RMS algoritmu potrebno za detekciju propada napona je između 10 i 20 ms. Ova brzina detekcije nije uvek odgovarajuća zbog toga što se mreža razvila i dalje se ubrzano razvija sa novim tipovima opreme koji zahtevaju bržu reakciju.

## 2.2 PREGLED I KLASIFIKACIJA METODA ZA DETEKCIJU I ANALIZU POREMEĆAJA NAPONA

U oblasti koja se bavi detekcijom i analizom naponskih poremećaja objavljen je izuzetno veliki broj radova koji sadrže značajan broj različitih metoda i algoritama. Najveći broj ovih algoritama koristi neki vid obrade signala da bi izdvojio iz signala potrebne parametre, i dalje onda na bazi predodređene vrednosti sa kojom se poredi signal vršio detekciju poremećaja. Takođe, neki od algoritama koriste neka od metoda za praćenje oblika signala i napredno zaključivanje, tj. veštačku inteligenciju.

Pored detekcije, izdvojeni parametri signala se dalje mogu koristiti za određivanja parametara kontrole ili za klasifikaciju poremećaja kod metoda za PQ monitoring.

Ove metode se mogu podeliti u tri velike kategorije, kao što je prikazano na slici 2.1 na:

- Standardne metode,
- Metode bazirane na obradi signala i
- Metode bazirane na veštačkoj inteligenciji.

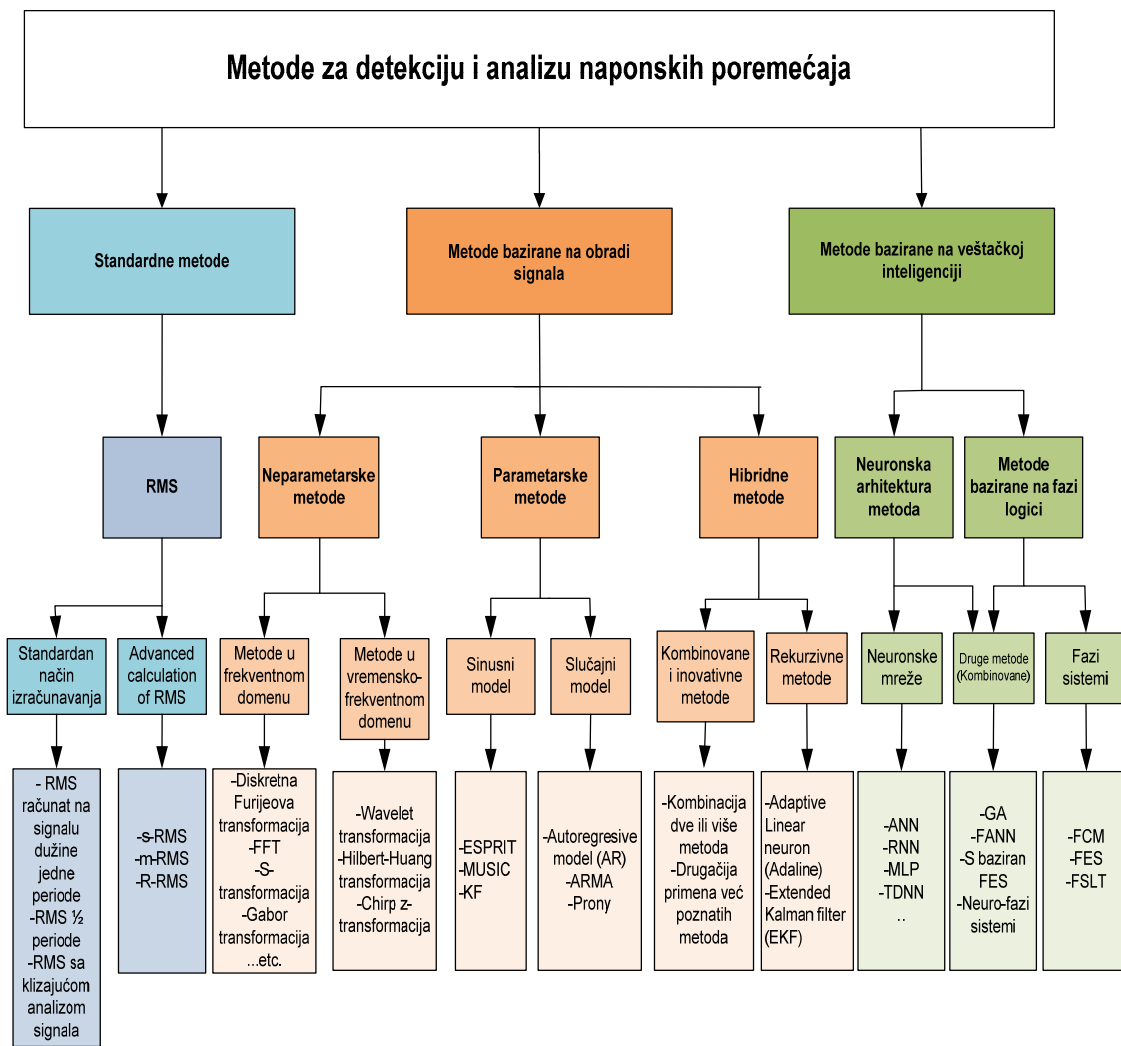
Kao osnov za merenje propada napona i drugih varijacija napona uzima se RMS vrednost napona [5,12,38]. Zbog toga RMS je najčešće korišćena metoda za detekciju i segmentaciju. Po IEC 61000-4-30 [12] standardu i IEEE standardu 1564-2014 [5] za detekciju propada

napona kao bazna metoda definisana je RMS metoda koja koristi dužinu signala od jedne periode, i poredi dobijenu vrednost sa predefinisanim granicom svakih pola ciklusa ( $\text{RMS } \frac{1}{2}$ ). Pored načina za proračun RMS koji su definisane standardima postoji i veći broj načina koji su istraženi u literaturi, i oni se mogu klasifikovati kao unapređen način proračuna RMS-a.

Harmonijska estimacija predstavlja izdvajanje komponenti signala u frekventnom domenu i izračunavanje njihovih amplituda i faznih uglova. Veliki broj metoda za harmonijsku estimaciju je razvijen i primenjen za detekciju propada napona.

Metode za harmonijsku estimaciju mogu se podeliti u dve velike klase, na parametarske i neparametarske metode. Neparametarske metode aproksimiraju, tj. izračunavaju harmonijski spektar direktno iz signala, obično u formi koeficijenata, koji se izračunavaju uz pomoć seta osnovnih funkcija. Parametarske metode koriste odgovarajuće modele koji predstavljaju signal i na osnovu njih se estimiraju parametri modela na osnovu poznatih vrednosti signala. Estimirani parametri se zatim uvrste u izabrani model da bi se izračunale harmonijske vrednosti, tj. harmonijski spektar. Pored ova dve klase, neki autori u klasifikaciju dodaju i treću grupu, hibridne metode. U ovu klasu spadaju metode koje koriste prednosti dve ili više metoda i objedinjuju ih u jednu metodu ili koriste postojeće metode na nov i inovativan način.

Treća grupa su metode koje mogu biti klasifikovane kao skup metoda kojima je zajednička osobina da koriste neku formu veštačke inteligencije za zaključivanje ili za praćenje određenog oblika ili šablona u signalu. Poređenje nekog od parametara napona ili struje, kao što su vrednost RMS-a, ili vrednost osnovnog harmonika napona sa odabranom graničnom vrednošću (najčešće 0.9 p.u. za RMS i prvi harmonik) su kod ovih metoda zamenjene praćenjem kompleksnih šablona u vremenskom ili u harmonijskom domenu ili modelima koji se obučavaju i uče na konkretnim primerima onoga što se želi analizirati. Uobičajeno, kod ovih metoda se koriste neuronske mreže (NN) ili fazi logika (FL) u cilju unapređenja sposobnosti detekcije i analize kvara.



Slika 2.1 – Klasifikacija metoda za detekciju i analizu naponskih poremećaja

### 2.3 STANDARDNE METODE

Naponski signal ne može biti direktno iskorišćen za detekciju ili klasifikaciju događaja i poremećaja u ES. Zbog toga jednostavna i najčešće korišćena metoda je bazirana na direktnom proračunu RMS vrednosti napona iz sinusnog oblika napona, kao što je prikazano u (2.1).

$$V_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N v_i^2} \quad (2.1)$$



gde je  $N$  broj uzoraka (vrednosti) signala nad kojim se vrši proračun a  $v_i$  je vrednost  $i$ -tog uzorka signala napona.

Takođe vrlo čest pristup je baziran na izračunavanju amplitude osnovnog harmonika napona. Na osnovu ove vrednosti zatim se može izvršiti DIA poremećaja.

Najbitniji parametar kod RMS metoda je dužina signala koji se obrađuje, kao i učestanost sa kojom se proračun vrši. Na primer, RMS koji se izračunava na osnovu dužine signala od pola periode ima bolju preciznost ali izračunata vrednost ima veće oscilacije u poređenju sa RMS metodom koja računa sa dužinom signala od jednog celog ciklusa [38]. U IEEE [5] i IEC [39] standardima je definisana metoda  $V_{\text{rms}1/2}$  - kao proračunata vrednost RMS napona korišćenjem signala dužine jedne periode, a gde se rezultat ponovo računa svakih pola periode. U radu [44] različiti načini proračuna RMS su opisani i predstavljeni, koristeći fiksnu dužinu signala ali sa različitim vremenskim periodima (s-RMS), zatim pokretna tehnika koja sadrži usrednjavanje signala (m-RMS) ili konačan impulsan odziv (rekurzivno pokretno usrednjavanje - r-RMS) [44].

Pored kašnjenja u detekciji, nemogućnosti izračunavanja precizne amplitude i dužine trajanja poremećaja, posebno za kratke kvarove, nemogućnosti izračunavanja faznog pomeraja pri poremećaju kao ni tačke na sinusoidi signala gde se poremećaj dogodio (point-on-wave) su loše stvari RMS metode, koje doprinose da u međusobnim poređenjima sa drugim metodama RMS uvek zauzima poslednje mesto.

## **2.4 METODE BAZIRANE NA OBRADI SIGNALA**

Metode za analizu i detekciju naponskih poremećaja obuhvataju različite tipove metoda koje koriste transformacije kao osnov za svoj rad. Dalje ove metode u zavisnosti od tipa transformacija koje se koriste se mogu podeliti na neparametarske, parametarske i hibridne metode.

### **2.4.1 Neparametarske metode**

Neparametarske metode izračunavaju harmonike direktno iz signala. Ovakav način proračuna i estimacije harmonika je računski daleko jednostavniji i zahteva dosta manje računskih operacija. Iz tog razloga, neparametarske metode su daleko jednostavnije za

implementaciju i korišćenje a i cena implementacije je niža u poređenju sa parametarskim i hibridnim metodama.

Neparametarske metode obuhvataju dve podgrupe, metode koje rade analizu signala u frekventnom domenu i one koje rade analizu signala u vremensko-frekventnom domenu. Transformacije koje pretvaraju signal iz vremenskog u frekventni domen su bazirane na Furijeovoj transformaciji, tj. jednoj varijaciji ove transformacije koja je pogodna za izračunavanje za mikroprocesore, a to je Diskretna Furijeova transformacija. U ovu grupu spadaju i druge metode koje se baziraju na Furijeovoj transformaciji, kao što su , FFT, STFT, DFT i algoritam razvijen od strane autora – Reduced Fast Fourier Transform – RFFT [45].

Furijeova analiza zbog svoje dokazane preciznosti, pouzdanosti i jednostavnosti je dominirala u oblasti obrade signala od svog pojavljivanja. Primenjena je u svim oblastima analize signala, kao i mnogim oblastima inženjerstva. Ovaj metod je dugo godina u upotrebi, ali u poslednje vreme ponovo je u fokusu i nalazi nove primene. Diskretna Furijeova transformacija se računa kao što je predstavljeno u (2.2).

Brza Furijeova transformacija je osnovni alat kojim se postiže harmonijska estimacija, tj. koja omogućava izračunavanje amplitude i faznog ugla harmonika koji su prisutni u signalu. Brza Furijeova transformacija je samo jedan način izračunavanja Furijeove transformacije, koji je pogodan za primenu u računarima. Primena u poboljšanju kvaliteta električne energije [46] kao i u modernim tehnologijama, kao što je detekcija propada napona u elektroenergetskoj mreži koja sadrži distributivne izvore energije [47], pokazala je veoma dobre rezultate koji omogućavaju i dalja unapređenja u ovim oblastima. Direktna proračun ove transformacije zahteva  $N \cdot \log N$  operacija. Osnovna formula za proračun FT u diskretnom domenu je:

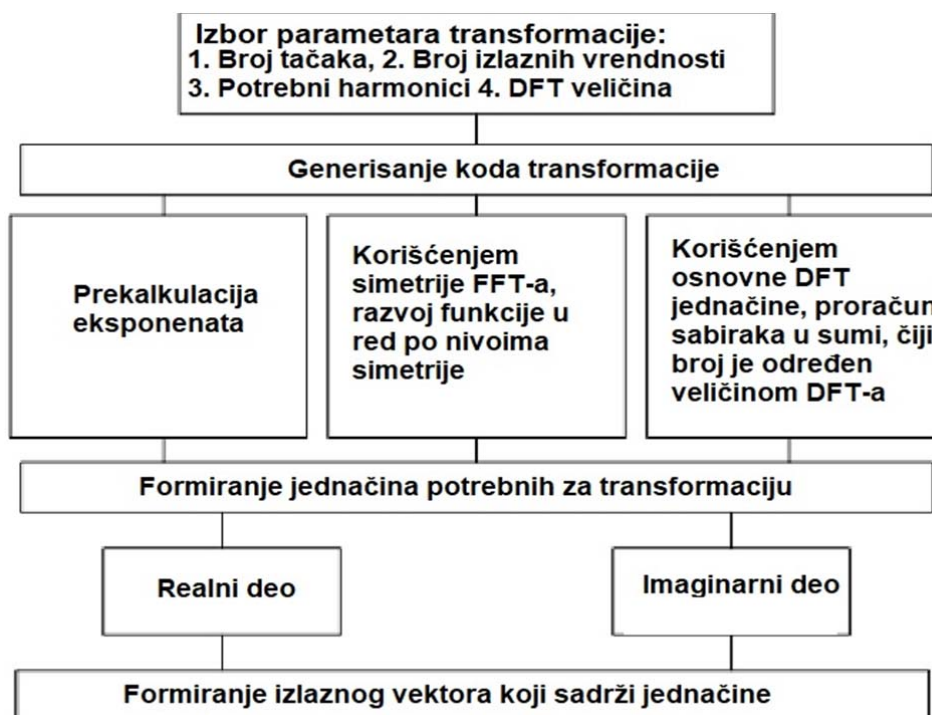
$$X_k = \sum_{n=1}^N x(n) e^{-jkn/N} \quad (2.2)$$

za  $k=1, 2, 3, \dots, N$ .

U ovoj formuli  $n$  je  $n$ -ti uzorak signala,  $N$  je veličina, tj dužina vektora signala koji se analizira i  $k$  je indeks frekvencije, tj. harmonik. Veličina izlaznog vektora koji sadrži za svaku izračunatu frekvenciju po jedan vektor sa dva člana (amplituda i fazni stav) jednaka je dužini

ulaznog vektora signala koji se analizira. Furijeova transformacijama ako su ispunjeni uslovi za njenu primenu daje vrlo precizne rezultate. Preporučeni uslovi za primenu su linearnost i da je signal periodičan ili stacionaran, i u tim slučajevima klasična Furijeova transformacija daje vrlo dobre rezultate. Ukoliko ovi uslovi nisu ispunjeni, moguća je pojava određene greške usled efekta senke (aliasing), efekta curenja (leakage), itd.

Rad [47] je originalni rad autora u kome su pokazane vrlo dobre sposobnosti algoritama baziranih na Furijeovoj transformaciji u primeni za detekciju propada napona. Takođe, Redukovana Brza Furijeova transformacija – RFFT se pokazala kao vrlo brza i pouzdana metoda sa boljim rezultatima od FFT. Kod ove metode moguće je izračunavanje samo harmonika koji su potrebni u proračunu, bez računanja celog frekventnog spektra, i takođe izbegnuta je rekurzivnost. Ovo omogućava direktno izračunavanje harmonika iz signala. Izračunavanje samo odabranih frekvencija moguće je i uz pomoć Goertzel algoritma, ali ovaj algoritam i dalje ima rekurziju, tj petlju u proračunu, dok je RFFT izražen kao proračun niza, što ima velike prednosti kada su primene u realnom vremenu u pitanju. Blok šema koja predstavlja način proračuna RFFT metode je predstavljena na slici 2.2, dok je broj računskih operacija potreban za proračun RFFT-a dat u (2.3).



Slika 2.2 Algoritam za formiranje RFFT metode

$$N_0 = H \left[ 2^{(L-S)} D_s + \sum_{i=0}^{L-S} 2^i \right] \quad (2.3)$$

Gde je  $N_0$  računaska kompleksnost,  $N$  je dužina signala koji se analizira,  $D_s$  je veličina DFT bloka za proračun (broj sabiraka na koje se DFT direktno primenjuje),  $H$  je broj harmonika koje je potrebno izračunati i  $L$  i  $S$  su definisani kao  $L = \log_2 N$ , and  $S = \log_2 D_s$ .

Mane klasične FFT su detaljno istražene i objašnjene u literaturi [38,48]. Da bi se mane prevazišle, veliki broj algoritama baziranih na FFT-u je razvijen. Ove metode koriste "windowing" [49–53], interpolaciju [54–58], sinhronizaciju [59–63], i još neke postupke opisane u [64]. Takođe, pojavile su se i neke nove neparametarske metode koje su pokušale da nadomeste i isprave nedostatke koji su primećeni kod FFT – a to su: Wavelet Transform [65,66] i Hilbert–Huang Transform [67].

Potrebno je ovde se zaustaviti i naglasiti da mane koje su primećene, kao i naknadno razvijene metode, odnose se na specifične oblasti primene algoritama. U detekciji propada napona, sama preciznost algoritma da sa izuzetnom tačnošću izračuna određeni harmonik, ili neki frekvencijski spektar, nije od ključne važnosti. Ono što je najbitnije je da sa onim harmonikom koji pratimo, ili delom spektra, možemo brzo da detektujemo propad napona, da li kroz rast vrednosti ili brzinu promene. Manje greške u amplitudi koje mogu nastati u tranzijentnim režimima mogu biti relevantne kod nekih drugih oblasti poput analize signala i analize kvaliteta električne energije. Iz ovog razloga, pored velikog broja metoda, od kojih dosta ima određenu prednost u nekoj od aplikacija, postoji i veliki broj načina primene samih metoda, što će biti naknadno diskutovano.

Na slici 2.1 podela metoda za estimaciju harmonika je prikazana sa daljom podelom u još tri podgrupe, u koje se mogu svrstati i sve napredne metode koje su razvijene do sada, a koju je izvršio autor, delom po ugledu na poznate sistematizacije i klasifikacije od ranije opisane u [38,65]. Ova nova podela, kao i jedan deo pregleda literature prikazan u ovom radu, je predstavljen u radu autora [68].

Wavelet transformacija (WT) je jedna od najčešće korišćenih metoda za DIA-u propada napona, prekida u napajanju, kao i drugih PQ poremećaja. WT je takođe metoda koja se vrlo često koristi i kao deo kompleksnih algoritama za PQ monitoring. Za razliku od FT, koja daje globalnu estimaciju vrednosti harmonika kao vektora, WT računa lokalnu vektorsku

estimaciju u oba domena, i vremenskom i frekventnom. Zbog ove osobine WT je pogodan za analizu signala gde je potrebno precizno odrediti vremensko-frekventne parametre signala, kao što su tranzijentne promene nakon nastanka različitih PQ poremećaja u distributivnim mrežama [69]. Ova transformacija se može interpretirati kao set filtera, od kojih svaki sledeći ima povećan opseg. Diskretna WT se može izračunavati kao što je prikazano u (2.4).

$$F_{ij} = L^{-j/2} * \sum_{n=0}^N f_n * \omega * \left(\frac{n-i}{L^j}\right) \quad (2.4)$$

Gde je  $v_i$  digitalni signal napona,  $F_{ij}$  je matrica koja se sastoji od  $v_i$ ,  $j$  je nivo dekompozicije,  $i$  indeks opsega,  $L$  je dilatacioni parameter translacije (za Dyadic wavelet je jednak broju 2),  $N$  je broj uzoraka,  $\omega$  je vrednost kompleksne konjugacije i  $n$  je  $n$ -ti uzorak signala [38].

U najvećem broju radova gde je WT primenjen, koristi se najviši frekventni opseg za detekciju naglih promena [38]. U radu [70] metoda bazirana na WT za DIA-u naponskih poremećaja je predstavljena. WT je iskorišćena za detekciju i za izdvajanje potrebnih parametara iz signala, dok je dalja obrada i klasifikacija poremećaja urađena sa NN. Glavna mana WT je to što centralne frekvencije svakog od opsega je teško podesiti da budu baš željeni harmonici koje je potrebno izračunati iz signala. Ova mana utiče na to da WT nije najbolji izbor za analizu poremećaja kada je harmonijski spektar u pitanju. Takođe pokazano je da detekcija sa WT metodom, iako može postići izuzetnu brzinu, je podložna smetnjama, šumu u signalu i lošem kvalitetu merenog signala [71–73].

S-transformacija predstavlja modifikovanu verziju WT, tj. može se tumačiti i kao generalizacija STFT. Transformacija se bazira na skalabilnoj lokalizaciji Gaussian prozora (window) i obezbeđuje rezoluciju signala koja je zavisna od frekvencije. Ova transformacija je pokazala dobre rezultate u primeni kod algoritama za analizu i klasifikaciju PQ poremećaja. U radu [74] su predstavljeni rezultati poređenja WT i S-transformacije i zaključeno je da je S-transformacija pokazala bolje rezultate u oblasti detekcije i analize PQ poremećaja nego WT. S-transformacija koja kombinuje ovu metodu sa metodom baziranom na veštačkoj inteligenciji za detekciju ostvarila je dobre rezultate u [75], i u ovom radu je zaključeno da S-transformacija ima veliki potencijal u oblasti analize i klasifikacije. Ali u oblasti detekcije pored toga što zahteva dodatnu metodu za ostvarivanje dobrih rezultata, WT

ima vizuelno jasniju predstavu početka i kraja kvara, i u signalima koji sadrže šum WT se pokazao kao bolje rešenje.

U literaturi se može naći poređenje različitih neparametarskih metoda sa drugim metodama u različitim oblastima primene- U [76] upoređene su dve metode, FFT i RFFT. Obe metode prikazale su dobre rezultate u detekciji propada napona, i uspešno su u svim slučajevima detektovale različite propade. FFT metoda je estimirala i pratila prvi (osnovni) harmonik, dok je RFFT pratio treći harmonik napona. U radu [77], nerekurzivna adaptacija FFT metode je primenjena i upoređena sa waveletom i jednom hibridnom metodom – Kalman filtrom. U ovom radu je pokazano da Kalman filtra i algoritmi bazirani na Furijeovoj transformaciji su u stanju da reaguju, tj. da detektuju dubok propad napona za 1 ms, dok za manje propade napona je potrebno do 4 ms. Zaključeno je da je ova brzina prihvatljiva i zadovoljava potrebe koje su potrebne uređajima za ublažavanje propada (“mitigation devices”), jer propadi koji imaju najveći propad amplitude se najbrže detektuju, što je ključna osobina kod ovih primena. Popularna RMS metoda je pokazala loše rezultate. Wavelet je imao problema sa šumom i komponentama na visokim frekvencijama, i nije pokazao dobre rezultate [77]. U [78] poređene su RMS, STFT, Unapređeni Kalmanov filter i wavelet metode. Zaključeno je da RMS i STFT uvek imaju kašnjenje prilikom detekcije propada napona. Takođe ove dve metode pokazale su ograničene mogućnosti za detekciju kod kratkih propada i propada kod kojih amplituda malo opadne. Unapređeni Kalman filter je pokazao dobre performanse kako u detekciji propada napona tako i u estimaciji dubine i vremena trajanja propada napona. Na kraju, wavelet je pokazao najbolje rezultate u detekciji i u estimaciji vremenski promenljivih parametara propada napona, ali zbog korišćenja najvišeg frekvencijskog spektra uz wavelet transformaciju potrebno je koristiti dodatnu pomoćnu metodu da bi se razlikovali propadi napona od ostalih visokofrekventnih promena. U [79] STFT, RMS i High pass filter (HPF) metode su upoređene. U ovom radu je STFT je pokazao bolje performanse u detekciji a i precizniji je u vremenskoj lokalizaciji propada u odnosu na RMS i High pass filter. U [80] STFT i WT su upoređeni. U ovom radu je zaključeno da obe metode imaju svojih prednosti i mana. "Dyadic wavelet" filteri nisu pogodni za harmonijsku analizu signala propada napona. Frekvencije oko kojih su centrirani izdvojeni delovi spektra su nefleksibilni i dobijeni rezultati ne daju informaciju o tome kako se harmonici menjaju u vremenu. Sa druge strane, STFT ima dobru aproksimaciju harmonika i zbog toga je korisniji u analizi signala u energetici. Sa pravilno izabranom širinom koraka (window size) diskretni

STFT je takođe u stanju da detektuje i analizira tranzijent tokom kvara. Generalno, zaključak ovog rada je da je STFT pogodniji za primenu u analizi signala propada napona nego WT.

U [81] predstavljeno je poređenje rada algoritma baziranog na simetričnim komponentama i šestofaznog algoritma, primenjeno u oblasti analize i klasifikacije nebalansiranih propada napona. Metod simetričnih komponentata određuje vrstu propada uz pomoć pozitivnih i negativnih simetričnih komponentata. Šestofazni algoritam nakon proračuna naonske komponente nultog redosleda, računa tri RMS vrednosti napona iz tri fazna napona i tri među-fazna napona. Na osnovu ovih vrednosti izračunava parametre kvara direktno, karakteristična vrednost propada je najniža vrednost koja je izračunata u svih 6 signala, dok je PN faktor najviša vrednost u svih 6 signala. Šestofazni algoritam je imao problem sa klasifikacijom plitkih propada napona, koje je najčešće pogrešno klasifikovao, kao i srednje duboke propade sa velikim faznim pomerajem, dok metod simetričnih komponenti je imao problema kod velikih rotacija u PN-faktoru propada.

Hilbert–Huang transformacija (HHT) je metoda za analizu signala koja se sastoji iz dve različite transformacije. Prva je Empirijska dekompozicija a druga je Hilbertova transformacija. Ova metoda se vrlo često koristi u oblasti detekcije i klasifikacije, kao deo metoda za PQ monitoring. U radu [82] HHT transformacija je primenjena za analizu poremećaja i izdvajanje parametara potrebnih za klasifikaciju uz pomoć NN, i rezultati ove metode su upoređeni sa rezultatima S-transformacije i WT. HHT je u ovom radu pokazala najbolje performanse.

Chirp z-transformacija nije pogodna za detekciju propada napona, može se koristiti za analizu, ali nije prihvaćena u većem broju radova ni u kakvoj primeni u oblasti PQ poremećaja [83].

#### **2.4.2 Parametarske metode**

Parametrijske metode koriste odgovarajući model da predstave signal i zatim da estimiraju parametre signala. One su pogodne za primene gde je preciznost proračuna bitnija od brzine proračuna [40], pa iz ovog razloga one najčešće nisu najbolja opcija kada je detekcija propada napona u pitanju. Ipak, ove metode mogu biti pogodne za primenu kada je određivanje kvaliteta električne energije u pitanju. Kako u ovom radu to nije primarno, ove metode će ukratko biti objašnjene, gde će naglasak biti dat na određenim parametarskim

metodama koje ipak imaju značajniju primenu i ostvaruju dobre rezultate u detekciji propada napona.

Autoregressive model (AR) je korišćen u radu [84] za DIA-u tranzijenta prilikom različitih pojava u mreži, između ostalih kvarova i propada napona. Ova metoda je pokazala obećavajuće rezultate za analizu signala poremećaja u ES, ali dalje istraživanje primene u oblasti analize PQ poremećaja je potrebno da bi se u potpunosti sagledale njene mogućnosti.

Autoregressive Moving Average (ARMA), WT i AR su primenjeni i upoređene su im performanse u [85], kao algoritmi za DIA-u propada napona. Oba algoritma se nisu dobro pokazala kada je detekcija propada napona u pitanju. Oba algoritma su pokazala slične rezultate u oblasti detekcije i analize, a WT je pokazao najbolje rezultate u ovom radu.

Kalman filter (KF) može biti uspešno primenjen kao algoritam za DIA-u propada napona i drugih PQ poremećaja [39, 40]. U nekim specifičnim slučajevima primene KF se čak pokazao kao najbolji izbor, posebno za detekciju i segmentaciju poremećaja [77]. MUSIC, ESPRIT i Prony metode takođe nisu pogodne kao optimalan izbor algoritma za detekciju propada napona [54, 55]. Ipak, u [54], Prony metoda kombinovana sa wavelet-om može da da dobre rezultate i može se koristiti za identifikaciju kvarova i poremećaja u mreži.

Za parametarske metode generalno može se zaključiti da su pogodne za primene u slučajevima kada je bitnije da se izdvoje i posmatraju harmonici ili interharmonici stacionarnih signala. Ipak, više iskustva i istraživanja je potrebno da bi se ove metode uspešno procenile, kao i njihov značaj u oblasti detekcije i segmentacije kvarova, kao i u oblasti analize signala i estimacije harmonika.

### 2.4.3 Hibridne metode

Hibridne metode su klasifikacija koja je nastala i prepoznata kao potreba određenih autora da se metode koje se ne mogu klasifikovati kao parametarske ili neparametarske uključe u sveobuhvatnu klasifikaciju. Ove metode su uglavnom nastale kao pokušaj da se prevaziđu poznati problemi neke od najpoznatijih parametarskih i neparametarskih metoda. Algoritmi koji su razvijeni u novije vreme u većini slučajeva se mogu svrstati u hibridne, sa tim izuzetkom da je u ovom radu posebno izdvojena klasa metoda koje su bazirane na nekom vidu veštačke inteligencije i donošenja zaključaka. Kod nekih autora [40] klasom hibridnih metoda su obuhvaćene i metode bazirane na AI. Kao što je prikazano u [68] i na slici 2.1 autor je smatrao da je postojeću klasifikaciju moguće proširiti na vrlo logičan način, tako da i



novorazvijene metoda imaju svoje mesto u skladu sa osobenostima koje ih karakterišu. Ova podela je na dve pod-klase hibridnih metoda:

- Metode nastale kombinacijom dve ili više metoda i algoritmi koji primenjuju postojeće metode na novi način,
- Rekurzivne tehnike.

U [86] nova metoda za poboljšanje detekcije i analize PQ poremećaja koja koristi kombinaciju dve metode, WT i predobrade signala metodom pokretnog prozora (sliding window). WT je korišćena za detekciju i pokazala je dobre rezultate sa ovim unapređenjem, čak i za signale koji su imali šum. Ipak u radu fali analiza pouzdanosti metode, kao i tačna vremena potrebna za detekciju.

Poboljšana Kalman metoda (Extended Kalman filter - EKF), koja je napravljena da prevaziđe određene probleme originalnog Kalman filtera, inijene performanse u oblasti detekcije i analize u ES je prikazana u [87]. U ovom radu je takođe EKF metodi pridodata i WT metoda i Fazi ekspert sistem kako bi se dobili bolji rezultati. Pouzdanost veća od 90% je ostvarena, kao i relativno niska računaska zahtevnost i cena implementacije.

Inovativna kombinacija metoda koja kombinuje metodu najmanjih kvadrata (least square) sa ADALINE metodom je predstavljena u [88]. Osobenost ovog algoritma se ogleda u tome što se analiza odvija odvojeno, kao linearni problem koji se analizira sa metodom najmanjih kvadrata i nelinearni za koji se koristi ADALINE. U poređenju sa EKF algoritmom ovaj metod je pokazao bolje rezultate.

Algoritmi za detekciju propada napona bazirani na WT koriste detaljni koeficijent za najviši frekvencijski spektar. Drugačiji i originalni pristup detekciji propada napona je predstavljen u [89]. U ovom radu korišćeni su energetski koeficijenti wavelet transformacije. U radu [90] hibridna diskretna wavelet transformacija je razvijena sa idejom da se dobije metoda koja može uspešno i brzo da detektuje brze promene u signalu napona. Ovaj algoritam kombinuje dve vrste WT matičnih wavelet-a, .Daubechies sa dva filter koeficijenta (Daub2) i Daubechies sa 8 filter koeficijenata (Daub8.). Ova kombinacija donela je poboljšanje u detekciji i analizi propada u odnosu na klasično korišćenje WT.

Adaptivni filter koji se koristi za odvajanje šuma iz signala, poznata kao ADALINE je metod koji se najčešće koristi za prepoznavanje i identifikaciju modela, kao i za linearizaciju [91]. U radu [85] je pored već spomenutih ARMA, WT i AT metoda predstavljeno poređenje

ADALINE, RMS i High-pass filtera u cilju što brže i preciznije detekcije propada napona. Pokazano je da i ADALINE metoda, kao i RMS nije precizna. Zaključeno je da adaptivne metode generalno nemaju dobre rezultate ako se koriste za detekciju i segmentaciju, a objašnjenje ovoga je da konvergencija koja je povezana sa parametrima učenja algoritama ometa vremensku lokalizaciju, tj. brzinu i preciznost [85].

## 2.5 METODE BAZIRANE NA VEŠTAČKOJ INTELIGENCIJI

Ova grupa metoda obuhvata metode koje su razvijene u najvećoj meri u tekućoj deceniji, i koje se intenzivno razvijaju i usavršavaju. Sa napretkom i ubrzanim razvitkom računarskih nauka, kako hardvera tako i softvera, napredne metode iz računarskih nauka su počeli da se koriste i u ostalim oblastima, pa i u detekciji i analizi PQ poremećaja. Dve najzastupljenije grupe metoda su neuronske mreže i fazi logika.

Neuronske mreže su algoritmi koji su inspirisani nervnim sistemom. To je u stvari mreža međusobno povezanih elemenata koji vrše prostu obradu podataka (čvorovi), a ovi elementi se najčešće nazivaju neuroni. Oni omogućavaju neuronskoj mreži da se adaptira na različita stanja i uslove tokom rada, da pamte šablone koji im se zadaju i kasnije ih prepoznaju kao i da unapređuju ove šablone i mogućnost zaključivanja tokom samog rada [92]. NN imaju široku oblast primene u predikciji, praćenju šablona, fitovanju, upravljanju bazama podataka, itd. Takođe se koriste za rešavanje problema u oblasti ES u planiranju ES [93], detekciji, analizi i klasifikaciji PQ poremećaja [91], utvrđivanju kvara unutar uređaja energetske elektronike [94], naprednim metodama merenja, kontroli snage [95], PQ analizi [96], itd.

U [97] metoda za DIA-u poremećaja u naponu, bazirana na HHT i FL je predstavljena. HHT metoda je iskorišćena kao deo algoritma koji estimira parametre signala koji se dalje prosleđuju u FL, a FL zatim prati i donosi zaključke o tipu poremećaja. Kao dodatni i konačni algoritam za klasifikaciju iskorišćeno je i zaključivanje na osnovu unapred utvrđenih pravila (rule-based). Izlaz ove metode je klasifikacija na osnovu IEEE 1159 standarda. Deo metoda koji se koristi za DIA-u ima malu računsku kompleksnost kao i nisku cenu implementacije, ali celokupna metoda ipak u tom smislu se mora posmatrati kao srednje zahtevna. Takođe ova metoda nije testirana za višestruke i komplikovane poremećaje, kao ni za slučajeve kada je prisutan šum u signalu. U normalnim uslovima pokazala je dobre performanse, ali u normalnim uslovima se mogu iskoristiti i mnogo jednostavnije metode koje bi ostvarile sličan učinak.

U radu [22] prikazani su rezultati metode bazirane na modularnoj NN sa verovatnoćama (modular probabilistic neural network - PNN) kao i vektorske mašine (support vector machine). Kao metode za DIA-u poremećaja, tj. pripremu signala za analizu sa pametnim metodama iskorišćeni su WT i S-transformacija. S-transformacija je pokazala bolje rezultate u oblasti detekcije i analize od WT, dok su obe metode, i modularna NN i vektorska mašina ostvarile slične, dobre rezultate.

Metoda za detekciju, klasifikaciju i utvrđivanje mesta na kome je nastao kvar u distributivnoj mreži je predstavljena u [96]. Ova metoda kombinuje nekoliko algoritama koji imaju različite zadatke, WT kao i multirezolucionu analizu (MRA), kombinaciju fazi i neuronske mreže (Fuzzy-ARTMAP Artificial Neural Network) kao i klasične neuronske mreže za analizu kratkih spojeva, i analizu na bazi različitih parametara koja utvrđuje lokaciju samog kvara. Kontinualan proračun detekcije je ostvaren, dok drugi proračuni se odvijaju sa zadržkom. Metod je testiran i ostvario je dobre rezultate u klasifikaciji. Svi delovi ove metode kao i kompletna metoda su izuzetno kompleksni i zahtevni u računskom smislu.

Metoda koja vrši klasifikaciju za 11 različitih predefinisanih tipova poremećaja, kao i obavlja detekciju je predstavljena u [98]. U ovom radu detekcija, izdvajanje potrebnih parametara (4 parametara se koriste za analizu i klasifikaciju) iz signala i deo analize se obavljaju prvenstveno putem S-transformacije, dok se klasifikacija obavlja sa naprednim tipom neuronske mreže PNN. Takođe u ovom radu je i PNN upoređena sa poznatim NN, kao što su “feedforward multilayer back propagation” (FFML) i “learning vector quantization” (LVQ) neuronska mreža. Pouzdanost LVQ je 90%, FFML 98% dok je pouzdanost PNN skoro savršenih 99.6%. Predstavljeni rezultati su ipak rezultati dobijeni kompjuterskim simulacijama. Mana ovih metoda je što detekcija kao i klasifikacija i analiza imaju vidljivo kašnjenje. WT metoda je imala problem sa detekcijom u slučajevima kada u signalu postoji šum, dok korišćenje S-transformacije i PNN-a je dalo dobre rezultate i u ovim uslovima.

Metoda za DIA-u naponskih poremećaja bazirana na KF, WT i fazi ekspert sistemu je predstavljena u [87]. KF i WT metoda imaju ulogu detekcije i segmentacije kvara, kao i analize signala i estimacije potrebnih parametara (amplitude, različitih harmonika, itd.), dok fazi ekspert sistem vrši klasifikaciju. Osnovna metoda koja se koristi je KF, dok WT je dodat da ubrza i poboljša rezultate KF. Pokazano je da ova metoda može da detektuje, izdvoji glavne karakteristike poremećaja i klasifikuje ih sa velikom pouzdanošću i preciznošću čak i u slučaju kompleksnih višestrukih poremećaja.

U [99] metoda koja kominuje fazi logiku sa optimizacijom putem roja čestica (particle swarm optimization - PSO). Kao algoritmi za analizu i pripremu signala su korišćeni DFT i WT, i zatim izlaz ova dva algoritma je prosleđivan do PSO i FL. Ovaj inovativan algoritam pokazao je da ima sposobnost da detektuje i klasifikuje pojedinačne i višestruke poremećaje. Fazi sistem obavlja detekciju i utvrđuje potrebne parametre bazne funkcije koja je potrebna PSO algoritmu. PSO dalje kao nastavak FL metode vrši klasifikaciju. Metod je u simulacijama pokazao dobre rezultate, i u slučajevima kada u signalima ima šuma. Algoritam ima problem sa učenjem, a zbog toga i kod samog korišćenja, jer nije moguće ga koristiti za detekciju i klasifikaciju svih poremećaja koji se mogu pojaviti u mreži.

## 2.6 KRITIČKA ANALIZA POSTOJEĆIH METODA

Poređenje metoda u literaturi i pregledi su prikazani u [36,100–105]. Ovi pregledi daju generalan pregled literature sa ocenjivanjem na bazi rezultata koji su autori predstavili u datim radovima i gde uslovi testiranja ni približno nisu isti. Takođe u najvećem broju slučajeva većina testova je obavljena u kompjuterskim simulacijama. Primećeno je da za savremene metode ono što predstavlja izazov su testiranje u uslovima kada u signalu ima šuma (što odgovara distributivnim mrežama sa DER, gde šum predstavljaju harmonici), kao i detekcija i analiza višestrukih poremećaja [36,98–100].

Zbog načina poređenja gde se metode porede u različitim uslovima i na različiti način, rezultati i poređenja sličnih ili istih metoda koje su u svojim radovima predstavljali različiti autori su u nekim slučajevima davali suprotne rezultate. U radovima [79,80] je zaključeno da STFT je bolji izbor za detekciju i analizu nego RMS, WT i HPF. Suprotan zaključak od ovog je prikazan u [106–109] gde STFT se nije pokazao bolje od WT. A dijametralno suprotno od prethodno pomenutih radova, u [78] je pokazano da EKF je bolja metoda u ovim primenama i od STFT i od WT baziranih metoda za detekciju i analizu. Zatim u [46] su rezultati pokazali da i FFT i STFT se sa velikom uspešnošću mogu koristiti za harmonijsku analizu poremećaja, kao i da kombinacija ovih metoda je dobar izbor za PQ monitoring. A u radovima [47,77] WT metoda se pokazala najbolja kada je u pitanju brzina detekcije i obrade signala, ali su primećeni problemi u pouzdanosti.

Iz svega prethodno navedenog se može zaključiti da je jako bitno da se poređenje različitih metoda obavlja u uslovima primene za koju se iznose zaključci i za koju je metoda namenjena. Autor je u većem broju radova se bavio analizom i poređenjem velikog broja

metoda koje su pokazale najbolje rezultate u literaturi i koje imaju široku primenu. Performanse metoda su ispitivane za primene u savremenim distributivnim mrežama, tj. u distributivnim mrežama koje u sebi sadrže distribuirane generatore, i u ovom delu će biti dati rezultati poređenja sa kritičkom analizom testiranih metoda.

U [41] po prvi put je predstavljena originalna metoda autora za estimaciju harmonika, koja ima preciznost ekvivalentnu FFT metodi, ali sa velikom prednosti u brzini izračunavanja i daleko manju računsku kompleksnost. U poređenju sa FFT metodom za analizu signala napona i struje, RFFT metoda je pokazala boje rezultate.

U radu autora [110] predstavljena je RFFT metoda za detekciju propada napona. Ova metode koja je primenjena na inovativan način, da prati treći ili treći i peti harmonik, koji u slučaju kvara imaju gotovo trenutni skok amplitude. Pokazano je da je kvar moguće detektovati unutar vremenskog intervala od jedne polu-periode, tj. unutar 10 ms od nastanka kvara u mreži.

U [47] predstavljeno je poređenje WT, FFT, i RFFT metode. Metode su testirane u IEEE 13 test mreži sa dodatim distribuiranim generatorima, i u laboratoriji za energetske elektroniku Fakulteta tehničkih nauka [111]. FFT i RFFT metode su uspešno detektovale sve testirane propade, dok je WT imao problema sa pouzdanošću. RFFT metoda je imala najbolje računsko vreme, tj. omogućavala je najbrži proračun a i najbrže vreme detekcije u 5 od 6 testiranih slučajeva, dok je WT najbrži u 1 testiranom slučaju. Ipak, WT je pokazao pouzdanost u testiranim uslovima od samo 33% detektovanih kvarova.

Autori su testirali performanse vrlo popularne STFT (Short-Time Fourier Transform) metode primenjenu za detekciju i analizu poremećaja u oblasti distributivnih mreža sa velikom količinom energije dobijene iz distribuiranih izvora u [112]. STFT metoda je upoređena sa FFT metodom i pokazano je da su obe metode pouzdane i da omogućavaju detekciju i dalju analizu osnovnih parametara kvara. FFT metoda se pokazalo kao bolja i brža u detekciji, dok je STFT metoda omogućavala bolju i precizniju harmonijsku analizu signala.

U [113] primena KF za DIA-u propada napona je upoređena sa FFT i RMS metodama. Algoritmi su testirani u simulacijama i u laboratorijskim uslovima, kao i za različita mesta kvara i različite uslove rada DG-ova. KF metoda je pokazala najbolje rezultate u brzini i preciznosti detekcije, dok su sve tri metode pokazale slične rezultate u pouzdanosti. Sve tri metode su uspešno detektovale i analizirale testirane poremećaje iz mreže.

Na osnovu rezultata prethodno opisanih radova iz literature, kao i originalno sprovedenog poređenja metoda za detekciju i analizu, formirana je tabela 2.1, u kojoj je dat opis prednosti i mana svake metode. B je brzina predložene metode, P je pouzdanost dok je K računski kompleksnost metode. Ocene su formirane na skali od 1-5, tako da ocena predstavlja relativni odnos rezultata između metoda u datom opsegu. Pored pojedinačnih, data je i konačna ocena optimalnosti ( $R^*$ ), formirana na osnovu formule (2.5).

$$R^* = 0.4 * (B + P) + 0.2 * K \quad (2.5)$$

Brzine detekcije metoda je testirana sa naponskim poremećajima snimljenih iz realnih distributivnih mreža, kao i primeni metoda na laboratorijskom sistemu, gde je merena zahtevnost kao i brzina i ponašanje metoda u realnom vremenu. Izabrano je 9 reprezentativnih metoda, od toga 2 standardne (RMS i s-RMS), 6 metoda baziranih na obradi signala (4 neparametarske (FFT, STFT, RFFT, WT), 1 parametarska (KF) i 1 hibridna (EKF)) i jedna metoda koja u sebi sadrži veštačku inteligenciju (metoda predstavljena u radu u [96], bazirana na nekoliko različitih metoda, kao što su WT; MRA, kao i nekoliko tipova naprednih neuronskih mreža - MRA+NN).

## 2.7 ZAKLJUČAK

Iz pregleda literature i tabele 2.1. može se zaključiti da postoji veliki broj metoda za detekciju propada napona koji je zasnovan na estimaciji harmonika. Generalno, neparametrijske metode su široko korišćene u ovoj oblasti i daju vrlo dobre rezultate u velikom broju primena. Na primer, metode bazirane na WT i Furijeovoj analizi u određenim primenama su pokazale vrlo dobre rezultate i mogu pomoći da se određeni problemi vezani za kvalitet napona reše. Pored toga, ove metode su najjednostavnije, dobro su poznate i računski su najmanje zahtevne.

Parametrijske metode, sa izuzetkom Kalmanovog filtra nisu odgovarajuće za primenu u detekciji propada napona. KF ostvaruje rezultate koji se mogu okarakterisati kao srednje uspešni, uz to ima malu računsku zahtevnost u poređenju sa naprednijim metodama.

Hibridne metode, koje su razvijene u skorije vreme, i dalje se razvijaju, dizajnirane su da prevaziđu određene probleme koji se javljaju prilikom primene klasičnih metoda. Hibridna

metoda EKF je pokazala bolje ukupne rezultate od svih parametarskih i neparametarskih metoda, ali se mora naglasiti da unosi dva puta veće kašnjenje od WT baziranih metoda, koje su jednostavnije i računski manje zahtevne.

Metode bazirane na najsavremenijim metodama koje uključuju i neuronske mreže ili fazi logiku mogu da ostvare najbolje rezultate u oblastima za koji su projektovane, dok u drugim primenama često ti rezultati nisu zadovoljavajući. Metoda bazirana na MRA i WT, kao i na nekoliko neuronskih mreža nije ostvarila očekivane rezultate i poboljšanja, iako ima najbolju i najdetaljniju analizu signala.

Generalan zaključak je da ni jedna metoda ne može da se izdvoji kao apsolutni pobednik. WT ima najbolju brzinu detekcije, ali metoda ima velikih problema kada je šum prisutan u signalu, što je upravo slučaj u savremenim distributivnim mrežama. Metoda bazirana na veštačkoj inteligenciji je najsloženija, i uprkos najboljoj analizi signala pokazalo se da u određenim slučajevima ima problem sa detekcijom propada napona.

Cilj koji je postavljen je da se razvije metoda za detekciju i analizu sa brzinom koja je ekvivalentna ili čak i brža od one koju daje WT metoda (za vreme koje je kraće od 1 ms), sa velikom pouzdanošću i sa mogućnošću praćenja i analize svih relevantnih osobina signala kvara, na osnovu kojih se dalje može izvršiti precizna klasifikacija. Na ovaj način po zadatim kriterijumima takva metoda bi mogla da bude izabrana kao optimalna.

Kao dodatna mogućnost, pokazaće se da na bazi harmonijskog otiska koji je osnov metode za detekciju, se može i predvideti osnovni parametar kvara, a to je dubina propada napona, tj. podatak na koju najnižu vrednost će amplituda napona redukovati svoju vrednost tokom poremećaja u mreži.

Tabela 2.1 : Pregled osnovnih osobina metoda za DIA-u naponskih poremećaja

Nazivi metoda	B	P	K	R*	Prednosti	Mane
RMS	1	4	5	3	Jednostavna, standardna metoda.	Metoda ima veliko kašnjenje u detekciji, brzina nedovoljna za nove primene, nema mogućnost izračunavanja ni nekih od osnovnih parametara signala kao što je fazni pomeraj.
s-RMS	2	4	4	3.2	Jednostavna, unapređenje standardne RMS metode, nešto brža od RMS.	Brzina i dalje nedovoljna, unosi kašnjenje u detekciju, nemogućnost izračunavanja potrebnih parametara isto kao kod RMS.
FFT	3	5	3	3.8	Jedna od najpoznatijih metoda za analizu u frekventnom domenu, uspešno izračunava fazni ugao kao i potrebne harmonike. Brzina detekcije veća od RMS.	Moguće greške kod estimacije vrednosti tokom tranzijenta, unosi kašnjenje koje je iako manje nego kod RMS metoda, i dalje daleko veće nego kod WT metode.
RFFT	3	5	4	4	Jednostavna metoda, najbrža od svih predstavljenih, ima mogućnost estimacije harmonika, faznog ugla i osnovnih parametara signala.	Brzina limitirana poređenjem sa predefinisanim vrednošću, nemogućnost zaključivanja i praćenja složenijih šablona u signalu.
STFT	3	5	3	3.8	Računski nezahtevna metoda, jednostavna za primenu.	Moguće greške kod estimacije tokom dinamičkih promena u signalu
KF	3	5	3	3.8	Parametarska metoda koja ima umerenu računsku zahtevnost, dobru pouzdanost i umerenu brzinu.	Kašnjenje koje se unosi je slično onom kod FFT-a.
EKF	4	5	2	4	Metoda je srednje računski zahtevna, zahtevnija je od ostalih parametarskih i neparametarskih metoda, ali ima veću brzinu od KF i FFT metoda	Kašnjenje je manje nego kod FFT metoda, ali je i dalje dva puta veće nego kod WT metode.
WT	5	3	2	3.6	Daje parametre signala i u frekventnom i vremenskom domenu, ima dobru rezoluciju proračuna, brzina detekcije bez konkurencije najbolja kod parametarskih i neparametarskih metoda.	Pouzdanost detekcije je u slučajevima kada ima signala u šumu nedovoljna (od 30-70 %), a pokazano je da problem sa pouzdanošću postoji kod primene u DM koje u sebi sadrže DER-ove.
MRA + NN	4	4	1	3.4	Metoda bazirana na nekoliko tipova naprednih NN. Izuzetno detaljna analiza signala i pouzdana klasifikacija, detekcija umerene brzine.	Kompleksna metoda, detekcija unosi određeno kašnjenje, u nekim slučajevima nemogućnost detekcije poremećaja.



## **POGLAVLJE 3**

---

### **SAVREMENE DISTRIBUTIVNE MREŽE SA DISTRIBUIRANIM GENERATORIMA**

### 3.1 UVOD

Elektrodistributivne mreže (ili skraćeno distributivne mreže) predstavljaju deo elektroenergetskih sistema čija je funkcija da vrše distribuciju električne energije od napojnih čvorova koji se nalaze u transformatorskim stanicama visoki napon (VN)/srednji napon (SN) (koje se napajaju iz prenosnih ili subprenosnih mreža) do krajnjih potrošača električne energije [114].

Tradicionalne distributivne mreže su se sastojale isključivo od pasivnih elemenata, ali se ovakav koncept distributivnih mreža znatno promenio u proteklih nekoliko decenija. Razlog tome je uvođenje distribuiranih izvora. Distributivne mreže postaju aktivne kada se u njih dodaju DG jedinice što dovodi do dvosmernog toka snage u mrežama. Usled ovih promena, distributivne mreže se suočavaju sa brojnim tehničkim i ekonomskim izazovima, kao i brojnim izazovima u oblasti kvaliteta električne energije, o čemu je već bilo reči u poglavlju 1. Takođe, distributivne mreže se i u razvijaju i postaju sve složenije usled konstantnog porasta broja mernih uređaja koji su raspoređeni u distributivnom sistemu na srednjem a sve češće i na niskom naponu.

Distribuirana proizvodnja (engl. Distributed generation – DG) je termin koji se u elektroenergetici koristi za proizvodnju električne energije na lokaciji potrošača, dok se pod terminom distribuirani izvori-generatori misli se na generatore koji se priključuju na distributivnu, niskonaponsku ili srednjenaponsku mrežu. U anglo-američkoj literaturi postoji više izraza kojima se imenuje ovakav način proizvodnje: distributed generation, on-site generation, dispersed generation, embedded generation, decentralized generation, decentralized energy, distributed energy, dok se u našem jeziku najčešće koriste dva izraza, distribuirani generatori (DG) ili distribuirani izvori energije (DER). Ne postoji precizno definisana snaga ili naponski nivo na kome se koriste i priključuju distribuirani generatori. Međutim, ako pričamo o IEEE-standardu, tada se distribuiranim generatorima smatraju jedinice snage do 10 [MW]. Širi termin od distribuiranog generatora (DG) jeste distribuirani elektroenergetski resursi (DER), a tu, osim pomenutih distribuiranih generatora, spadaju još i rezervni sistemi napajanja, sistemi za akumuliranje električne energije i mere za upravljanje potrošnjom.

U DER spadaju i skoro svi obnovljivi izvori, do određene snage, tako da su termini obnovljivi izvori i distribuirani izvori vrlo blisko povezani. Već je rečeno šta se podrazumeva

pod terminom distribuirani izvori, a pod pojmom obnovljivi izvori podrazumevaju se izvori energije koji se nalaze u prirodi i obnavljaju se u celosti ili delimično.

Solarne elektrane, vetroelektrane, male HE, elektrane na biomasu, postrojenja za kombinovanu proizvodnju električne i toplotne energije koja koriste fosilna goriva, elektrane koje koriste geotermalnu energiju i gorivne ćelije, sve ovo spada u distribuirane izvore. Od ostalih vrsta obnovljivih izvora treba pomenuti elektrane koje koriste energiju morskih talasa (plime i oseke) i magneto-hidrodinamičke generatore [115].

Uprkos brojnim pogodnostima koje pružaju konvencionalni energetske sistemi, sledeće tehničke, ekonomske i ekološke koristi dovele su do razvoja i integracija DG sistema:

- DG mogu da obezbede pokrivanje povećanja potrošnje određenog broja potrošača,
- Svi distribuirani resursi se mogu proširivati u vrlo malim koracima,
- Pojedini distribuirani izvori se mogu postaviti na bilo kom mestu i za vrlo kratko vreme,
- Povećanje sigurnosti i pouzdanosti napajanja,
- DG rade bez štetnog uticaja na okolinu ili sa redukovanom emisijom štetnih materija (u slučaju da je energija dobijena iz obnovljivih izvora),
- Konkurentnost na tržištu električne energije,
- DG mogu imati pozitivan uticaj na naponske prilike i kvalitet električne energije,
- Omogućavaju operatorima distributivnog sistema lakše ujednačavanje (poravnavanje) dijagrama potrošnje,
- Postojanje DG u distributivnom sistemu obezbeđuje smanjenje opterećenja prenosnih kapaciteta.

Osim potencijalnih gorenavedenih pogodnosti, često se raspravlja o nedostacima upotrebe distribuiranih izvora. Zapravo, dok nekoliko generatora ne čine problem, buduća vizija sistema električne energije predviđa veliku zasnovanost na distribuiranim izvorima, što neizbežno uvodi određene probleme. Kritične promene su:

- Postojanje DG utiče na rad uređaja relejne zaštite,
- Visoko učešće DG u potrošnji sistema utiče na stabilnost,
- Visoki troškovi, odnosno visoka cena instalacije distribuiranih izvora energije

- Odsustvo standarda, tj. stalna dopuna i objavljivanje novih standarda jer je ovo relativno novo područje,
- Administrativne i pravne barijere, jer u većini zemalja nema standardnog zakonodavstva i ustaljenih regulativa za regulisanje rada ovog tipa izvora električne energije [116].

Bitno je napomenuti da u svim oblastima iz godine u godinu stanje se popravlja, a u prve dve stavke intenzivno istraživanje se vrši i ispituju se uticaji DG na različite delove sistema, cena DG je u konstantnom padu (po jedinici snage), a i poslednje dve stavke koje se tiču standarda i pravnih barijera se ubrzano popravljaju i rešavaju.

### **3.2 PAMETNE MREŽE**

Ova vrsta mreže koristi digitalne komponente i tehnologije komunikaciju u realnom vremenu instalirane kroz mrežu za praćenje električnih karakteristika mreže i stalno prilagođavanje kako bi svi delovi funkcionisali u optimalnom režimu. Ovakvi sistemi poseduju inteligenciju kako bi neprekidno tražili potencijalne probleme koji mogu biti različitog uzroka, kao što su kvarovi, oluje, ljudske greške ili čak sabotaze o sajber napadi na telekomunikacionu strukturu mreže. U deliću sekunde pametne metode će reagovati na potencijalne nepravilnosti (abnormalnosti). Trebalo bi da imaju mogućnost da trenutno izoluju problem čim pojavi (detektuju ga i zatim odrede njegov uzrok) i reorganizuje mrežu preusmeravajući prenos i tok energije tako da potrošači i dalje budu napajani, dok se problem fizički ili na drugi način rešava ili popravlja od strane stručnih timova. Ovakva mreža može da obezbedi brojne prednosti.

Tri najvažnije funkcije uključuju:

1. Praćenje u realnom vremenu i trenutno reagovanje, što omogućava sistemu da konstantno podešava svoj rad na optimalno stanje,
2. Predviđanje, koje sistemu omogućava da automatski predvidi problem koji može izazvati veće poremećaje,
3. Brzo izolovanje kvara, prepoznavanje problema i mesta ili lokacije koje je uzrok poremećaja, što omogućava da se problem izoluje, kao i da se delovi mreže u kojima se desio poremećaj odvoje od ostatka sistema. Ovo se radi u cilju kako bi se izbeglo širenje poremećaja i omogućila brža restauracija normalnog režima rada.

### 3.3 MIKRO MREŽE

Pametne mikro mreže predstavljaju ključnu oblast razvoja i istraživanja poslednjih godina i bez sumnje će igrati sve veću ulogu u zadovoljavanju zahteva i potreba potrošača za povećanjem pouzdanosti i obezbeđivanju lokalne kontrole tokova i kvaliteta električne energije. Mikromreže su mali sistemi, snage svega nekoliko megavata (MW) ili manje sa tri osnovne karakteristike: postojanje distribuiranih generatora (sa opcionalnim kapacitetom skladištenja), postojanje autonomnog centra za kontrolu opterećenja i sposobnost međusobno povezanog ili izolovanog (ostrvskog) rada. Skladištenje energije se može obezbediti pomoću baterija, super-kondenzatora ili drugih izvora.

Mikromreže mogu da služe kao idealna platforma za realizaciju kombinovanih ciljeva pametnih mreža, uključujući pouzdanost, integraciju obnovljivih izvora energije, diverzifikaciju izvora energije i fleksibilan odgovor na potražnju.

U nekim aspektima, mikro-mreže mogu biti znatno složenije. Na primer, one mogu uključivati DC elemente i invertore za konverziju. One takođe mogu omogućiti veću kontrolu nad raznovrsnijim potrošačima, a povezanost sa mrežom može biti fleksibilna. Na kraju, mikromreže mogu da omoguće neprekidno napajanje tamo gde mreže mogu biti nepouzidane. U ovom slučaju, izolovani (ostrvski) rad dolazi do izražaja.

Autonomna mikromreža je mikromreža koja je koordinisana inteligentnim automatskim kontrolama bez značajnog oslanjanja na ljudsku intervenciju. Takođe, za autonomnu mikromrežu podrazumeva se da funkcioniše maksimalno nezavisno od drugih mikromreža.

Već možemo videti da se na mnogim lokacijama počinju graditi mikromreže, kako bi služile kampusima, zajednicama i gradovima. Mnoge od tih mikromreža će dobijati električnu energiju tj. napajati se iz lokalno dostupnih i danas vrlo poželjnih obnovljivih izvora energije poput vetra i fotonaponskih sistema.

Koncept mikromreža se može eventualno proširiti na više naponske nivoe, kako bi bili stvoreni samostalni i samodovoljni sistemi [117], ali to izlazi iz okvira ovog rada i trenutnog istraživanja.

Metode koje su predstavljane u ovom radu su prvenstveno namenjene i projektovane za korišćenje u savremenim distributivnim mrežama, pametnim ili mikromrežama. Takođe,

testiranje je obavljeno sa realnim signalima iz distributivnih mreža, u laboratorijskim uslovima koji emuliraju mikromrežu i u računarskim simulacijama distributivne mreže.

### 3.4 MODELI DISTRIBUTIVNIH MREŽA

U cilju testiranja različitih metoda i algoritama koji su namenjeni za primenu u distributivnim mrežama potrebno je koristiti modele ovog tipa elektroenergetskih mreža. Sa razvojem naprednih računarskih tehnologija pojavile su se i veće mogućnosti za razvoj kompleksnih softverskih alata koji su postali više slični realnosti, sa odzivom i proračunima u realnom vremenu, mogućnostima korišćenja velikih baza podataka u kojima se nalaze različiti parametri mreže kao i karakteristike mreže ili podaci sa SCADA uređaja, itd.

Kao mana javlja se to da različite tehnike kojima se testira veliki broj scenarija, stanja u mreži (kvar, nestabilnost, itd.), kontrolnih algoritama, kompenzacionih metoda, implementaciju različitih vrsta DG, mogu imati komplikovan i dugotrajan proračun, takođe predstavljaju i skup način testiranja, koji nije pogodan za često korišćenje a i univerzalnost dobijenih rezultata je zanemariva. Takođe, ako se koriste modeli koji se modeluju na osnovu lokalnih distributivnih mreža može se desiti da određeni parametri nisu dovoljno precizno ili nisu uopšte poznati i dokumentovani, posebno za parametre "duboko" u distributivnoj mreži. Ovi problemi dovode do toga da je testiranje različitih scenarija vremenski dugotrajno i zahtevno.

Zbog svega navedenog, pojavila se potreba da se ustanove jedan ili više referentnih modela distributivnih mreža sa standardizovanom kompleksnošću, strukturom i dobro poznatim i dokumentovanim parametrima, koji mogu da predstavljaju distributivne ili prenosne mreže [118–120]. Ovi test i referentni modeli su izabrani kao optimalni da mogu da pokriju najrazličitije potrebe za testiranjem u različitim uslovima, operativnim scenarijima i u zavisnosti od tipova opterećenja i same strukture elektroenergetskog sistema. Najčešće su ovi modeli uprošćeni modeli realnih elektroenergetskih sistema (kod IEEE - Institute of Electrical and Electronics Engineers - test mreža i EPRI - Electrical Power Research Institute-) ali mogu biti i sintetički modeli mreža koji su razvijeni da budu slični realnim mrežama ali sa tom prednošću da nemaju problem sa čuvanjem i tajnošću podataka o energetskej infrastrukturi (TAMU -Texas A&M University- test mreže), a mogu biti i u potpunosti izmišljeni modeli, da odgovaraju određenim specifičnim potrebama, kao što su na primer DC mreže ili kobinovane AC-DC mreže (CIGRE -Council on Large Electric Systems-

test mreže). Generalno postoje dva tipa test mreža: distributivne test mreže i prenosne test mreže. U daljem radu kao i u ovom poglavlju fokus je na distributivnim mrežama, i zbog toga će one biti detaljno opisane.

### 3.4.1 Distributivne test mreže

Distributivne test mreže su modeli mreža koji su replike ponašanja stvarnih distributivnih mreža. Generalno, cilj je da se reprodukuju karakteristike stvarnih mreža, uključujući specifičnosti određenog regiona gde se mreža nalazi. Distributivne test mreže su veoma koristan alat i često se koriste u istraživanjima u oblasti elektroenergetike. Njihova primena obezbeđuje da su rezultati međunarodno proverljivi i da se sva testiranja mogu ponoviti i da se rezultati koji dobiju mogu posmatrati zajedno sa rezultatima drugih istraživanjima. Ovi tipovi mreža su dizajnirani pre svega za testiranje algoritama u trofaznim sistemima, ali postoje i test mreže sa dvofaznim i monofaznim delovima mreže. Za zvanične test mreže svi potrebni parametri za modelovanje su jasno i nedvosmisleno definisani i dati, kao i šematski prikazi i instrukcije za modelovanje svakog dela mreže. Postojanje ovakve dokumentacije u velikoj meri ubrzava modelovanje i povećava pouzdanost dobijenih rezultata. Pored električnih osobenosti modela (oprema, vodovi, potrošači, zaštitni uređaji, itd.) u dokumentaciji test mreže definisani su geografski podaci o vodovima kao i međusobnim vezama (dužina vodova, njihove rute i način povezivanja), zatim definisani su parametri potrošača u svakom čvoru mreže (broj potrošača, veličina, klasa, profil potrošnje, vršno opterećenje-KW kao i faktor snage), i linijski dijagram u kome su ucrtani vodovi i čvorovi i informacije o transformatorima (MVA, KV, impedansama, sprežni brojevi, itd.).

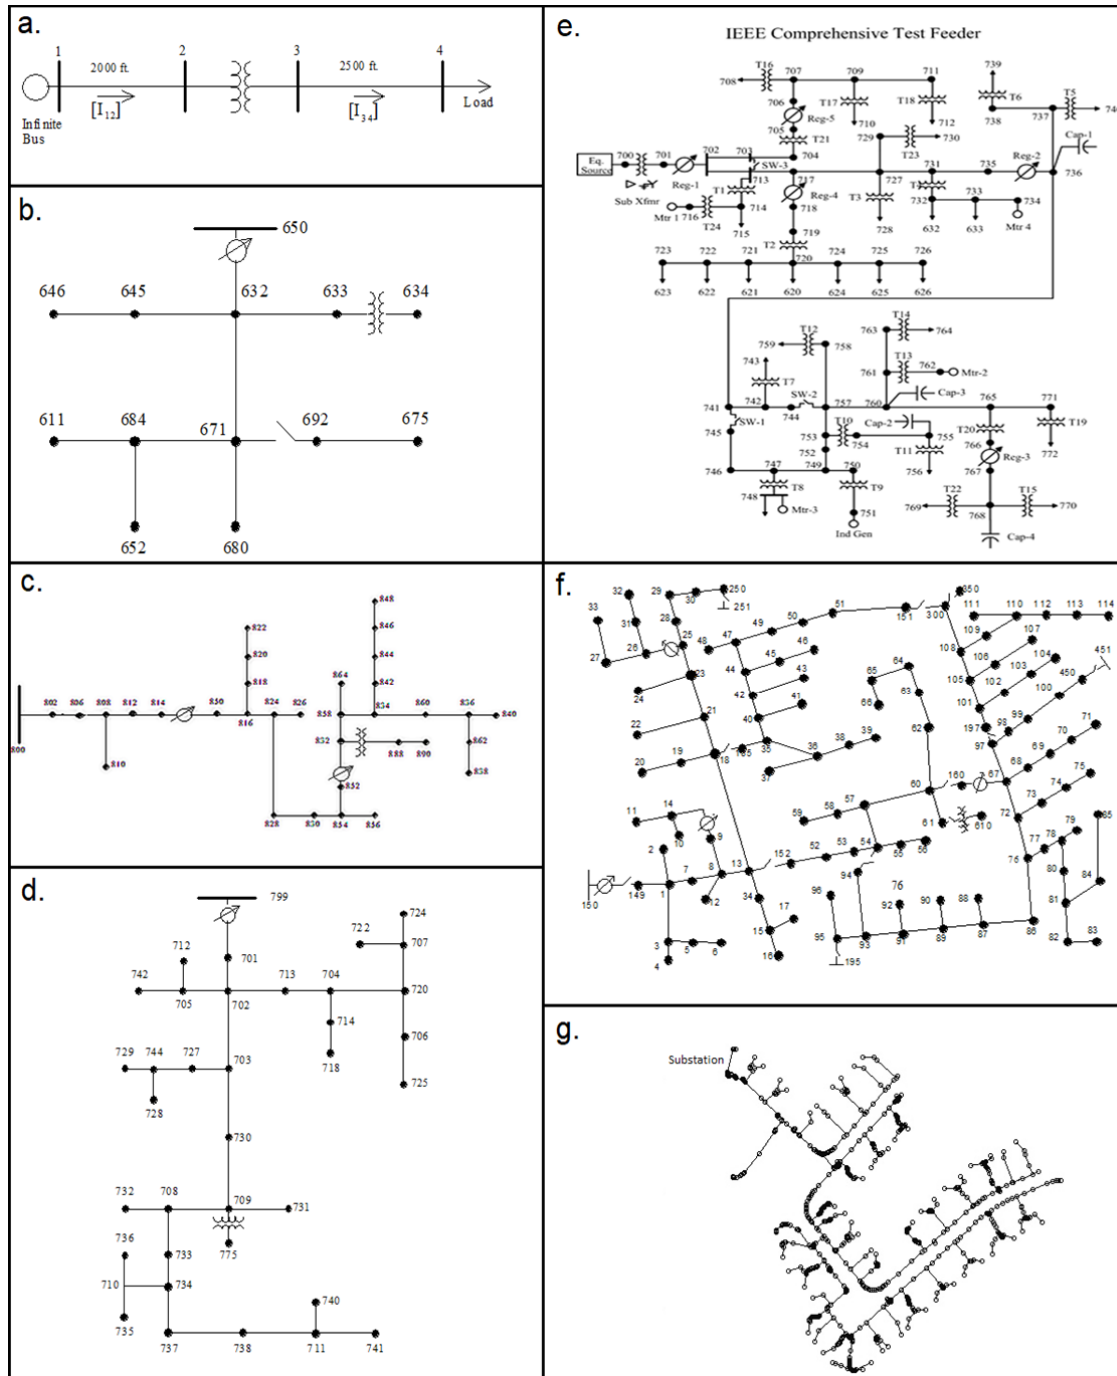
### 3.4.2 IEEE test mreže

Najčešće korišćene distributivne test mreže su IEEE test mreže. IEEE je kreirao test mreže sa 4, 13, 34, 37, 123 i 8500 čvorova [121]. Originalni dokument koji opisuje test mreže sa 13, 34, 37, i 123 čvora kreiran je 1992. godine, a odobrena je njegova publikacija 2000. Nakon toga publikovane su test mreže sa 8500 čvorova (2010.) i Evropska niskonaponska test mreža (2015.). Sve spomenute test mreže su uprošćeni modeli realnih (fizičkih) distributivnih mreža, uglavnom geografski lociranih na Severno Američkom kontinentu, sa izuzetkom Evropske niskonaponske mreže. Pregled ključnih podataka o svim test mrežama dat je u tabeli 3.1, dok su fazni dijagrami test mreža predstavljeni na slici 3.1.

Tabela 3.1 Glavne osobine IEEE test mreža [122]

<b>Ime:</b>	<b>Naponski nivo [kV]</b>	<b>Maks. opterećenje [MVA]/ Br. Potr.</b>	<b>Nivo DG gen. energije [MVA]</b>	<b>Dužina mreže [km]</b>	<b>Modelavana u svrhe:</b>
<b>4-bus</b>	<b>12.47</b>	<b>6.3/1</b>	<b>0</b>	<b>1.3</b>	Za testiranje transformatorskih modela
<b>13-bus</b>	<b>4.16</b>	<b>3.6/9</b>	<b>0</b>	<b>2.5</b>	Za testiranje različitih algoritama u uslovima nebalansiranih i jako opterećenih distributivnih mreža
<b>34-bus</b>	<b>24.9</b>	<b>1.6/24</b>	<b>0</b>	<b>94</b>	Izuzetno dugačka mreža koja zahteva naponske regulatore da bi se ispunili osnovni standardi o kvalitetu
<b>37-bus</b>	<b>4.8</b>	<b>2.73/25</b>	<b>0</b>	<b>5.5</b>	Trofazni podzemni elektroenergetski sistem
<b>123-bus</b>	<b>4.16</b>	<b>3.8/114</b>	<b>0</b>	<b>12</b>	Veliki sistem koji se sastoji od nadzemnih i podzemnih monofaznih, dvofaznih i trofaznih vodova, naponskih regulatora i šant kondenzatora
<b>European LVTF</b>	<b>0.4 (416 V)</b>	<b>3.7/55</b>	<b>0</b>	<b>10.4</b>	Fokus je da se obezbedi test platforma za istraživanja za niskonaponske delove mreža, koje su česte u Evropi, i njihove brze i srednje brze tranzijentne promene
<b>CTF</b>	<b>24.9</b>	<b>4.17/36</b>	<b>0.15</b>	<b>81.7</b>	Test mreža namenjena da se testiraju komponente i algoritmi u sistemu sa izuzetno raznovrsnim tipovima komponenti.





Slika 3.1 Fazni dijagram: a) IEEE 4-bus; b) IEEE 13-bus; c) IEEE 34-bus; d) IEEE 37-bus; e) "IEEE Comprehensive test feeder"; f) IEEE 123-bus i g) Evropska test mreža [121].

[122]

### 3.5 DRUGE TEST MREŽE

Postoji mnogo drugih test mreža koje se mogu primeniti za istraživačke i nastavno/edukacione svrhe. Ove mreže uglavnom imaju svoje specifične osobenosti i namene, i značajno se razlikuju u broju čvorova i složenosti. Ove mreže uglavnom imaju mali broj DG izvora energije, ili ih nemaju uopšte.

Pored AC test mreža o kojima je isključivo do sada bilo reči, postoje i test mreže koje sadrže i DC delove i svu potrebnu opremu modelovanu i definisanu. Kako to nije tema i takve mreže neće biti korišćene za testiranje algoritama predstavljenih u ovom radu, samo će kratko biti objašnjene.

#### 3.5.1 Texas A&M engineering test mreže

Texas A&M engineering test mreže su dostupne na [123] a algoritmi korišćeni za njihovo formiranje i modelovanje su opisani i predstavljeni u [124]. Ovi modeli su u mnogim stvarima suprotnost u odnosu na IEEE test mreže, u potpunosti su sintetički (izmišljeni modeli), i dizajn i modelovanje nije bazirano na stvarnim mrežama. Uprkos tome, njihova funkcionalnost je slična statistički i principski, iako modeli nisu bazirani na stvarnim vodovima i mrežama. Velika prednost ovog pristupa modelovanju je to što ne sadrže bilo kakve poverljive podatke o energetskej infrastrukturi. Test modeli su dati na korišćenje u nekoliko dostupnih formata, a neke od poznatih test mreža su: ACTIVSg200, ACTIVSg500, ACTIVSg2000, ACTIVSg10k, UIUC150, ILLINI 42 Tornado ILLINIGMD 42 HEMP. Pored sopstvenih test mreža, postoje i modeli koje su bazirani na literaturi, pre svega IEEE mreža (IEEE 14, 24, 30, itd).

Ove test mreže pokrivaju širok raspon elektroenergetskih sistema, i ne obuhvataju isključivo distributivne mreže, već pokrivaju sve tipove mreža. Zbog toga što se u radu ne izlazi iz okvira distributivnih mreža, drugi tipovi se neće dalje opisivati.

#### 3.5.2 Electric Power Research Institute test grids

Ove test mreže su dizajnirane kao deo EPRI projekta u kome su formirane projektne baze podataka za različite tipove test mreža i date su na javno korišćenje [121,125]. Modelovane su male, srednje i velike realne mreže sa različitim osobinama. Postoje šest tipova test mreža: K1, M1, J1, Ckt5, Ckt7 i Ckt24. Svih šest tipova je ukratko opisano i glavne karakteristike su prikazane u Tabeli 3.2. Ovi modeli su uglavnom dizajnirani sa svrhom da se testiraju uređaji i

algoritmi u okruženju pametnih mreža. Tri test mreže (K1, J1 i M1) su dizajnirane za testiranje uticaja PV izvora na sistem, dok su druge tri (Ckt5, Ckt7 i Ckt24) dizajnirane za testiranje tokova snaga u pametnim mrežama.

Tabela 3.2 EPRI test mreže

<b>Ime</b>	<b>Nominalni napon [kV]</b>	<b>Max. opterećenje [MVA] / broj potrošača</b>	<b>Snaga DG izvora [MW]</b>	<b>Dužina [km]</b>
<b>K1</b>	<b>13.2</b>	<b>6/321</b>	<b>1</b>	<b>45.1</b>
<b>J1</b>	<b>12.47</b>	<b>6/1384</b>	<b>1.7</b>	<b>93.3</b>
<b>M1</b>	<b>12.47</b>	<b>5.5/1470</b>	<b>/ *</b>	<b>20.9</b>
<b>Ckt5</b>	<b>12.47</b>	<b>1.950/1379</b>	<b>/ *</b>	<b>77.2</b>
<b>Ckt7</b>	<b>12.5</b>	<b>2.4/5694</b>	<b>/ *</b>	<b>12.9</b>
<b>Ckt24</b>	<b>34.5</b>	<b>3.3/119.1</b>	<b>/ *</b>	<b>119.1</b>

\*/ Javno nisu javno dostupne

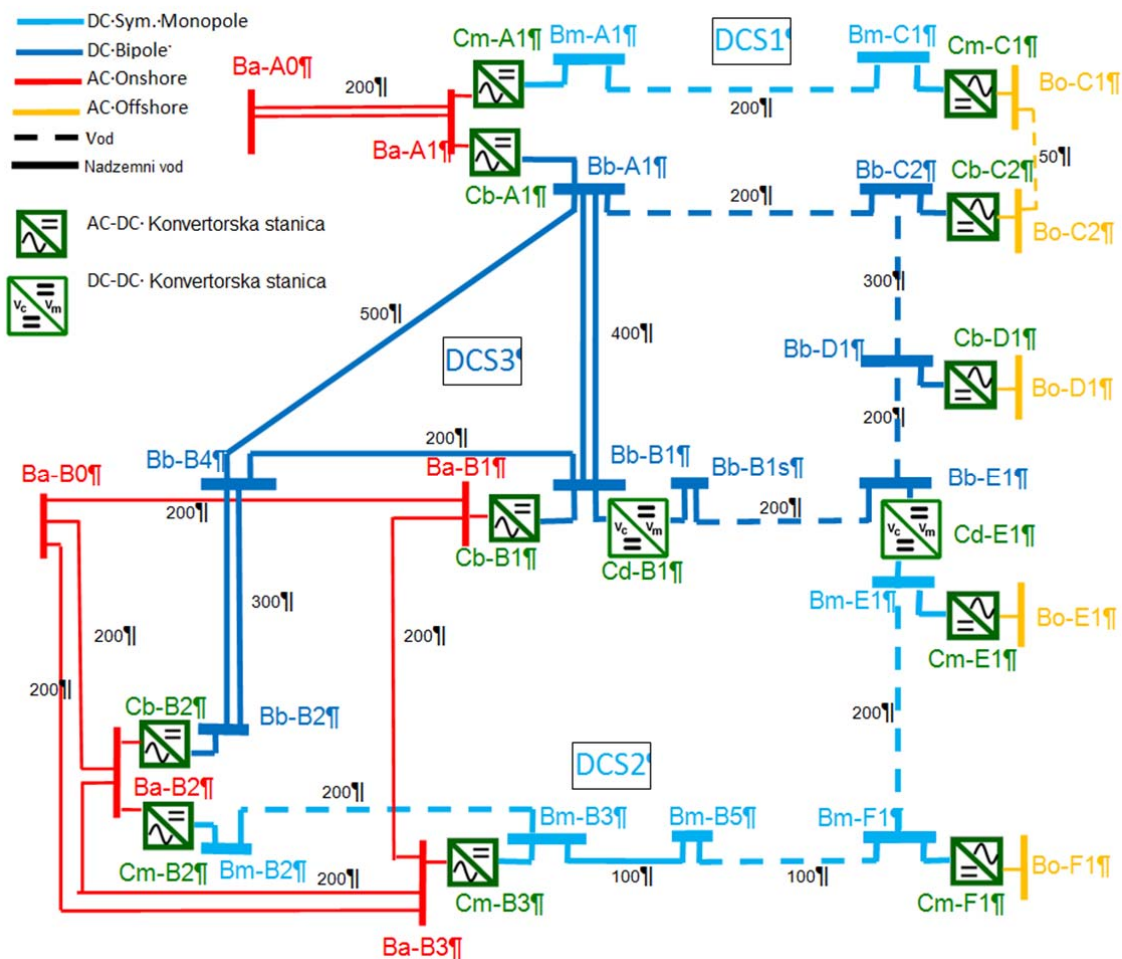
### 3.5.3 Test mreže koje sadrže i HVDC

HVDC tehnologija se nametnula kao jedno od rešenja za problem povezivanja i prenosa električne energije od velikih izvora električne energije koji se dobijaju iz obnovljivih izvora. Zbog toga došlo je do potrebe da se razvije test mreža koja će pokriti i ovo područje, pa će i to ukratko biti objašnjeno.

Svrha ove test mreže je da se postavi referenca i baza za istraživanja DC mreža. Pored detaljnih modela distributivne mreže, modelovano je i više tipova pretvarača kao i obnovljivih izvora energije, što ovu mrežu čini interesantnom i za oblast koju pokriva ovaj rad. Jedan od modela DC test mreža je opisan i predstavljen u [126].

CIGRE test mreža koja uključuje i primenu HVDC tehnologije, pod nazivom B4 DC Grid test system opisana je u [126]. Šema ove test mreže je predstavljena na slici 3.2. Ona sadrži dva DC čvora koja nemaju konekciju ka AC delu mreže, 3 naponska izvora koja su preko

invertora konektovana na DC sistem, 4 AC sistema "offshore" postavljena koji rade sa nominalnim naponom od 14 KV, 2 klasična vetrosistema koji su priključeni na 380 KV, zatim sadrži DC-DC konvertorske stanice, AC-DC konvertore kao i HVDC vodove na 200 KV i 400 KV. U mreži se nalazi instalirano 5.5 MW distribuiranih generatora, najviše "offshore" (van kopna-vetroelektrane, vetroelektrane koje su postavljene u moru) vetroelektrana. Frekvencija mreže je 50 HZ.



Slika 3.2 - CIGRE B4 DC test mreža [126].

### 3.6 ZAKLJUČAK

Distributivne mreže se konstantno menjaju i razvijaju. Pojava DG izvora energije u poslednjim decenijama i njihov ubrzan razvoj i primena, kao i razvoj i primena potrebnih tehnologija su dodatno doprineli da distributivne mreže imaju značajne promene u samoj strukturi i načinu rada. U cilju prevazilaženja novih problema kao i u cilju unapređenja pouzdanosti i kvaliteta električne energije, mnoga istraživanja, studije, projekti i testovi su sprovedeni, između ostalih i ovaj rad.

U cilju omogućavanja univerzalnosti i proverljivosti dobijenih rezultata, poželjno je koristiti neke od poznatih i pouzdanih test mreža, a tu se pre svega ističu IEEE test mreže. Jedna od najčešće korišćenih distributivnih test mreža je IEEE13 test mreža, i ona je u daljem radu korišćena u računarskim simulacijama za evaluaciju i testiranje predstavljenih metoda. Pored toga, ova test mreža je poboljšana da odgovara stvarnosti dodavanjem i priključenjem nekoliko vrsta obnovljivih izvora (distributivnih generatora), koji su dodati po optimalnom algoritmu u cilju poboljšanja kvaliteta i naponskih prilika u ovoj test mreži.

## **POGLAVLJE 4**

---


### **HARMONIJSKI OTISAK**

#### 4.1 DEFINISANJE "HARMONIJSKOG OTISKA"

Prilikom istraživanja harmonijskog spektra tokom naponskih poremećaja u distributivnim mrežama autori su primetili da amplituda harmonika niskog frekventnog spektra (2, 3, 5, 7, 9, 11, 13) ima gotovo trenutni porast, čija se promena amplitude daleko brže odvija od promene osnovne komponente napona (osnovnog harmonika) i brže se prenosi kroz mrežu od promene ukupne amplitude napona. Amplituda napona delom ima odložen pad vrednosti tokom tranzijenta kvara upravo zbog naglog skoka harmonika u mreži. U većem broju radova su ispitivane različite kombinacije harmonika, dok se nije došlo do one koja daje najbolje rezultate, a to je set do drugog, trećeg, petog i sedmog harmonika (HDU2357), koji je u radu autora [43] originalno nazvan Harmonijski otisak. Autori su tokom istraživanja testirali samo treći harmonik kao i treći, peti, sedmi, jedanaesti i trinaest harmonik u [76], zatim kombinovani set od trećeg, petog, sedmog, devetog, jedanaestog i trinaestog u [41], kao i set od trećeg, petog i sedmog u [47] i zatim kao optimalni je odabran set od drugog, trećeg, petog i sedmog harmonika u radu [127]. U radu u kome je odabran HDU2357 kao optimalni je zaključeno da ovaj set u kombinaciji sa 5% granicom za detekciju (kada odabrani set harmonika pređe datu granicu, algoritam detektuje poremećaj u mreži) se ostvaruje visoka pouzdanost (u simulacijama na IEEE13 distributivnoj mreži sa velikim brojem DER koje su predstavljene u radu 100% pouzdanost) i izuzetno jednostavna struktura samog algoritma.

#### 4.2 PRIMERI, IZGLED I MATEMATIČKA FORMULACIJA HARMONIJSKOG OTISKA


Na slici 4.1 (a.) prikazan je signal napona u sve tri faze (zajedno), (b.) RMS napona kao i (c.) odabrani set harmonika HDU2357 u sve tri faze, za propad napona u sve tri faze. Može se primetiti da u sve tri faze u kojima se dogodio kvar ima skok harmonika koji se poklapa sa početkom poremećaja. Takođe je moguće primetiti da se porast odvija u tri etape (i u jednom slučaju na početku faze 3 u dve etape), sa tri (dva) lokalna maksimuma i jednim globalnim, kako na početku poremećaja, tako i na kraju. Kvar koji je analiziran i prikazan na slici 1 je opisan u prilogu, u tabeli P1, pod rednim brojem 6.



Slika 4.1 – (a.) Naponski signal u sve tri faze, (b.) HDU2357 u sve tri faze za kvar #9 iz Tabele P1.



HO koji je obeležen na slici 4.1 (c.) sa crnim kvadratom, u prvoj fazi gde je propad i najdublji, je uvećan i prikazan na slici 4.2. Na ovoj slici je dodatno obeležen i prvi deo signala koji će se koristiti za detekciju propada napona, uz pomoć RNN.



Slika 4.2 – HDU2357 uvećan i obeležen period početka poremećaja, za kvar #9

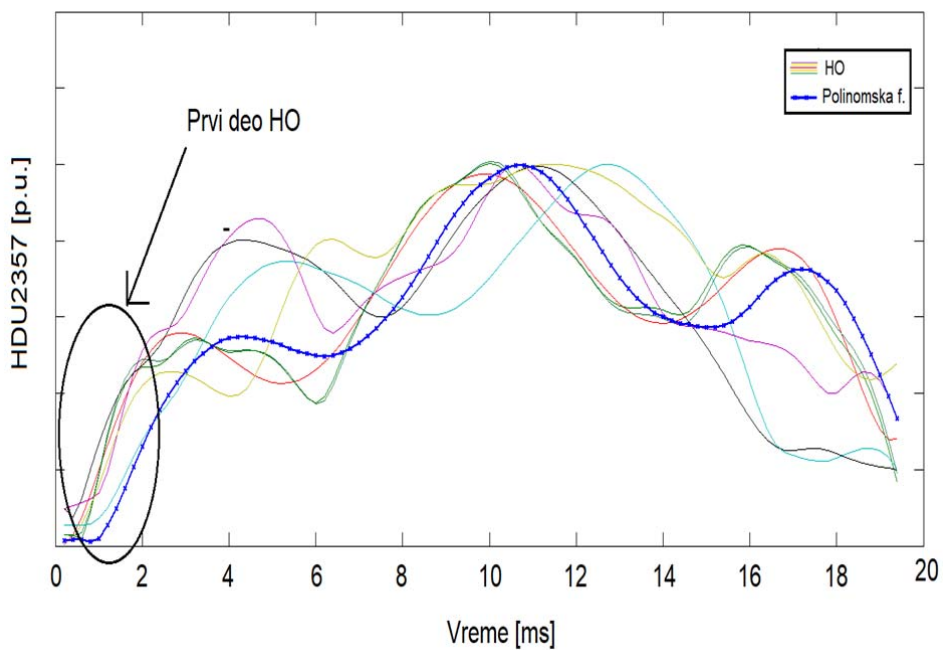
Kompletan HO se može estimirati polinomom osmog stepena (funkcija poly8 u Matlabu), i ova funkcija se može zapisati u obliku:

$$f(x) = p_1x^8 + p_2x^7 + p_3x^6 + p_4x^5 + p_5x^4 + p_6x^3 + p_7x^2 + p_8x + p_9 \quad (4.1)$$

Koeficijenti za formulu (4.1) za jedan konkretan slučaj (kvar 8) su predstavljeni u tabeli 4.1. Na slici 4.3 prikazano je nekoliko  $H_o$  za više različitih kvarova iz tabele P1 (#1, #2, #5, #6, #8, #9), kao i polinomska funkcija osmog stepena kojom se može približno opisati HO.

Tabela 4.1 – Koeficijenti za polinomski model HO

Koeficijenti za kvar #8		Coefficients with 95% confidence bounds
P1	4.652e-013	(4.094e-013, 5.21e-013)
P2	-1.809e-010	(-2.029e-010, -1.59e-010)
P3	2.834e-008	(2.48e-008, 3.187e-008)
P4	-2.277e-006	(-2.58e-006, -1.975e-006)
P5	9.892e-005	(8.419e-005, 0.0001136)
P6	-0.002223	(-0.00263, -0.001815)
P7	0.02161	(0.01558, 0.02764)
P8	-0.02546	(-0.0665, 0.01559)
P9	0.008948	(-0.08251, 0.1004)



Slika 4.3 – Izgled HO za nekoliko različitih kvarova iz tabele P1 (#1, #2, #5, #6, #8, #9) kao i izgled polinomske krive kojom se oblik HO može približno opisati

Karakteristični oblik HO je u najvećoj meri izazvan rastom drugog i trećeg harmonika. Razlog zašto je izabran da se drugom i trećem harmoniku dodaju i peti i sedmi je da bi se dobila veća opštost i da bi svi kvarovi koji mogu da izazovu propade i poremećaje napona bili uspešno detektovani i prepoznati. Harmonici nultog reda, kao što je treći harmonik, se ne prenose kroz većinu distributivnih transformatora. Kao posledicu ove činjenice imamo da postojanje trećeg harmonika na srednjem naponskom nivou je daleko manje nego na niskom. Takođe, u slučaju da kvar i mesto na kome se obavlja monitoring u mreži imaju između sebe distributivni generator, može se desiti da ovaj harmonik ima smanjenu vrednost. Za razliku od trećeg harmonika, peti i sedmi harmonik imaju slične vrednosti na različitim naponskim nivoima [38]. Drugi harmonik, pored toga što za klasične kvarove koji izazivaju propade napona (kratki spojevi) imaju dominantno velike amplitude, bitni su i zbog toga što kod magnjećenja transformatora kao i kod propada izazvanih pokretanjem velikih motora su dominantni i uzrokuju isti oblik HO.

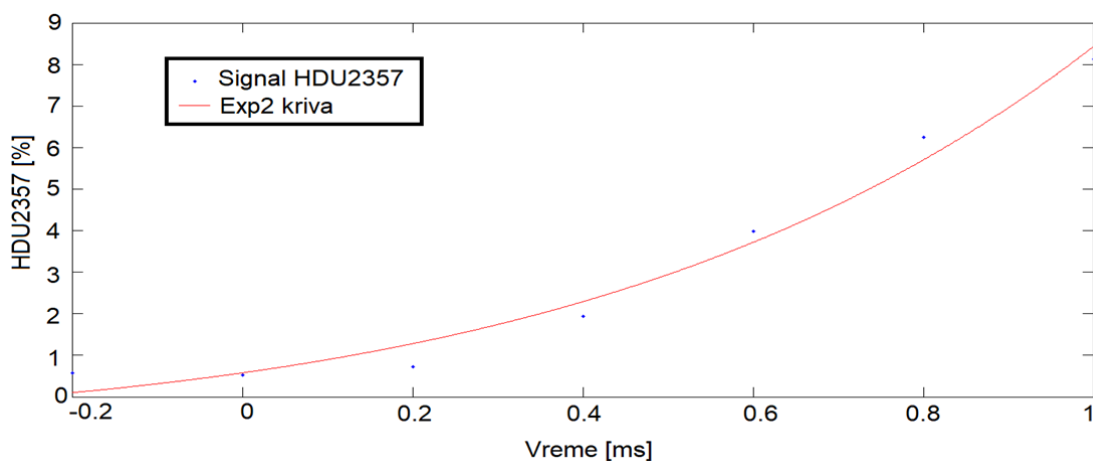
Na osnovu slike 4.3 vidljivo je da postoji velika razlika u nekim delovima HO i da jako teško ostvariti dobro podudaranje na celom intervalu. Takođe, prvi deo HO, koji je naznačen na slikama 4.2 i 4.3 je vrlo sličan, i ovaj deo je odabran za dalju analizu kao i za detekciju naponskih poremećaja u sledećem poglavlju. Ovaj prvi deo HO karakteriše oštar, eksponencijalan rast vrednosti odabranog seta harmonika. Matematička funkcija koja opisuje samo ovaj prvi deo, se može opisati izuzetno precizno sa dvoparametarskim eksponencijalnim modelom (Exp2), koji je korišćen i prvi put opisan u radu [43]:

$$f(x) = ae^{bx} + be^{cx} \quad (4.2)$$

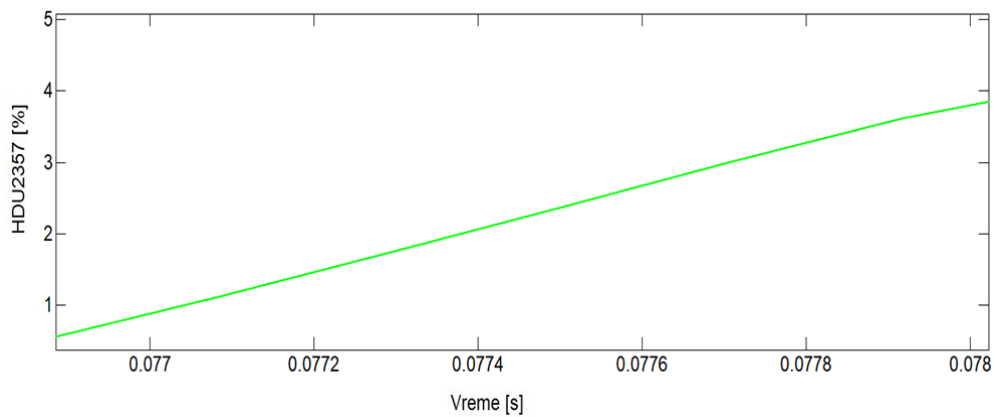
Tabela 4.2 – Koeficijenti za eksponencijalni Exp2 model za kvar #8

	Koeficijenti Exp2 modela
a	0.6745
b	-0.3996
c	0.204
d	0.152


U tabeli 4.2 prikazani su parametri za kvar #8 iz tabele P1 i Exp2 model. Ovaj model je grafički prikazan na slici 4.4, kao i stvarni podaci za kvar #8 koje ova kriva opisuje. Vidi se da sa vrednosti od oko 0.7, signal u vremenskom intervalu od svega 1 ms nakon početka kvara, narasta na preko 8, eksponencijalnim porastom. Ovako nagli porast kao i to što je karakterističan po samom načinu promene (eksponencijalni rast) je pogodan za praćenje sa metodama za praćenje šablona koji su bazirani na NN. Ovako brz porast je za kvar koji izaziva propad napona na 54% od nominalne vrednosti pre kvara, i u ovom slučaju harmonici dostižu svoju maksimalnu vrednost na 20.5%. Za kvarove koji izazivaju manje propade napona u mreži, i ovaj porast harmonika je na manje vrednosti. Ovo se može videti na slici 4.5 gde je prikazan uvećano DHU2357 za početak kvara 6. Signal HDU2357 sa vrednosti oko 0.5 narasta na vrednost od 4. Prikazan je i porast u prvoj milisekundi nakon kvara i za signal #9 iz tabele P1 na slici 4.6, kod koga je propad na niži naponski nivo nego što je to slučaj i kod kvara #6 i kod kvara #8. Kao što je i očekivano, HDU2357 dostiže veću vrednost u toku prve ms nakon kvara, a i dostiže veću vrednost tokom celog tranzijenta (35.6%). Ovaj nagli porast je i prvi deo HO, tako da se ostvaruje najveća moguća brzina. Slike 4.5 i 4.6 su uvećani prikazi signala JDU2357 nakon kvara u trajanju od 1 ms, gde su 6 diskretnih vrednosti signala iscrtane i spojene pravim linijama (funkcija plot u Matlabu spaja dve susedne tačke pravim linijama), i zbog toga a i velikog uvećanja eksponencijalni oblik nije očigledan kao na slici 4.4.



Slika 4.4 – Prikaz izgleda signala HDU2357 na samom početku kvara, kao i krive Exp2 modela za kvar #8



Slika 4.5 – Prikaz izgleda signala HDU2357 na samom početku kvara, kao i krive Exp2 modela za kvar #6



Slika 4.6 – Prikaz izgleda signala HDU2357 na samom početku kvara, kao i krive Exp2 modela za kvar #9

## **POGLAVLJE 5**

---

### **PAMETNA METODA ZA DETEKCIJU PN ZASNOVANA NA RNN I HARMONIJSKOM OTISKU**

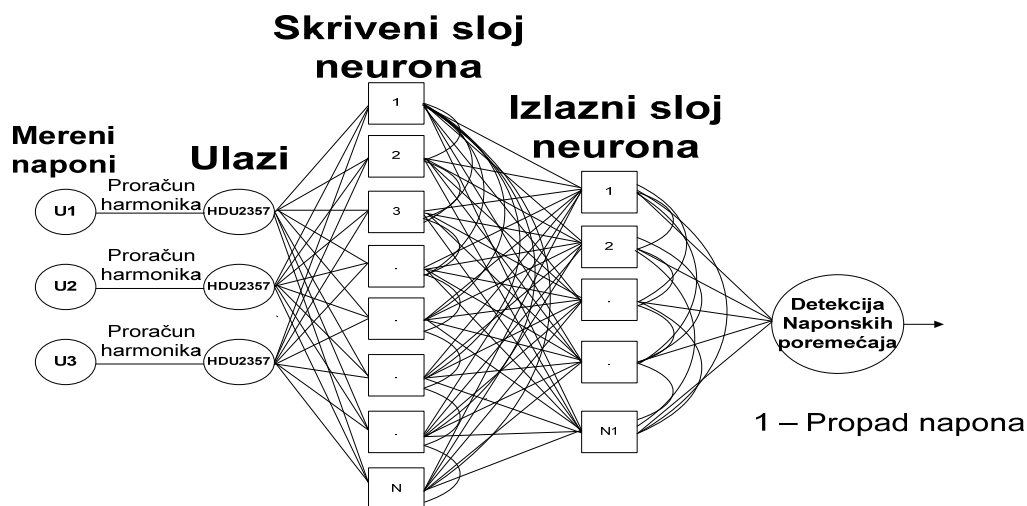
## 5.1 PREDLOG PAMETNE METODE ZA DETEKCIJU PN

U ovom poglavlju biće predstavljena metoda za detekciju propada napona koja svoj rad zasniva na naprednoj, Rekurentnoj neuronskoj mreži i praćenju definisanog nižeg harmonijskog spektra koji se sastoji iz drugog, trećeg, petog i sedmog harmonika.

U cilju ostvarivanja željene brzine detekcije unutar vremenskog intervala od 1 ms nakon nastanka kvara u mreži, za praćenje HO i detekciju specifičnog oblika na početku HO, iskorišćena je napredna neuronska mreža – Rekurentna neuronska mreža (RNN) zajedno sa LSTM [128]. Ova mreža je prilagođena za detekciju naponskih poremećaja u programskom okruženju Python, a takođe su korišćene TensorFlow softverske biblioteke. LSTM je uobičajena primena u slučaju korišćenja TensorFlow biblioteka.

RNN je klasa veštačkih neuronskih mreža (artificial neural network) kod koje veze između jedinica koje sadrže i analiziraju podatke imaju direktnu vezu, tj. ove veze formiraju direktan krug. Ove ciklične veze omogućavaju da RNN ima daleko bolje sposobnosti analize i praćenja šablona kod vremenski promenljivih signala sa kompleksnim zavisnostima, u poređenju sa klasičnim "feed-forward" neuronskim mrežama. Takođe RNN ima izuzetne dinamičke sposobnosti, što su sve prednosti koje su potrebne za brzo reagovanje i detekciju tokom samog tranzijenta nakon nastanka kvara.

Na slici 5.1 prikazana je struktura RNN koja je prilagođena za detekciju propada napona praćenjem HDU2357 i HO, a koja je opisana u radu [43]



Slika 5.1 – Struktura RNN prilagođena detekciji naponskih poremećaja

Nakon merenja napona i digitalizacije signala, a da bi se dobio signal koji je potreban za analizu sa RNN, potrebno je estimirati odabrani set harmonika. Ovaj korak u analizi signala je takođe poznat kao izdvajanje parametara signala. Iz merenog signala napona se izdvajaju odgovarajući harmonici, i nakon toga se računa HDU2357 po formuli:

$$HDU2357 = \frac{\sqrt{\sum_{n=2,3,5,7} U_n^2}}{U_1} \quad (5.1)$$

Izdvajanje harmonika iz signala napona se može obaviti nekom od transformacija iz vremenskog domena u frekventni, kao što su FFT, WT, STFT, itd. Kao optimalni metod za ovu primenu, u radu [43] odabrana je RFFT metoda, pa i u ovom radu za sve transformacije iz vremenskog u frekventni domen koristiće se ova transformacija, primenjena tako da uzima dužinu signala u trajanju cele periode, dok se račun obavlja sa svakim novim uzorkom signala. Ova metoda unosi vrlo malo kašnjenje, koje je zanemarivo u odnosu na ukupno vreme za koje se obavlja detekcija (15  $\mu$ s – vreme potrebno da se izračuna RFFT je višestruko manje od vremena koje protekne između dva uzastopna merenja).

Da bi se RNN prilagodila i iskoristila za detekciju NP, potrebno je obaviti nekoliko stvari.

Prvi korak je dizajn i programiranje same mreže, kao i definisanje ulaza i izlaza. Definisana su tri ulaza, a to su tri signala HDU2357, za svaki od merenih signala napona u 3 faze. Takođe potrebno je definisati signale koji se očekuju na izlazu. Kako je u pitanju detekcija, postoji samo jedan izlaz koji ima dva moguća stanja. Jedno stanje je 0 i ono predstavlja normalno stanje u mreži, dok pojava 1 predstavlja detekciju poremećaja. Dok god u mreži traje kvar, izlaz RNN će biti postavljen na vrednost 1. Iz ovoga se određuje i jedan od dva osnovna parametra poremećaja, a to je dužina trajanja samog kvara. O određivanju drugog osnovnog parametra kvara, kao i mogućnost njegove predikcije će biti objašnjena u poglavlju 6.

Kao dužina signala koji će se analizirati u RNN odabrano je da se koristi dužina signala od 7 vrednosti (merenih uzoraka signala HDU2357).

Nakon što su definisani osnovni parametri i RNN je prilagođena, potrebno je izvršiti obučavanje mreže, tj. oformiti RNN trening algoritam, kako bi ona ispravno detektovala različite poremećaje. Da bi se mreža obučila potrebno je odabrati odgovarajući set signala, i



oformiti bazu u koju će oni biti smešteni. Takođe u svakom signalu se precizno obeležava deo gde počinje odgovarajući šablon koji je potrebno detektovati i koji označava početak kvara. U ovom slučaju je to prvi deo HO, tj. nagli porast (može se aproksimirati kao eksponencijalni), predstavljen u poglavlju četiri, formuli (4.2) kao i na slikama 4.3 - 4.6. Zbog toga što su samo dve mogućnosti moguće za izlaz, dovoljan je relativno mali set signala za obučavanje RNN, ali sa velikom raznovrsnošću i različitim uslovima i kvarovima, i u [43] je odabrano da taj set sadrži signale koji su mereni u realnim mrežama, kao i određen broj signala sa poremećajima koji su dobijeni u kompjuterskim simulacijama na IEEE13 modelu distributivne mreže u koju su dodati distribuirani generatori. Ukupno set za obučavanje je sadržao 10 različitih signala, koji sadrže različite tipove poremećaja. Nakon što je baza sa signalima za obuku mreže formirana, RNN analizira ove signale i „uči” kako da detektuje kvar.

RNN projektovana za ovu primenu ima tri skrivena neuronska sloja, kao i 64 neurona (bloka za obradu podataka) koji čine svaki od slojeva neuronske mreže. Detaljan opis funkcionisanja neuronskih mreža može se naći u dodatku na kraju rada.

Da bi se izbegle pogrešne detekcije kao i da bi se ostvarila visoka pouzdanost metode, potrebno je posebnu pažnju posvetiti izboru signala koji ulaze u trening algoritam, kao i obeležavanje šablona na osnovu kod se vrši detekcija. U bazi podataka za učenje mreže su odabrani signali sa različitim THDU (količina harmonika - suma), kao i signali sa različitim uzrocima i tipovima kvara. RNN je u toku obučavanja analizirao ceo set u 100 prolazaka. Signali koji su korišćeni za obučavanje mreže nisu korišćeni i za testiranje rada algoritma. Ovako obučena i projektovana mreža je nakon testiranja, statistički procenila pouzdanost detekcije na 97.8%, što je i potvrđeno u poglavlju 7 sa kompjuterskim simulacijama, testiranjem sa signalima merenim u laboratoriji kao i sa detaljnim testiranjem sa 127 signala koji sadrže poremećaje a mereni su u realnim distributivnim mrežama na dva različita naponska nivoa.

Kada se završi obučavanje mreže, metod za detekciju je u potpunosti sposoban za rad. U toku rada zbog korišćenja RNN metod ima mogućnost da popravlja svoj rad kao i da dodatno uči i dalje analizira poremećaje u mreži i dopunjava svoju bazu podataka.

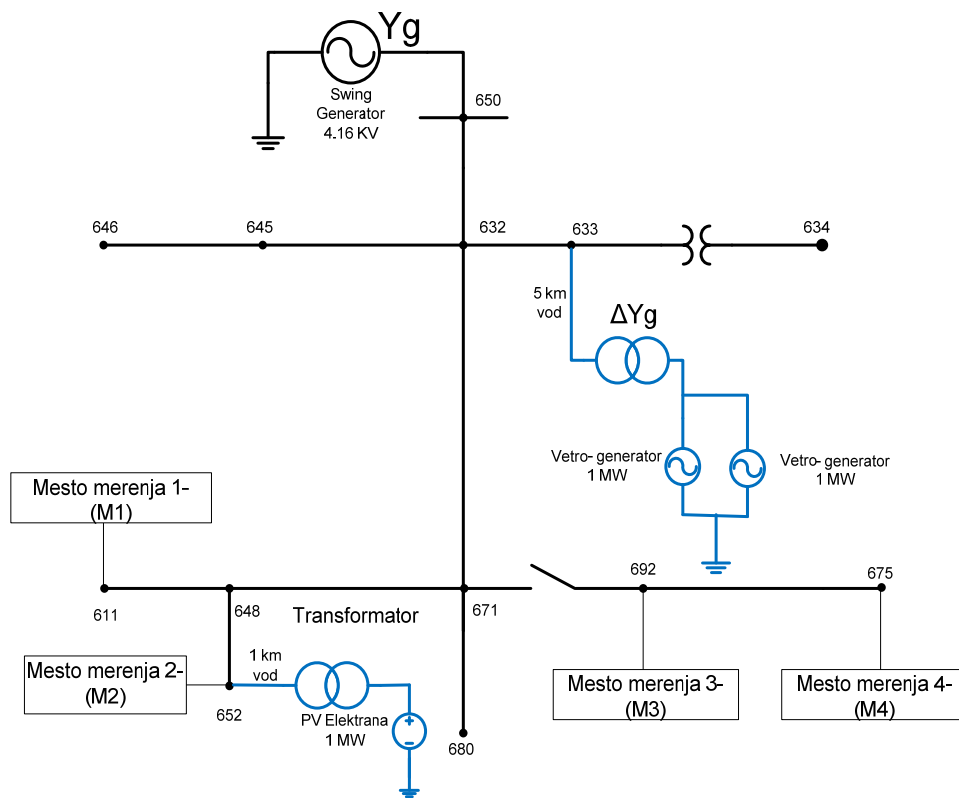
## 5.2 OPIS NAČINA TESTIRANJA

U svrhu testiranja pametne metode za detekciju propada napona korišćeni su signali dobijeni računarskim simulacijama, snimljeni na laboratorijskoj postavci na Fakultetu tehničkih nauka, kao i podaci iz realnih distributivnih mreža. Kako je algoritam urađen u programskom jeziku Python, takođe zahteva rad u ovom okruženju, pa su svi snimljeni podaci prilagođeni i metoda je za signale iz sva tri izvora testirana na računaru, u ovom okruženju.

### 5.2.1 Kompjuterske simulacije

Za kompjuterske simulacije korišćen je programski paket Matlab i Simulink okruženje. U ovom programu je korišćen model IEEE13 test mreže [129], koja radi u najvećoj meri na naponskom nivou od 4.15 KV. Kako je test mreža standardna, i ne uključuje obnovljive izvore energije, prateću uputstva iz rada [122] klasična test mreža je modifikovana sa dva distributivna izvora energije ukupne snage 3 MW. Celokupna potrošnja IEEE13 standardne test mreže je 3.57 MW.

IEEE13 test mreža je dizajnirana za testiranje algoritama u neuravnoteženim trofaznim radijalnim sistemima. Ova test mreža je uprošćen model realne distributivne mreže. Ono što karakteriše ovu mrežu je da je ona kratka, nebalansirana i u značajnoj meri opterećena mreža. Mreža se sastoji od 13 čvorova koji su međusobno povezani sa 10 vodova, ima jedan glavni izvor napajanja kao i dva transformatora (jedan distributivni transformator  $\Delta Y$  115/4.16 KV i jedan linijski transformator YY 4.16/0.480 KV), dve kondenzatorske baterije, kao i neuravnoteženi distributivni potrošači. Umesto postojanja generatora i transformatora  $\Delta Y$  115/4.16 kV u simulaciji je korišćen swing generator (generator koji pokriva zahteve za potrošnjom P i Q) koji radi na 4.16 kV. U simulaciji nije modelovan ni naponski regulator, jer korišćenje swing generatora isključuje potrebu za njim, a takođe je i mreža modifikovana sa DER-ovima. Pojednostavljen model ovako modifikovane IEEE13 test mreže prikazan je na slici 5.2. Na ovoj slici su i obeležena mesta na kojima se u slučaju kvara u mreži posmatra i snima napon.



Slika 5.2 – Uprošćen model IEEE13 test mreže sa dodatim distribuiranim izvorima

U čvoru 633 (čvor 5) povezana je vetroelektrana (2 MW) koja se sastoji od dva vetrogeneratora, svaki snage po 1 MW. Vetroelektrana je povezana sa distributivnom mrežom preko  $\Delta Y (D_{11} Y_g)$  0.575/4.16 KV transformatora i trofaznog voda dužine 5 km.

Korišćeni su modeli DFIG generatora (doubly-fed induction generator). Generator je mašina sa namotanim rotorom, a u modelu postoji i AC/DC/AC konvertor, koji je modelovan preko IGBT-ova (Insulated-gate bipolar transistor) i sa PWM modulacijom. Statorski namotaj je konektovan na mrežu direktno, dok je rotor povezan preko AC/DC/AC konvertora. Generatori imaju po 3 para polova, inerciona konstanta je 0.685 dok je nominalni napon statora 575 V. DFIG tehnologija omogućava da se maksimalna energija iz vetra iskoristi čak i kod malih brzina vetra optimizovanjem brzine turbine, i vrlo je često rešenje kod vetrogeneratora. U modelu je moguće menjati brzinu vetra, kao i ugao turbine u odnosu na vetar. Tokom simulacija menjana je brzina vetra i preko nje je postizana promena proizvedene količine energije. Celokupna vetroelektrana radi po uputstvima datim u

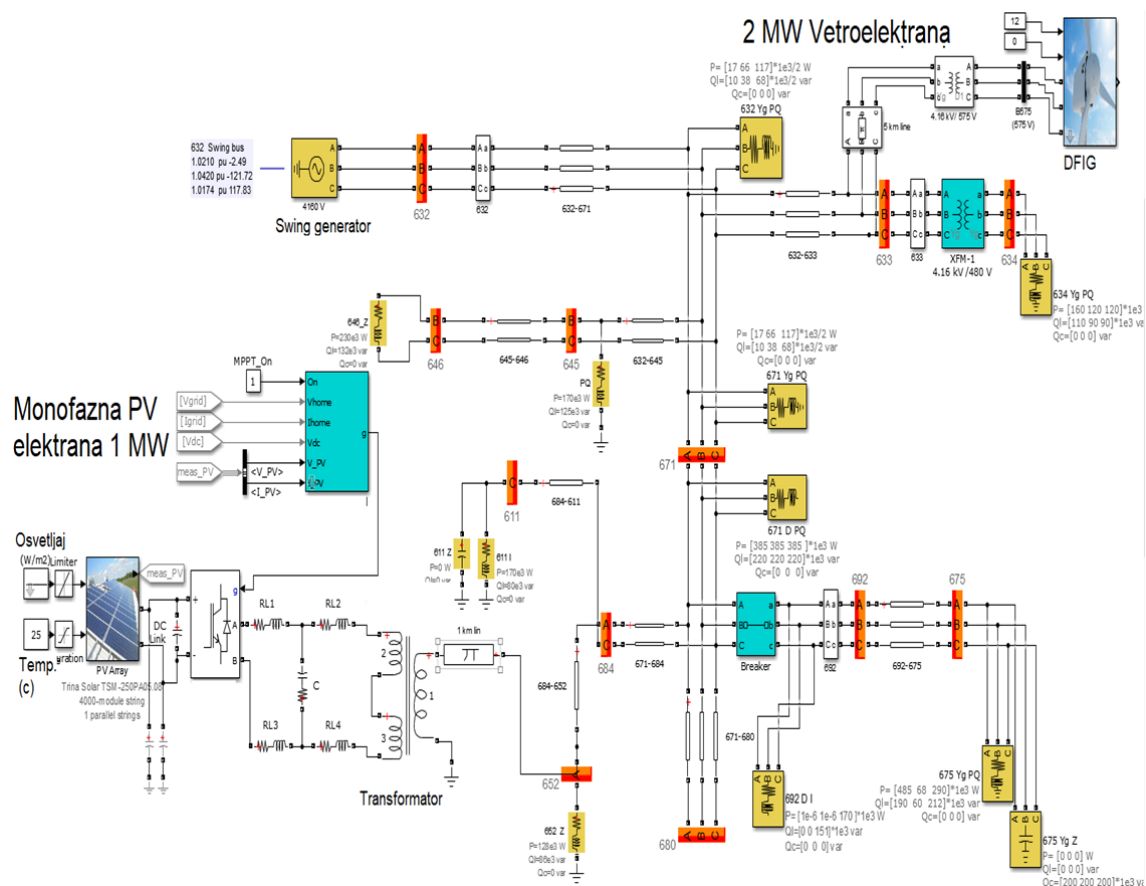
pravilima o radu distributivnog sistema. Nominalna brzina je podešena na 11 m/s, dok je ulazna (brzina pri kojoj počinje proizvodnja – cut-in) 4 m/s. Celokupan model vetrogeneratora je urađen po uzoru na [130].

U čvoru 652 (čvor 11), koji pripada monofaznom delu mreže, priključena je PV (photovoltaic - solarna) elektrana snage 1 MW. Ova elektrana je povezana na mrežu preko monofaznog linijskog transformatora 0.425/4.16 kV i 1 km voda, u fazi 1. Elektrana se sastoji od Andalay solar TW-250-1-AC2-D-B panela koji su vezani u stringove, pa zatim su stringovi povezani paralelno. Paneli su zatim povezani na DC/AC pretvarače (invertore). Invertori su modelovani kao kao pretvarači sa topologijom H-mosta. Kontrolni sistem se sastoji od 5 glavnih celina:

- MPPT-a (Maximum Power Point Tracking),
- PLL i blok za merenje,
- PWM generatora,
- Strujnog regulatora i
- VDC (Voltage DC - DC napon) regulatora.

Kod modela PV elektrane proizvedena snaga se regulisala i menjala u zavisnosti od zadatog osvetljaja i temperature. Nominalna radijacija za korišćene panele je  $1000 \text{ W/m}^2$ , dok je nominalna radna temperatura  $25 \text{ }^\circ\text{C}$ . Model solarne elektrane je urađen po ugledu na [131].

Vetar, solarno zračenje i temperatura se menjaju u vremenu tokom simulacije da bih se simulirali što realniji realni uslovi. Simulacija je izuzetno detaljna, modelovanju distribuiranih izvora kao i uređaja energetske elektronike je posvećena velika pažnja i svi modeli su modelovani tako da pored praćenja klasičnih veličina dinamičke performanse se verno simuliraju. Simulink model IEEE test mreže sa dodatno 3 MW dobijenih iz DER je prikazan na slici 5.3.



Slika 5.3 – Simulink model modifikovane IEEE13 test mreže

### 5.2.2 Laboratorijska postavka

U svrhu testiranja metode korišćeni su i signali koji su snimljeni u Laboratoriji za energetska elektronika Fakulteta tehničkih nauka u Novom Sadu. Ova komplikovana laboratorijska postavka se sastoji od naprednog hardvera u oblasti električnih pogona, kao i pretvarača povezanih na mrežu. Sistem je zasnovan na dSpace modularnom kontrolnom hardveru i industrijskim konvertorima koji su izmenjeni i prilagođeni za laboratorijsku upotrebu [111]. Sistem se sastoji od 7 glavnih komponenti koje su i obeležene na slici 5.4:

1. dSpace procesorske jedinice,
2. Merne i druge dSpace kartice,
3. Energetski pretvarači,

4. Oprema za merenje,
5. Prekidačka i sklopna oprema, u ovom ormanu se nalazi i tačka povezivanja na mrežu,
6. Distributivni transformator,
7. Grid emulator i
8. Električne mašine (potrošači).

Na grid emulatoru GE 15-AC se podešavaju željeni naponski poremećaji, u ovom slučaju konkretno propadi napona. Mogu se zadavati željena dubina propada, fazni pomeraj prilikom starta kvara, kao i specifičan harmonijski spektar, dužina trajanja kvara kao i referentni napon u mreži tokom ustaljenog stanja.

Propad napona koji je podešen na grid emulatoru se prekod transformatora i merne opreme digitalizuje i uvodi u računarski sistem, gde se obrađuje u real-time uslovima RFFT metodom i memoriše. Off-line testiranje ovim signalima koji su snimljeni na opisanoj eksperimentalnoj postavci su izvedeni naknadno na PC računaru, u Windows okruženju i Python programu. Kompletan metoda sa RNN nije implementirana na datom sistemu jer sistem radi isključivo sa Matlab/Simulink okruženjem i bibliotekama koje rade u realnom vremenu. Ali, RFFT metoda za ekstrakciju i izračunavanje HO je implementirana i uspešno testirana. Rezultati RFFT metode u analizi signala propada i brzini detekcije su predstavljeni u [47,76].



Slika 5.4 – Izgled laboratorijske opreme

### 5.2.3 Naponski poremećaji izmereni u realnim distributivnim mrežama

Kao glavni izvor podataka za obučavanje, a i za testiranje pametne metode za detekciju propada napona je baza signala koja se sastoji od 680 snimaka iz distributivnih mreža, koji su mereni na dva različita naponska nivoa. Ovi signali su plod višegodišnjeg merenja i sadrže 127 signala u kojima su zabeleženi najrazličitiji poremećaji u distributivnim mrežama. Veliku zahvalnost autor duguje Prof. Math Bollen-u koji je ustupio ova merenja na korišćenje, koji su dalje omogućili verifikaciju pametne metode za detekciju propada napona. Takođe na osnovu ovih merenja će u poglavlju 6 biti formulisana i statistički dokaza veza između predstavljenog harmonijskog otiska i minimalne vrednosti napona tokom poremećaja, tj način za predikciju dubine propada. Opisi kvarova su takođe dostavljeni zajedno sa merenim podacima, i mogu se videti u tabeli P1 u prilogu.

## 5.3 REZULTATI PAMETNE METODE ZA DETEKCIJU


Mogućnost pametne metode, bazirane na RNN i praćenju harmonijskog otiska za detekciju propada napona su testirani u tri dela sa signalima dobijenim kroz simulacije, sa grid emulatorom u laboratorijskim uslovima i sa signalima naponskih poremećaja iz realnih distributivnih mreža.

## 5.4 REZULTATI RAČUNARSKIH SIMULACIJA

U simulacionom modelu IEEE13 test mreže koja je modifikovana sa 3 MW energije dobijene iz distribuiranih izvora, koji je opisan u poglavlju 6.1. Način na koji je izvršeno dodavanje obnovljivih izvora u distributivnu IEEE13 test mrežu je izabrano kao optimalno u cilju smanjenja gubitaka i u cilju ostvarenja maksimalnog kvaliteta napona (minimalno odstupanje vrednosti napona u čvorovima) u radu [132]. Izvršeno je testiranje simuliranjem 6 različitih kvarova, koji su izazvani na vodu između čvorova 632 i 671. Kvar je simuliran Matlab blokom “three-phase fault”. Ispitivani su odzivi za četiri nesimetrična i dva simetrična kvara, kao što je prikazano u tabeli 5.1. Detaljan prikaz simulacije detekcije propada napona sa setom harmonika HDU2357, ali koristeći samo poređenje sa predefinisanim vrednošću od 5% je predstavljeno u radu [127].

U tabeli 5.1 su predstavljena vremena detekcije koja su ostvarena koristeći pametnu metodu za detekciju baziranu na RNN i praćenu HO. Za 6 različitih kvarova harmonici i

naponi su posmatrani i snimljeni na 4 različita mesta u mreži. Početak i kraj kvara je uspešno detektovan u svih 6 testova koji su obavljani. Potrebno je naglasiti da deo mreže u kome se nalazi mesto merenja 1 (M1) je monofazno, faze C, dok deo mreže gde se nalazi M2 ima dve faze, A i C. Rezultati simulacija su u rasponu od 0.44 ms do 0.96 ms, dok je prosečno vreme detekcije za sve simulacije je 0.687 ms. Pouzdanost metode 100% za signale koji su dobijeni simulacijama. Na slici 5.5 je prikazan jedan primer signala koji je dobijen u simulacijama, (a.) je naponski signal u sve tri faze mereno u M4, (b.) je signal estimiranog seta harmonika HDU2357 i pod (c.) je izlaz pametne metode za detekciju.



Slika 5.5 – Laboratorijski rezultati za kvar #1 : (a.) Napon na M4, (b.) HDU2357, (c.) signal metode za pametnu detekciju



Tabela 5.1 – Rezultati simulacija [15]


Podaci o kvaru			Vremena detekcije [ms]				
	Tip kvara koji se dogodio u mreži	Početak/ kraj propada[s]					
			Fault	M1 <sup>a</sup>	M2 <sup>b</sup>	M3	M4
#1	Faza A sa zemljom	0.05/0.15	0.76	/	0.9	0.76	1.12
#2	Faza B sa zemljom	0.2/0.3	0.9	/	/	1.1	0.96
#3	Faze A i C	0.33/0.72	0.44	0.71	0.66	0.45	0.47
#4	Faze A i B sa zemljom	0.1/0.2	0.51	/	0.64	0.64	0.64
#5	Simetrični kvar	0.15/0.8	0.51	0.67	0.64	0.64	0.65
#6	Simetrični kvar sve tri faze sa zemljom	0.1/1	0.52	0.77	0.64	0.52	0.64
Prosečno vreme detekcije [ms]			<b>0.606</b>	<b>0.716</b>	<b>0.58</b>	<b>0.685</b>	<b>0.746</b>
			<b>0.687</b>				

<sup>a</sup> deo mreže koji je monofazni, faza C; <sup>b</sup> deo mreže koji ima dve faze, A i C.

## 5.5 REZULTATI ANALIZE SIGNALA MERENIH U REALNIM DISTRIBUTIVNIM MREŽAMA

Kao osnovni model za verifikaciju rada pametne metode za detekciju propada napona korišćeni su signali koji su dobijeni praćenjem i merenjem u distributivnim mrežama. U tabeli 5.2 prikazano je za deset naponskih poremećaja vreme koje je potrebno pametnom algoritmu za detekciju da detektuje kvar. Kao referencu dato je i vreme koje je potrebno RMS metodi da detektuje kvar. RMS metoda je implementirana da proračun vrši sa frekvencijom sa kojom se vrši merenje, tj. računa vrednost rms-a napona za svaku novu vrednost (dužina signala koji se analizira jedna perioda). Pametna detekcija ima ogromnu prednost u brzini detekcije za svaki od 10 testiranih propada napona. Vreme detekcije je u rasponu od 0.2 ms

do 2.5 ms, dok je prosečno vreme detekcije 0.9268 ms. Na slici 5.6 je prikazan jedan primer signala koji je dobijen testiranjem sa kvarom #8 iz tabele 5.2. Na slici 5.6 (a.) je prikazan naponski signal u sve tri faze mereno, (b.) je signal estimiranog seta harmonika HDU2357 i pod (c.) je izlaz pametne metode za detekciju. Ono što je vrlo bitno za metode za detekciju je i njena pouzdanost. U tabeli 5.3 prikazano je 127 signala kojima je testirana metoda. Od 127 signala, samo u 3 slučajeva pametna metoda nije bila u stanju da detektuje kvar, tj. harmonijski otisak se nije pojavio u početnim periodama nakon nastanka poremećaja u mreži. Posmatrano u procentima, uspešnost metode je 97.56%, čime je i potvrđena aproksimacija same neuronske mreže o tačnosti koja će biti ostvarena nakon obučavanja metode. Takođe, harmonijski otisak se i u 118 signala pojavljuje i na kraju poremećaja i omogućava i uočavanje početka normalizacije i oporavka posle poremećaja. Izraženo u procentima, u 93% slučajeva je moguće detektovati i završetak propada. U 7 od 9 signala gde nije detektovan završetak kvara u pitanju su složeni poremećaji kod kojih imamo normalizaciju signala u više etapa. U tabeli 5.3 možemo videti kompletan set naponskih poremećaja i objašnjenje da li je kvar uspešno detektova (početak i kraj), u kojim slučajevima nije i koji deo nije uspešno prepoznat.



Slika 5.6 Rezultati analize realnih signala za kvar #8 : (a.) Napon na M4, (b.) RMS, (c.) HDU2357, (d.) signal metode za pametnu detekciju

Tabela 5.2 – Rezultati analize signala iz realnih mreža [15]

Broj kvara	Vreme početka kvara u signalu	Brzina detekcije [ms]	Brzina detekcije RMS [ms]
#1	0.1023 s	0.735 (0.1098 s)	11 (0.1133 s)
#2	0.0896 s	1.2 (0.0908 s)	20.5 (0.1091 s)
#3	0.0708 s	2.5 (0.0733 s)	14.8 (0.0848 s)
#4	0.1035 s	0.9 (0.1044 s)	11.9 (0.1149 s)
#5	0.0623 s	0.4 (0.0627 s)	47 (0.1092 s)
#6	0.0775 s	0.6 (0.0781 s)	25.5 (0.094 s)
#7	0.105 s	0.2 (0.1052 s)	6 (0.1101)
#8	0.1052 s	0.633 (0.10583s)	9 (0.1140 s)
#9	0.1037 s	0.9 (0.1046 s)	2.6 (0.1063)
#10	0.0934 s	1.2 (0.0946 s)	6.9 (0.1003)
Prosečno vreme detekcije [ms]		<b>0.9268</b>	<b>15.52</b>

Tabela 5.3 – Rezultati analize realnih signala radi utvrđivanja pouzdanosti detekcije bazirane na RNN metodi [Da/Ne]

Tipovi kvara	
1. Početak prekida nakon nebalansiranog kvara	Da
2. Tip G, pet perioda, razvija se u tip A, 60 perioda	Da
3. Pad napona, povratak na nominalnu vrednost nije snimljen, snimak od 10 sekundi	Da
4. Propad sa harmonijskim zasićenjem na početku događaja	Da
5. Tip C, 15 perioda, karakteristični fazni pomeraj oko -7 stepeni-dvofazni sa zemljom kvar	Da

Nova metoda detekcije propada napona u mreži sa distribuiranim generatorima
---

6. Tip C, 15 perioda, pomeraj faznog ugla	Da
7. Propad koji se razvija kroz više faza, kvar koji se razvija	Da <sup>a</sup>
8. Tip C, 12 perioda, pomeraj faznog ugla, veoma konstantan rms napona	Da
9. Tip G, 9 perioda. Karakteristični fazni pomeraj oko -50 stepeni	Da
10. Balansirani propad sa nebalansiranim oporavkom	Da
11. Kraj prekida + zasićenje transformatora praćeno velikim harmonijskim izobličenjima	<b>Da<sup>b</sup></b>
12. Nebalansirani propad sa neobičnim oporavkom: motor + transformator?	Da
13. Tip D sa pomerajem faznog ugla, 5 perioda	Da
14. Tip C, 12 perioda, pomeraj faznog ugla, veoma konstantan rms napona	Da
15. Izuzetan višestruki događaj, bez jasnog objašnjenja. Počinje kao Tip C, spori oporavak posle nekoliko perioda; potpuni oporavak; porast u jednoj fazi, a pad u druge dve faze. Linijski naponi su iscertani.	Da
16. Tip C, 10 perioda, pomeraj faznog ugla, veoma konstantan rms napona	Da
17. Trofazni kvar; trajanje kvara oko 70 perioda, oko -50 stepeni pomeraj faznog ugla	Da
18. Oporavak nakon tipa D	<b>Ne</b>
19. Trofazni kvar, trajanje kvara 20 perioda, mali pomeraj faznog ugla	Da
20. Propad napona sa porastom napona u jednoj fazi, moguć dvofazni kvar sa zemljom	Da
21. Propad u dve faze, jedna faza sa porastom napona, 6 perioda	Da
22. Propad napona sa porastom napona u jednoj fazi, moguć dvofazni kvar sa zemljom	Da
23. Tip C, 18 perioda, mali pomeraj faznog ugla, mali uticaj na opterećenje	Da
24. Tip propada C sa dugum trajanjem, mali pomeraj faznog ugla	Da
25. Tip C, 15 perioda, koji se razvija u Tip G, 2 perioda. Propad se razvijao iz propada jedne faze sa zemljom u propad dve faze sa zemljom. Linijski naponi su mereni.	Da
26. Tip D, 30 perioda, neispravan rad prekidača koji dovodi do izobličenja talasa tokom događaja.	Da
27. Kratak propad, verovatno prolazni kvar	Da
28. Početak prekida bez kvara, na početku	Da
29. Magnećenje transformatora sa porastom napona usled harmonika	Da
30. Magnećenje transformatora sa stabilnim porastom napona	Da
31. Tip D, bez skoka, oporavak u dve etape	<b>Da<sup>c</sup></b>

32. Tip C sa 11 perioda koji se razvije u tip A od 6 perioda sa oporavkom u dve etape. Linijski naponi su mereni.	Da <sup>a</sup>
33. Kvar koji se razvija sa oporavkom u dve etape	Da
34. Trofazni kvar, pri čemu postoje razlike u trenutnom oporavku u sve tri faze	Da
35. Tip C sa 11 perioda koji se razvija u tip A sa 3 perioda. Sa pomerajem faznog ugla.	Da
36. Tip F sa 15 perioda koji se razvija u tip A takode sa 15 perioda.	Da <sup>a</sup>
37. Trofazni kvar sa malim pomerajem faznog ugla.	Da
38. Veoma plitak propad samo u plavoj fazi (faza c), 5 perioda (od 434 V rms do 430 V)	Ne
39. Trofazni kvar . Oporavak u dve etape.	Da <sup>a</sup>
40. Tip C, 16 perioda, umeren pomeraj faznog ugla, komplikovan oporavak	Da
41. Tip C, 10 perioda, sa pomerajem faznog ugla, sa određenim uticajem na opterećenjem	Da
42. Početak prekida bez kvara sa porastom napona na početku	Da
43. Tip C, 15 perioda, sa pomerajem faznog ugla	Da
44. Prekid bez kvara sa varničanjem zbog opterećenja motora	Da
45. Trostruki propad zbog kvara u jednoj fazi, sa porastom napona u fazama bez kvara	Da
46. Tip C, 25 perioda, bez pomeraja faznog ugla, konstantan rms napona	Da
47. Nebalansirani propad (Tip C) sa velikim napajanjem mesta kvara od strane mašina prilikom početka propada. Oporavak u dve etape. Spor oporavak posle kvara.	Da
48. Nebalansirani propad (Tip C) sa velikim napajanjem mesta kvara od strane mašina prilikom početka propada. Oporavak u dve etape. Smanjeni naponi nakon kvara. Moguće zaustavljanje indukcionih mašina.	Da <sup>d</sup>
49. Tranzijent (nema propada napona)	Ne
50. Razvoj kvara (kvar koji se razvija)	Da
51. Oporavak nakon tipa C	Da
52. Tip B, 5 perioda (porast napona), razvija se u tip E (porast napona), 3 perioda	Da
53. Tip C, 40 perioda, umeren pomeraj faznog ugla	Da
54. Tip C, 10 perioda, umeren pomeraj faznog ugla	Da
55. Tip C, 2 perioda, razvija se u tip A, 10 perioda. Uključuje pomeraj faznog ugla.	Da
56. 2x Kvar u jednoj fazi sa porastom napona u fazama bez kvara. Oporavak u dve etape. Uopšte nema uticaja opterećenja. Napon u fazi sa kvarom je inicijalno niži.	Da
57. Propad usled kvara u jednoj fazi, nestabilnost, prekid. Ovo bi moglo biti nenamerno izlovanje.	Da

Nova metoda detekcije propada napona u mreži sa distribuiranim generatorima
---

58. Kraj prekida	Da
59. Plitak propad, samo 1% između dve faze	Ne
60. Tip C ili D, veliki pomeraj faznog ugla, 50 perioda. Pomeraj faznog ugla oko -18 stepeni u jednoj fazi, dok nema nikakvih pomeraja faznog ugla u druge dve faze.	Da
61. Tip C, 3 periode, veliki pomeraj faznog ugla. Karakteristični pomeraj faznog ugla od -10 stepeni.	Da
62. Tip C, 7 perioda, razvija se u tip G, 7 perioda.	Da
63. Tip D, dve periode. Karakteristični pomeraj faznog ugla od -40 stepeni.	Da
64. Tip F, 15 perioda. Karakteristični pomeraj faznog ugla od -40 stepeni.	Da
65.2x Početak prekida bez kvara sa varničenjem zbog opterećenja motora	Da
66. Tip C, 15 perioda, razvija se u tip A, 15 perioda.	Da
67. Trofazni kvar, oko dve periode sa uticajem na opterećenje na početku. Veliki pomeraj faznog ugla.	Da
68. Početak prekida bez kvara	Da
69. Trofazni kvar, oko dve periode na početku oseti se uticaj opterećenja. Mali pomeraj faznog ugla.	Da
70. Trofazni kvar, sa veoma konstantnim rms-om napona. Pomeraj faznog ugla od -2 do -5 stepeni ya vreme kvara.	Da
71. Plitak, balansirani propad sa sporim oporavkomč – 3 stepeni je pomeraj faznog ugla, verovatno kvar u distributivnom delu mreže	Da
72. Tip F, 5 perioda. Karakteristični pomeraj faznog ugla od -55 stepeni.	Da
73. Prolazni kvar: dve faze--> jedna faza --> bez kvara, sve za oko dve periode	Da
74. Tranzijent sa povećanjem amplitude praćen prekidom	Da
75. Završetak prekida + zasićenje transformatora	Da
76. Tip D razvija se u tip A posle otprilike 5 perioda	Da
77.3x početak dvofaznog kvara sa zemljom	Da
78. 3x oporavak nakon dugog trofaznog kvara, koji se razvio iz dvofaznog kvara sa zemljom	Da
79. 3x Tip C, 4 periode, mali pomeraj faznog ugla, značajni uticaj opterećenja	Da
80. Tip C, 4 periode, mali pomeraj faznog ugla, značajni uticaj opterećenja, oporavak u dve etape	Da
81. Kvar koji se dugo razvija, od jednofaznog do trofaznog, sa from single-phase to three-phase sa snažnom indukcijom mašinom koja napaja na početku svake nove etape.	Da
82. Propad usled kvara u jednoj fazi, sa porastom napona u fazama bez kvara.	Da
83. 2x Trofazni kvar, oko 5 perioda doprinos motora na početku propada. Pomeraj faznog ugla oko -5 stepeni, znatno veći tokom doprinosa motora.	Da

84. Tip C, 5 perioda, razvija se u tip A, 15 perioda. Nestabilan rms napona.	Da
85. Veoma kratak propad, teško je reći šta je u pitanju.	<b>Da<sup>e</sup></b>
86. Tip D, 15 perioda; Tip F, 30 perioda, Tip A, 5 perioda.	Da
87. Još jedan kvar koji se duže vreme razvija.	Da
88. Trofazni kvar, sa neobičnim tranzijentom u sredini. Moguće da je u pitanju greška pri merenju.	Da
89. Nekoliko perioda tranzijentnog napona i šumova. Moguće da je kvar koji se nije razvio u potpunosti.	Da
90. Trofazni kvar, sa nekim čudnim pikovima. Moguće da je u pitanju greška pri merenju.	Da
91. 2x kvar koji se razvija u jednoj periodu. Počinje kao kvar između dve faze; treća faza se pridružuje jednu period kasnije.	Da
92. Trofazni kvar od dve periode, sa sporim oporavkom. Nema pomeraja faznog ugla.	Da
93. Trofazni kvar od dve periode, sa sporim oporavkom. Nema pomeraja faznog ugla.	Da
94. 3x trofazni kvar u dve periode.	Da
95. Tip C, 25 perioda, oporavak u dve etape.	Da
96. Mali propad napona u tri faze, ostaje na nižem nivou barem 10 sekundi.	Da
97. Pad napona, oporavak nije snimljen, snimano Voltage step down, recovery not recorded, sekundi	Da
98. 2x kratak propad, verovatno prolazni kvar	<b>Da<sup>e</sup></b>
99. Propad napona prilikom magnećenja transformatora	Da
100. Interesantna serija tranzijenata/veoma kratiki propadi praćeni malim porastom u rms napona.	Da <sup>d</sup>
101. Tranzijent sa porastom amplitude, praćen prekidom	Da
102. 2x Tip C, 30 perioda, bez pomeraja faznog ugla, oporavak u dve etape.	<b>Da<sup>b</sup></b>
103. Tip C, 5 perioda, manje-više normalan napon tokom 5 perioda, prekid bez kvara sa veType C, 5 perioda, more-or-less normal voltage during 5 perioda, non-fault interruption with large over-voltages at the beginning.	Da
104. Propad napona prilikom magnećenja transformatora.	Da
105. Tip C, 10 perioda, razvija se u tip A, 30 perioda. Nestabilan rms napona tokom trofaznog kvara.	Da
106. 2x Trofazni kvar, velika impedansa kvara. Impedansa kvara se resetuje na pola puta od kvara.	Da
107. Prekid bez kvara sa malim preostalim naponom između dve faze.	Da
108. Tip C --> Tip F --> Tip A za oko 100 perioda. Povratak napona na nominalnu vrednost nije zabeležen.	Da
109. 8% propad napona u sve tri faze. Trajanje je najmanje 10 sekundi. Povratak napona na nominalnu vrednost nije zabeležen.	Da

<sup>a</sup> harmonijski otisak primećen na početku (ili kraju) svakog dela višestrukog kvara, u odgovarajućoj fazi; <sup>b</sup> bez otiska na kraju kvara; <sup>c</sup> otisak se pojavljuje samo na prvom delu kod višestrukog oporavka od kvara; <sup>d</sup> kraj kvara nije moguće jasno segmentirati; <sup>e</sup> nema otiska na kraju kvara (suviše kratak poremećaj).

## 5.6 REZULTATI TESTIRANJA SIGNALIMA DOBIJENIM U LABORATORIJSKIM USLOVIMA


Kvarovi koji su emulirani na laboratorijskom sistemu su snimljeni i zatim analizirani sa pametnom metodom za detekciju propada napona. Na grid emulatoru je podešeno da kvarovi budu slični onima kakvi su snimljeni u računarskim simulacijama.

Vremena koja su pametnom algoritmu potrebna za detekciju predstavljena su u tabeli 5.4. Pouzdanost metode je za 6 testiranih slučajeva 100%. Vremena detekcije su u rasponu od 0.65 ms do 1.12 ms, dok je prosečno vreme koje je potrebno za detekciju 0.743 ms. Na slici 5.7 predstavljen je vizuelno signal napona, zatim RMS signal, HDU2357, i na kraju nakon obrade HDU2357 signala sa RNN, predstavljen je signal izlaza metode za detekciju, za kvar #1. Zbog toga što između grid emulatora i same laboratorijske postavke postoji distributivni generator, signal koji je emuliran kao kvar jedne faze sa zemljom je izazvao propad u dve faze.

Tabela 5.4 – Rezultati testova sa signalima snimljenim u laboratoriji [15]

Podaci o kvaru			detection time [ms]
	Tip kvara	Fazni ugao na početku kvara [°]	
#1	Faza A sa zemljom	0	0.8
#2	Faza B sa zemljom	45	0.65
#3	Faze A i C	170	1.12
#4	Faze A i B sa zemljom	120	0.53
#5	Simetrični kvar	13	0.72
#6	Simetrični kvar sa zemljom	190	0.64





Slika 5.7 Rezultati analize signala dobijenih u laboratoriji za kvar #1 iz tabele 8.4 : (a.) Naponi u sve tri faze, (b.) RMS, (c.) HDU2357, (d.) signal metode za pametnu detekciju

## 5.7 OCENJIVANJE PREDLOŽENE METODE

Predložena metoda bi se na osnovu rezultata testiranja mogla oceniti najvišim ocenama u oblasti pouzdanosti i brzine detekcije, sa ocenom 5. U cilju procene računске kompleksnosti potrebno je testirati vreme koje je metodi potrebno za proračun na mikroprocesoru.

Ovo testiranje je sprovedeno na PC računaru sa procesorom Intel i5 4690k PC (2013), mereno u Python programskom okruženju (na *Windows 10*<sup>®</sup>) sa funkcijom *process\_time()*. Dobijeni su rezultati u rasponu od 300-350  $\mu$ s, što prevedeno u jedinice koje oslikavaju količinu zauzete procesorske snage iznosi 12.4 DMI (Dhrystone millions of instructions, Dhrystone benchmark, version 2.1 [133]), za jedan ciklus proračuna, tj. za jednu iteraciju. Pri ovakvoj računskoj zahtevnosti, predložena metoda bi zahtevala 86837 DMIPS (DMI per second) ako se odabere visoka perioda odabiranja od 7 KHz. Moderni mikroprocesori imaju mogućnost da podrže ove zahteve, kao primer se može uzeti ARM Cortex-A73 koji ima 4.8 DMIPS/MHz/Cpu\_Core (64 Bit, 2.36 GHz) [134] po jezgri, ako se uzme procesor sa četvororojezgarnim klasterima, jedinica sa 4 klastera ima snagu od čak 181248 DMIPS, što je više od dvostruko potrebne računске snage.

Na osnovu navedenog, za računsku kompleksnost metoda je ocenjena ocenom 2, na skali od 1-5. Ako se uzme isti način ocenjivanja predstavljen u poglavlju 2, i koristeći formulu za proračun ukupnih performansi iz drugog poglavlja, formula (2.6), dobija se ocena  $R^*$  od 4.4, što je značajno više od ocene najbolje ocenjene metode u poglavlju 2 ( $R^*=4$  je ostvarila EKF metoda).

## 5.8 ZAKLJUČAK

U ovom delu je prikazana nova metoda za detekciju propada napona korišćenjem harmonijskog otiska, koji se može definisati kao jedna od karakteristika propada napona u ranom delu tranzijenta kvara u mreži. U užem smislu, harmonijski otisak se može posmatrati kao šablon koji se pojavljuje u signalu seta harmonika tokom tranzijenta propada napona. Usled delovanja zakona fizike, ovaj šablon se prenosi kroz mrežu brže nego redukcija u amplitudi napona, tako da se na ovaj način može značajno ubrzati detekcija propada napona.

Postojanje harmonijskog otiska na početku, kao i na kraju propada napona je potvrđeno analizom izmerenih signala iz stvarnih distributivnih mreža, u eksperimentalnim uslovima kao i analizom signala računarskih simulacija.

Predstavljeni metod za detekciju je "pametan", jer uključuje i veštačku inteligenciju, tj. zaključak da je u mreži propad napona donosi na osnovu analize i detektovanja šablona koji obavlja neuronska mreža. Metod je testiran na svih dostupnim signalima i visok stepen uspešnosti detekcije – preko 97%, kao i velika brzina detekcije – 0.9268 ms su postignuti. Ako se neuronska mreža obuča na odgovarajući način i sa dovoljno velikim setom signala za trening, mogućnost pogrešne detekcije je minimalna.

## **POGLAVLJE 6**

---

### **MOGUĆNOST PREDIKCIJE DUBINE PROPADA NA OSNOVU HARMONIJSKOG OTISKA**

## 6.1 UVOD

Pored brze i pametne detekcije za koju je u dosadašnjem delu rada pokazano da je ostvariva korišćenjem harmonijskog otiska, moguće je ostvariti još jedno unapređenje na bazi HO, a to je da se ostvari predikcija dubine propada napona tokom tranzijenta kvara.

Estimacija tačnih podataka i parametara o stanju u mreži je od izuzetne važnosti za kontrolni sistem uređaja energetske elektronike (pre svega će biti reč o invertorima) koji su povezani na mrežu, kao i uređaja koji služe za praćenje stanja u mreži. Kao deo detekcije stanja u mreži, detekcija propada napona kao i naponskih poremećaja obezbeđuje informaciju o početku poremećaja, ali takođe i estimira parametre poremećaja (propada napona) koji određuju način rada celokupne kontrole invertora. Najbitniji parametar stanja u mreži za rad kontrole u LVRT režimu je amplituda napona tokom propada, tj. minimalna amplituda tokom propada napona u mreži definisana IEEE standardnom 1564-2014 [5]. U ovom standardu je minimalna vrednost amplitude napona (u nastavku će se koristiti skraćenica MAN) definisana kao minimalna vrednost rms napona izračunata koristeći RMS  $\frac{1}{2}$  metod proračuna, tokom celog trajanja propada napona. Na osnovu ovog parametra kvara određuje se vremenski interval tokom kojeg inverter mora da radi u uslovima smanjenog napona (prema pravilima o radu distributivnog sistema, kao što je predstavljeno na slici 1.5), kao i reference aktivne i reaktivne snage koje pretvarač povezan na mrežu treba da preda u mrežu (slika 1.6).

## 6.2 ALGORITMI ZA ESTIMACIJU I PRAĆENJE AMPLITUDE NAPONA

Trenutno se za proračun i praćenje amplitude napona koristi RMS tehnika proračuna koja je i definisana standardima i može se koristiti za praćenje u realnom vremenu. Ako se posmatra napon kao rms vrednost sinusnog oblika napona, i zanemare se svi hamonici i poremećaji u sinusoidi, talasni oblik napona se može zapisati kao:

$$u(t) = \sqrt{2} u \cos(2\pi ft) \quad (6.1)$$

gde je  $u$  rms vrednost napona a  $f$  frekvencija napona. Dalje proračun rms vrednosti napona iz diskretizovanog signala se računa kao:

$$V_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N v_i^2} \quad (6.2)$$

gde je  $N$  broj uzoraka (vrednosti) signala nad kojim se vrši proračun a  $v_i$  je vrednost  $i$ -tog uzorka signala napona.

Ipak, precizan proračun amplitude napona, posebno tokom tranzientnih promena u signalu nije moguće ostvariti RMS metodom. Kada su naponi u potpunosti simetrični i bez poremećaja i šumova, svaka metoda daće isti rezultat. Nesimetrični naponski signala koji sadrže šum dovode do toga da različite metode daju različite rezultate [38].

Moguće je amplitudu napona pratiti i preko maksimalne vrednosti amplitude koristeći formulu:

$$V_m = \frac{\max(|v_0|, |v_1|, |v_2|, |v_3|, \dots, |v_N|)}{\sqrt{2}} \quad (6.3)$$

gde je  $N$  broj odbiraka signala koji se koristi za analizu, a  $v_i$  je  $i$ -ti odbiran napona. Implementacija ovog metoda nije jednostavna kao prethodna jer se mora prvo primeniti filter da se odstrane iz signala visoke frekvencije (low-pass filter). Kada se uzima vrednost maksimuma nad određenim brojem perioda trebalo bi se koristiti neka od metoda usrednjavanja da bi se izbeglo da se dobiju rezultati koji imaju nerealno velike vrednosti.

Treći način za proračun i praćenje amplitude napona je proračunom apsolutne vrednosti osnovnog harmonika:

$$V_{h1} = |V_1| \quad (6.4)$$

gde je  $V_1$  kompleksna vrednost osnovnog harmonika dobijenog preko bilo koje od transformacija iz vremenskog domena u frekventni [38]. Proračun osnovnog harmonika je definisan i poznat postupak koji u većini slučajeva daje slične rezultate koji bi se dobili i praćenjem rms vrednosti. Ova vrednost se naziva još i fundamentalna ili osnovna vrednost napona. Razlika između ovako dobijene vrednosti i rms vrednosti je totalno harmonijsko izobličenje (THD) napona:

$$V_{rms} = V_{h1} * \sqrt{1 + THD^2} \quad (6.5)$$

Uobičajen metod izračunavanja amplitude napona je onaj koji je prvi opisan, preko direktnog računanja rms vrednosti, iako po Bollen-u [38] nema ni jednog očiglednog razloga za to. Ova rms vrednost napona se koristi da se definišu i utvrde performanse svih vrsta opreme. Metod estimacije preko izračunavanja fundamentalne vrednosti (6.4) napona se koristi za proračun transfera energije ka većini rotacionih mašina koje rade u motorskom režimu, jer sve druge komponente samo unose promenljive momente i gubitke. Proračun amplitude preko

maksimalne vrednosti (6.3) ima svoju primenu u posmatranju rada mnogi elektronskih uređaja, gde se posmatra nivo (često DC) napona a ne rms vrednost.

Takođe, u literaturi postoje i napredne metode za praćenje u realnom vremenu ovog parametra napona [81,87]. U radu [81] predstavljen je proračun osnovnih parametara kvara, koristeći dva algoritma, algoritam simetričnih komponenti i šestofazni algoritam. Pokazano je da zbog načina proračuna i prelaska na simetrične komponente ovaj metod u određenim slučajevima (za određene tipove kvara) neminovno dovodi do grešaka. Metod simetričnih komponentata takođe je pokazao da greši kod kvarova koje uzrokuju mali pad u amplitudi napona (plitki propadi), kao i za srednje velike redukcije u amplitudi ali u slučajevima kada su praćeni velikim pomerajem u faznom stavu. Šestofazni algoritam je takođe pokazao određene mane i probleme, posebno za slučajeve kada je tokom kvara dolazilo do velikih rotaciju u pozitivno-negativnom faktoru (PN) faktoru propada. PN faktor je posledica toga da pozitivna i negativna komponentata impedanse nije potpuno jednaka. Ovo dovodi do propada napona i u fazama koje nisu u kvaru tokom kvara jedne faze sa zemljom [135]. U [87] predstavljen je novi metod za karakterizaciju kvara i proračun njegovih parametara koji kombinuje nekoliko metoda, KF, WT kao i fazi logiku. U radu je prikazano da metod je u stanju da izračuna amplitudu i tokom promena u mreži sa visokom tačnošću, kao i trajanje kvara i harmonike.

Na kraju pregleda metoda za proračun amplitudu napona kao i njegovo praćenje potrebno je istaći da i klasične metode, kao i napredne, izračunavaju u najboljem slučaju precizno trenutnu vrednost amplitude koja je u mreži, bez indicija i poznavanja bilo kakve informacije o daljoj promeni vrednosti amplitude napona.

U cilju analize naponskih poremećaja razvijen je i veći broj metoda koje imaju mogućnost predikcije broja kao i parametara kvara (amplitude propada napona i frekvencije događaja) u određenom vremenskom intervalu [136–139]. U radu [136] je rečeno da metode za predikciju su potrebne za kvantifikovanje sa aspekta kvaliteta električne energije za potrošača. U ovom radu dati su pravci razvoja „offline“ predikcije kao i osnovne tehnike razvijene do tad. Kao jednostavnije su istaknute metoda kritične udaljenosti i data su uputstava za jednostavan proračun predikcije koji omogućava da se izračuna uz određene pretpostvke moguća dubina kvara za kvar na svakom mestu u mreži, i da se estimira njegovo trajanje na osnovu poznavanja parametara i osobina, kao i radu relejne zaštite mreže. Takođe su istaknuta i mnoga ograničenja ovakvog metoda, na primer kada mreža nije radijalna već je upetljana, a

potrebno je izračunati i predikovati moguće MAN kao i dužine trajanja kvara, ili kada je potrebno uzeti u obzir i moguće događaje poput otkazivanja zaštitne opreme u obzir ili slično, kao i ako su netipični potrošači prisutni, kao na primer ako postoji veća koncentracija velikih motora, pa može doći do promene brzine opadanja napona tokom kvara, kao i oblika napona. Zaključeno je da je u slučajevima gde jednostavne metode ne zadovoljavaju ili imaju limite koje nije moguće prevazići, potrebno je iskoristiti metode zasnovane na stohastičkoj analizi, koje su naprednije i nemaju ove probleme. U [137] su opisane i prednosti i mane metode kritične udaljenosti, zatim metod pozicije kvara ali i napredne metode bazirane na stohastičkoj predikciji. U ovom radu je zaključeno da rezultati dobijeni metodom kritičnih udaljenosti su prihvatljive tačnosti i da ova metoda se može preporučiti za predikciju MAN. Za metod koji je baziran na poziciji kvara je zaključeno da ima prednosti i da ga je optimalno koristiti za predikciju učestanosti kvarova. Za napredne metode bazirane na stohastičkoj predikciji je zaključeno da su one najsloženije i da daju najbolje rezultate, i da ih autori preporučuju za implementaciju u softverskim alatima za predikciju.

U radu [138] predstavljena je konkretna primena stohastičke predikcije kao dodatnog parametra u planiranju elektroenergetskih mreža. Pored stohastičke predikcije korišćene su i Monte Karlo simulacije na kojima je celokupan metod planiranja mreže i zasnovan. Pored ovih metoda, implementiran je i koncept podele odgovornosti između operatera mreže i korisnika, koristeći krivu koja opisuje odgovornost za izazivanje propada napona. Za testiranje metode korišćena je IEEE RTS test mreža (one area Reliability Test System 96). Zaključeno je da je stohastička metoda uspešno predikovala parametre i broj kvara, a da je celokupan metod da zadovoljavajuće rezultate. Napredan i vrhunski metod za predikciju učestanosti zasnovan na stohastičkoj predikciji propada napona i njegovih parametara je prikazan u radu [139]. Glavna prednost i originalnost ovog rada je to što ne zanemaruje prilikom predikcije mogućnosti otkazivanja određenih komponenti i relejne zaštite, i modeluje i mogućnost otkaza ove opreme kao još jedan parametar tokom predikcije. Pokazano je da metod može da izvrši predikciju učestanosti određenog tipa kvara, podeljeno u nekoliko kategorija po amplitudi vrednosti napona kao i trajanju. U ovom radu je zaključeno da klasične metode zasnovane na stohastičkoj predikciji koje vrše zanemarenje mogućnosti otkaza zaštitne opreme u mreži prave grešku u predikciji parametara kvara, pa i MAN. Metod predstavljen u ovom radu uzima u obzir i ovu verovatnoću, što ga čini kompleksnijim za proračun od ostalih metoda, ali i daje bolje rezultate.



### 6.3 ORIGINALNOST I PREDNOSTI PREDLOŽENE METODE ZA PREDIKCIJU

Sve predstavljene metode za predikciju parametara propada napona (trajanja kvarova i MAN) kao i broja propada napona su offline metode, koje daju predviđanja koja su zasnovana na poznavanju određenih parametara mreže i zasnovane su na mnogim pretpostavkama koje se donose na bazi iskustva. Svaka pretpostavka ostavlja prostor za moguće greške. Takođe, ove metode donose generalna predviđanja, tj. predikcije za određeni vremenski period (najčešće godinu dana), i ne daju ni okvirni podatak kada se koji od predikovanih kvarova može pojaviti, ili nakon same detekcije koji je kvar baš u tom trenutku se dogodio u mreži.

Metoda za predikciju MAN parametra propada predstavljena u ovom radu je zasnovana na online praćenju harmonika i odgovarajućoj zavisnosti, takođe daje sa velikom tačnošću predikciju dubine propada za kvar koji je započeo, tj. detektovan je u mreži, i obaveštava opremu sa vremenskim predviđanjem u rasponu od nekoliko desetina milisekundi pa do nekoliko stotina milisekundi koliko će propad napona biti dubok, i da li će doći do potpunog prekida napajanja.

### 6.4 ANALIZA ZAVISNOSTI PARAMETARA – TEORIJSKE OSNOVE

Da bi se dokazalo postojanje zavisnosti između dubine propada napona i odabranog seta harmonika HDU2357, tj. njegove maksimalne vrednosti tokom tranzijenta (MHDU2357) korišćeno je nekoliko statističkih metoda. Samo dokazivanje zavisnosti kao i nalaženje funkcije zavisnosti (predikcije) je ključno, i ono omogućava dalje formiranje algoritma i uspešnu predikciju.

Za statističke analize korišćen je softverski paket Minitab, koji je specijalizovan za statistička istraživanja. Za dokazivanje postojanja zavisnosti korišćen je Pearson-ov test korelacije, i P-vrednost je izračunata i predstavljena. Takođe "goodness-of-fit" statistički testovi su korišćeni, čiji ključni rezultati su grafik sa predstavljenom tačnošću aproksimacije ("fitted-line plot") kao i vrednosti R-sq, R-sq(adj.) i vrednost parametara koja predstavlja grešku i od ključne je važnosti, i obeležava se slovom – S. Svi korišćeni parametri su u narednom tekstu ukratko objašnjeni.

### 6.4.1 Pearson-ov koeficijent korelacije (PCC)

Ovaj koeficijent je poznat i često korišćen za merenje i kvantifikaciju korelacije tj. zavisnosti. Moguće vrednosti su od 1 do -1. Ako koeficijent ima vrednost 1 to predstavlja savršenu direktnu zavisnost ispitivanih vrednosti, dok je -1 savršena obrnuta, tj. inverzna zavisnost. Ako vrednost koeficijenta je 0, onda ne postoji veza, dok vrednosti oko 0.3 predstavljaju slabu zavisnost (korelaciju), oko 0.5 umerenu direktnu zavisnost, a 0.7 je jaka direktna zavisnost. Isti rang je i za inverznu zavisnost, -0.3 je slaba zavisnost, -0.5 umerena, dok je -0.7 jaka zavisnost.

### 6.4.2 P-vrednost

P-vrednost je statistički parametar koji daje podatak o tačnosti hipoteze koja se dokazuje i za koju se vrši test, predstavljajući verovatnoću da se pretpostavljena hipoteza odbacuje i da se alternativna prihvata, tj. u slučaju da je vrednost dovoljno mala hipoteza je tačna i prihvata se. Uobičajeno je da ako je ova vrednost manja od unapred definisanog nivoa pouzdanosti (najčešće se usvaja vrednost 0.05 i obeležava sa  $\alpha$  ili alfa) može se smatrati da je rezultat dobar i da ima statistički značaj [140].

### 6.4.3 S – standardna greška regresije

Vrednost standardne greške regresije, koja se obeležava sa S, predstavlja prosečnu udaljenost stvarnih vrednosti od linije koja je data regresijom, tj. modelom. Ova vrednost predstavlja grešku koja je napravljena, tj. kolika je prosečna greška modela regresije kada se posmatra usrednjeno u odnosu na stvarne vrednosti koje se analiziraju. Manja vrednost predstavlja bolji rezultat, tj. to znani da su stvarne vrednosti bliže modelu regresije. Ako je vrednost S manja ili jednaka 2.5, to predstavlja dobar rezultat

### 6.4.4 R-Sq

Procenat uspešnosti modela da opiše određeni uzorak se predstavlja parametrom R-sq, koji se još uobičajeno označava i kao  $R^2$ , a prevod bi bio R na kvadrat (R-squared). Ono što karakteriše ovaj parametar je da što je vrednost veća, to je bolja tačnost modela kojim se opisuje neka pojava, ili pretpostavke koja se dokazuje. R-sq može imati bilo koju vrednost između 0-100%, a izražava se u procentima. Vrednost ovog parametra uvek raste ako se doda dodatni prediktor (činilac) u model. To dovodi do toga da iako je dobar pokazatelj preciznosti

modela, ovaj parametar je najbolje koristiti sa još nekim statističkim testom ili metodom, kao što je na primer grafik reziduala, što je i korišćeno u ovom radu u kombinaciji sa R-sq.

#### **6.4.5 R-Sq (adj.)**

R-sq (adj.) je parametar koji ima slično značenje kao R-sq, samo koji je preporučeno da se koristi kada pri izboru modela mogu da se koriste različit broj prediktora. Za predikciju i formiranje funkcije je korišćen samo jedan parametar tj. prediktor, tako da je podatak R-sq dovoljan, iako je izračunat i R-sq(adj.) koji je dao slične vrednosti.

### **6.5 REZULTATI ISPITIVANJA PREDLOŽENE METODE PREDIKCIJE**

#### **6.5.1 Analiza korelacija bazirana na snimcima propada napona iz distributivnih mreža**

Na osnovu analize signala naponskih poremećaja, među kojima prevladavaju propadi napona, prikazani u tabeli P1, urađena je statistička analiza u cilju dokazivanja postojanja zavisnosti između MHDU2357 i minimalne amplitude napona tokom propada napona (MAN). Prvo je urađena statističkoj analiza za propade dobijene u računarskim simulacijama, za 10 različitih slučajeva, a zatim je analizirano 110 signala iz realnih distributivnih mreža. Takođe je izdvojeno i 10 signala iz realnih mreža koji su korišćeni isključivo za testiranje predložene funkcije za predikciju kao i rada metode. Od 680 snimanja u mreži, 122 od njih sadržalo je nekoliko tipova poremećaja u naponu, propad, prekid ili neki drugi poremećaj, merena na dva različita naponska nivoa u distributivnoj mreži. U tabelama P1 i P2 su prezentovani opisi svih 122 poremećaja, zajedno sa MoVS [%] i maksimumom HDU2357 [%] (MHDU2357).

Od 122 poremećaja, 112 je predstavljeno u tabeli P1. Od ovih 112 snimanja, 6 njih sadrži samo oporavak nakon kvara, oni nisu korišćeni za statističku analizu i označeni su podebljanim fontom (snimci: #11, #18, %51, #58, #75 i #78). Ostalih 106 snimaka iz tabele P1 su korišćeni za statističku analizu i estimaciju korelacijske funkcije, a rezultati su predstavljeni u sledećem delu.

U tabeli P2 predstavljeno je 10 složenih poremećaja, koji sadrže nekoliko tipova propada napona. Ovi rezultati su korišćeni za testiranje preciznosti predikcije predložene funkcije.

Za analizu je korišćen statistički softver Minitab. Za fitovanje funkcija korišćen je "Fitted Line Plot". Primenjen je Pearson-ov korelacioni test i izračunata je P-vrednost za ovaj test.

Takođe su korišćeni “goodness-of-fit statistics” čiji su ključni rezultati predstavljeni na grafiku sa prikazanim poklapanjem i u tabeli I (R-sq, R-sq (adj) and S).

### 6.5.2 Rezultati analize korelacija

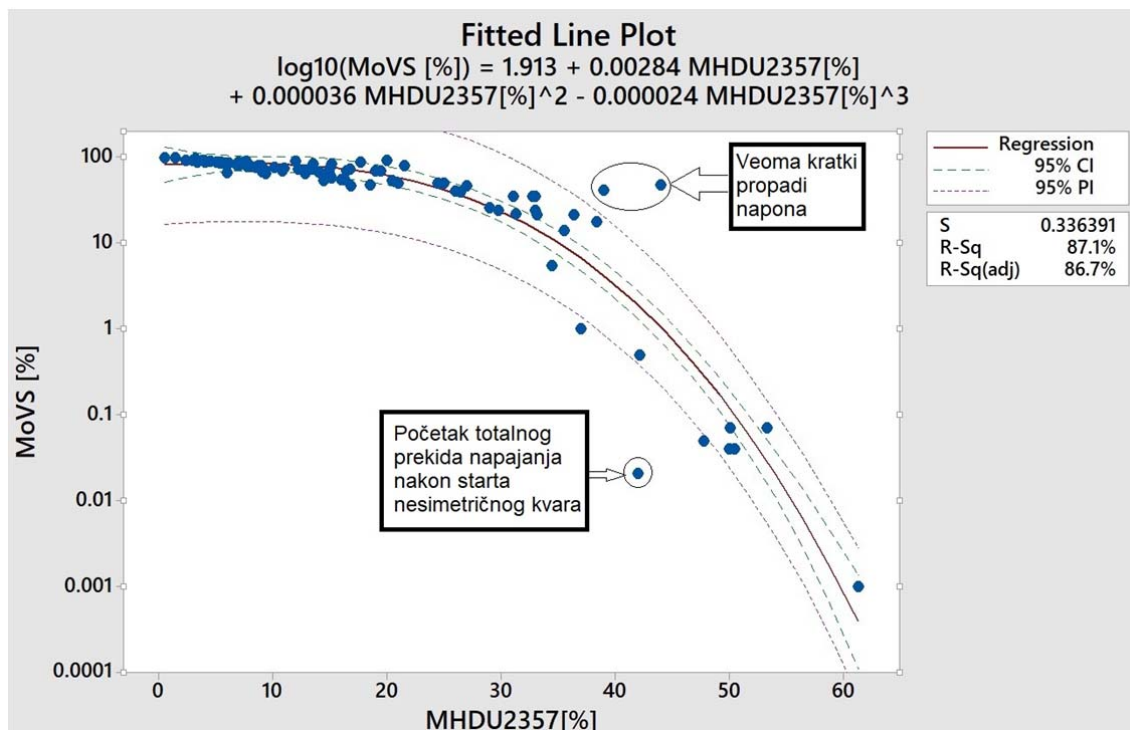
Da bi se analiziralo postojanje veze (korelacije) između MHDU2357 i MoVS vrednosti, nekoliko statističkih testova je korišćeno. Rezultati ovih testova su bazirani na 106 uzoraka (primeraka) (predstavljenih u tabeli P1) i prikazani su u tabeli 6.1. *PCC* je -0.937, što označava jaku, skoro savršenu negativnu vezu (korelaciju) između ova dva parametra kvara. *P*-vrednost za ovu vezu (korelaciju) je 0.000, što znači da je stvarna *P*-vrednost manja od 0.0005, odnosno verovatnoća greške je veoma niska. Dobijena *S* vrednost je 0.336, što znači da je većina vrednosti blizu linije poklapanja. *R-sq* je 87.1 i *R-sq(adj)* je 86.7 što je dobar rezultat. Može se zaključiti da postoji veza (korelacija) između veličine propada napona i MHDU2357, sa snažnom statističkom potvrdom. 106 merenja koja su korišćena za ovu statističku analizu su veoma dobar statistički uzorak, ne samo zbog dovoljnog broja uzoraka, već i zbog njihove raznovrsnosti. Osim toga, na vezu se ne može uticati normalizacijom, jer su i veličine napona i veličine osnovnih harmonika korišćene kao konstante (tokom normalnih uslova u mreži).

Tabela 6.1 Statistički rezultati analize 106 kvarova

	A Pearson correlation	P-value (<0.05)	S	R-sq [%]	R-sq(adj) [%]
#1	-0.937	0.000	0.336	87.1	86.7

### 6.6 PREDIKCIJSKA FUNKCIJA (FUNKCIJA PREDVIĐANJA)

Na slici 6.1 je predstavljena linija poklapanja stvarnih vrednosti sa funkcijom koja predikuje potencijalne dubine propada. Kao pokazatelji su korišćeni MDU2357 (x-osa) i MoVS (y-osa).



6.1 Fitovani grafik poklapanja predikcione funkcije sa stvarnim vrednostima


Korišćen je kubni model sa logaritamskom transformacijom i ( $\text{MoVS}^*$ -predikovana vrednost) sa 95.0 nivoom pouzdanosti. Linearni, kvadratni i kubni model bez transformacije i linearni i kvadratni model sa transformacijama (sve kombinacije) su isprobane pre nego što je prezentovani model izabran kao najtačniji.

Može se primetiti da samo 3 vrednosti divergiraju od 95% predviđenog interval, a dve su veoma blizu granice od 95%. Stoga, sledeća funkcija predikcije može biti predložena:

$$\begin{aligned} \log_{10}(\text{MoVS}^*) &= 1.913 + 0.00284 \cdot \text{MHDU2357} \\ &+ 0.000036 \cdot \text{MHDU2357}^2 \\ &- 0.000024 \cdot \text{MHDU2357}^3 \end{aligned} \quad (6.6)$$

Na slici 6.2 prikazan je grafik reziduala. Rezidual je razlika između opažene vrednosti zavisne promenljive, u ovom slučaju merenih vrednosti dubine propada napona, i vrednosti

promenljive koju predviđa model. Grafik reziduala je koristan kao dodatna potvrda korelacije (veze) između funkcije predikcije i samih podataka. Važno je da nema očigledne vizuelne korelacije na grafiku reziduala, tj. podaci su nasumični. Takođe, može se primetiti da su reziduali veoma male vrednosti, što je jaka potvrda preciznosti kojom predikciona funkcija opisuje stvarne vrednosti propada napona.



6.2 Residuali u odnosu na fitovane vrednosti

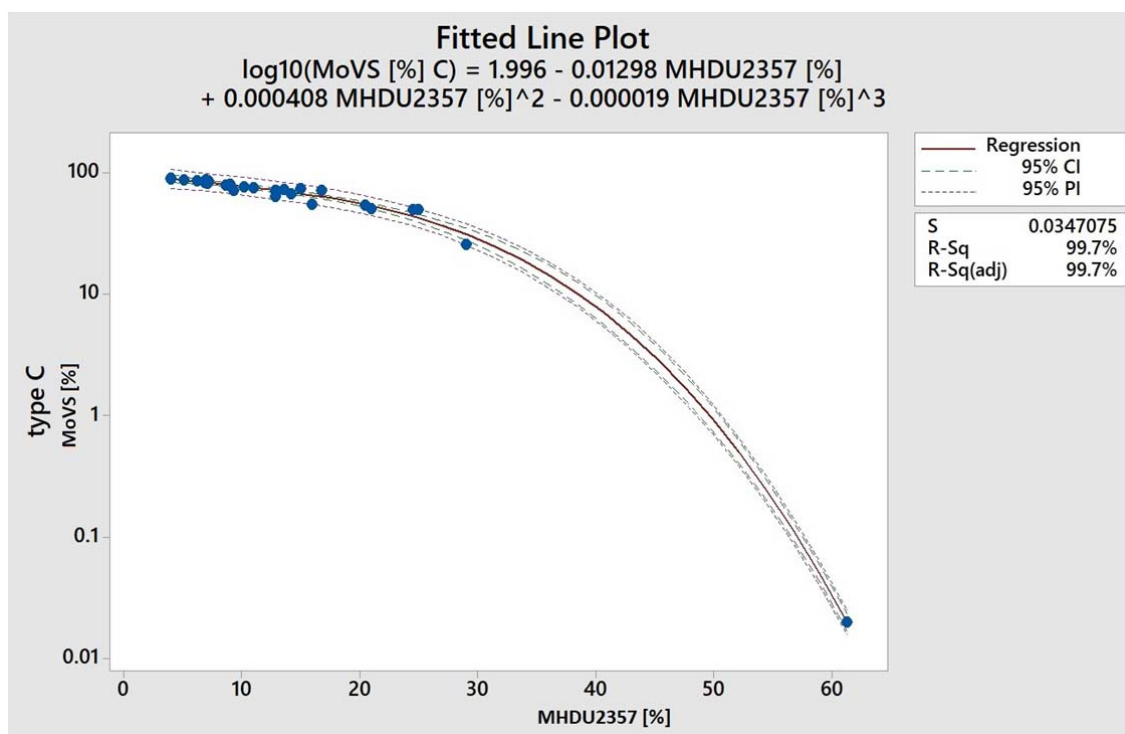
Generalni model za sve merene poremećaje napona ne može biti veoma precizan, zbog svoje generalnosti. Da bi se predstavio potpuni potencijal ove korelacije, koliko je jaka veza odabranog skupa MHDU2357 sa MoVS i koliko precizan može biti model, kada se redukuje njegova generalnost, analizirano je 30 poremećaja koji sadrže tip C propada napona. Rezultati su predstavljani u tabeli 6.2 i na slikama 6.3 i 6.4. Sa slike 6.3 može se primetiti da je  $S$  0.0347075, a preciznost predstavljene funkcije je 99.7 %. Osim toga, nijedan od uzoraka nije izvan 95% predviđenog interval.

Tabela 6.2 Statistički rezultati analize 30 signala koji sadrže C tip kvara

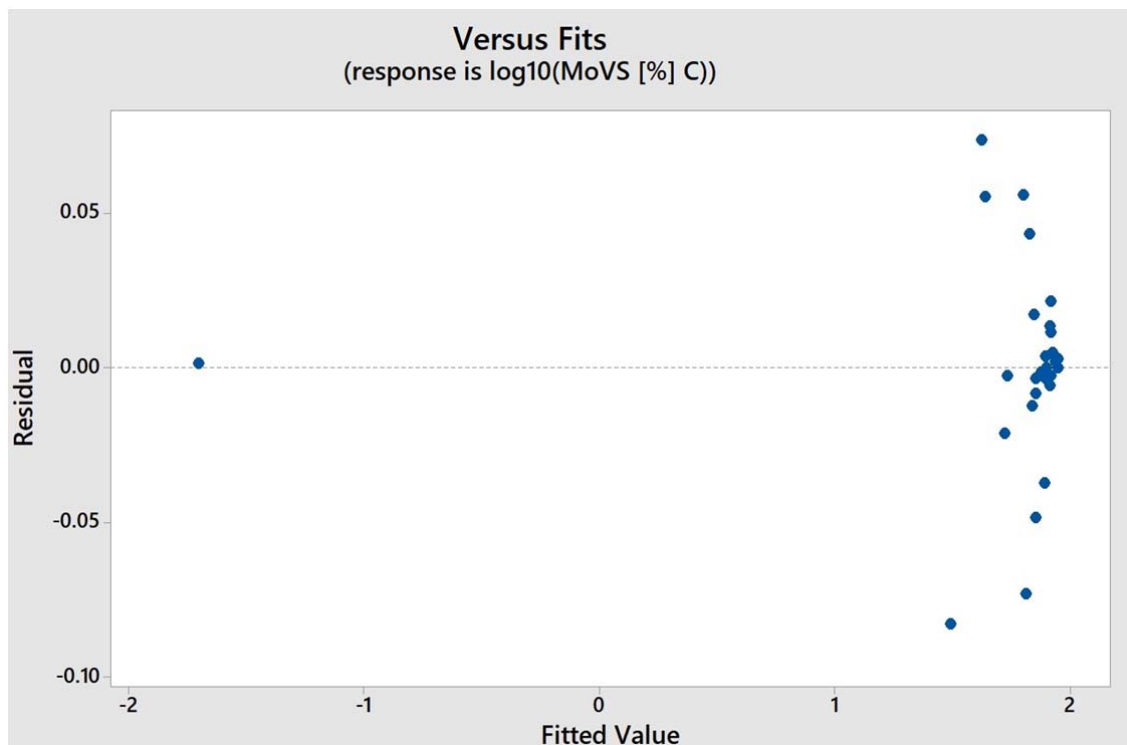
	A Pearson correlation	P-value (<0.05)	S	R-sq [%]	R-sq(adj) [%]
#2	-0.957	0.000	0.0347	99.7	99.7

Funkcija predikcije za propade tipa C je:

$$\begin{aligned} \log_{10}(\text{MoVS}^*) &= 1.996 - 0.01298 \cdot \text{MHDU2357} \\ &+ 0.000408 \cdot \text{MHDU2357}^2 \\ &- 0.000019 \cdot \text{MHDU2357}^3 \end{aligned} \quad (6.7)$$



6.3 Fitovani grafik poklapanja funkcije predikcije sa stvarnim vrednostima samo za propade C tipa



6.4 Reziduali u odnosu na fitovane vrednosti, samo za propade C tipa

## 6.7 ALGORITAM ZA PREDIKCIJU MAN-A

Algoritam za predikciju MAN-a može biti implementiran zajedno sa blokom za detekciju propada napona kako bi pomogao u estimaciji MAN-a i ukazao na dubinu propada napona tokom kvara koji se još uvek razvija. Moderni algoritmi za detekciju propada napona imaju veliku brzinu detekcije i obezbeđuju informacije o početku kvara mnogo pre nego što napon opadne u potpunosti. Algoritam se aktivira odmah nakon detekcije propada napona, računaju se potrebne vrednosti i daje se predikcija dubine propada. Na slici 6.5 prikazano je kako kao dodatak informaciji o početku propada, predikovana vrednost MAN može biti korišćen kao indikator ozbiljnosti poremećaja u svrhu poboljšanja LVRT.

HDU2357 je u ovom radu korišćen i računat kao:



$$HDU_{2357} = \frac{\sqrt{\sum_{n=2,3,5,7} U_n^2}}{U_1} \cdot 100 \text{ [%]} \quad (6.8)$$

gde je  $U_1$  amplituda osnovnog harmonika.

$HDU_{2357}$ , odnosno harmonijski otisak, ima karakterističan oblik, koji izgleda kao vrh planine. Funkcija predikcije računa amplitudu napona kao funkciju maksimalne vrednosti harmonijskog otiska:

$$MoVS^* = f(MH DU_{2357}) \quad (6.9)$$

gde je  $MH DU_{2357}$  globalni maksimum  $HDU_{2357}$  tokom tranzijentnog perioda. Globalni maksimum  $HDU_{2357}$  može biti definisan kao:

$$MH DU_{2357} = \max(HDU_{2357}) \quad (6.10)$$

Ili

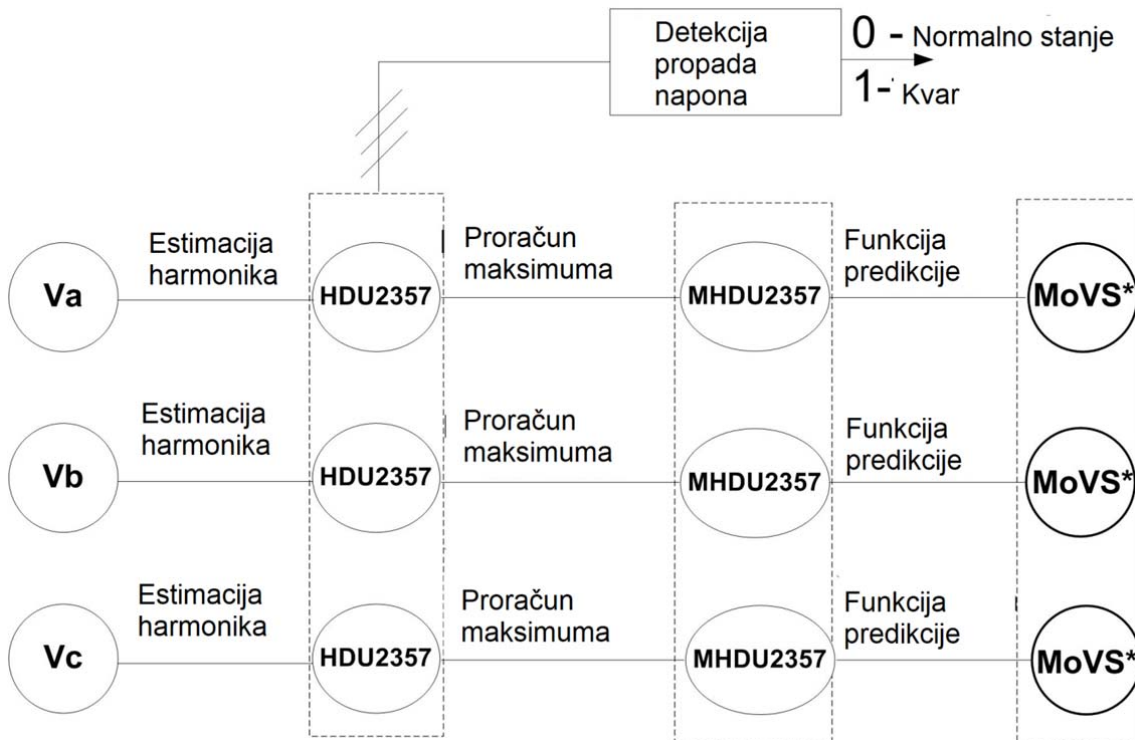
$$\begin{aligned} f'(HDU_{2357}) &= 0, \\ HDU_{2357} &= f(t), t \in I \end{aligned} \quad (6.11)$$

gde je  $I$  interval tokom tranzijenta,  $t$  je vreme,  $f'(HDU_{2357})$  je prvi izvod funkcije koja predstavlja skup (set) harmonika tokom tranzijenta.

Algoritam za detekciju propada napona i predikciju MAN-a sastoji se od nekoliko koraka, kao što je prikazano na slici 6.5. Na ovoj slici je blok za analizu i predikciju dubine propada uključen u blok za detekciju propada napona.

Detekcija propada je urađena korišćenjem harmonijskog otiska ( $HDU_{2357}$ ) kao što je opisano u [15]. Prvi korak je izdvajanje harmonika iz signala napona i proračun  $HDU_{2357}$  koristeći (6.8). Dalje, kada se detektuje propad napona generiše se signal, koji nam govori o nastanku kvara u mreži i aktivira proračun predikcije MAN. Sledeći korak je proračun

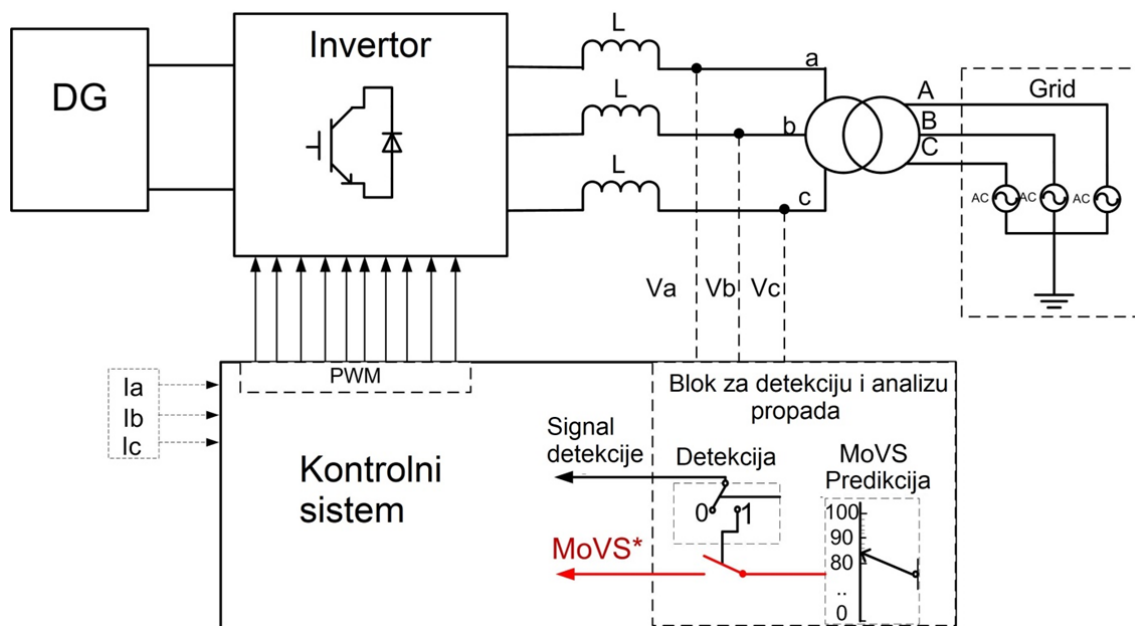
globalnog maksimum tokom tranzijentnog perioda iz signala HDU2357 (skraćeno MHDU2357, obično drugi ili treći lokalni maksimum harmonijskog otiska tokom tranzijenta). Maksimum se računa kao što je prikazano u (6.10) ili (6.11). Koristeći MHDU2357 i funkciju predikcije, prezentovanu u (6.6), predikovana vrednost MAN može biti izračunata kao konačni korak algoritma.



6.5 Strukturna blok šema rada algoritma za predikciju MAN

### 6.8 PRIMENA MAN PREDIKCIJSKE FUNKCIJE

Na slici 6.6 je predstavljena pojednostavljena struktura sistema distribuiranog generatora povezanog na mrežu. Kontrolni sistem je poboljšán dodavanjem bloka za predikciju MAN-a odmah pored bloka za detekciju propada napona. Tri linijska napona su nadgledana i u slučaju kvara u mreži, signali propada napona su generisani i MAN algoritam je aktiviran. Izračunata predikovana vrednost MAN je poslata kontrolnom bloku GTI, koji ovu ranu informaciju može koristiti kao moguću prednost u radu jer se naponske prilike poznaju u određenom vremenskom intervalu „unapre“.



6.6 Uprošćena šema strukture kontrolnog algoritma za LVRT kod DG-ova povezanih na mrežu, sa dodatkom algoritma za predikciju propada napona

## 6.9 DISKUSIJA I TESTIRANJE

Predložena funkcija za predikciju kao u sekciji (6.6) je testirana za 10 različitih propada napona (pogledati tabelu P2), a rezultati su dati u tabeli 6.3. Trebalo bi primetiti da su skupovi podataka ovih 10 propada napona iz korelacijske analize i da se sastoje od širokog opsega poremećaja, višestrukih događaja i propada napona usled različitih uzroka kvara u mreži. Odabrani poremećaji imaju MAN u opsegu od 5.5% do 85%.


Funkcija predikcije pokazuje dobre rezultate sa apsolutnom greškom u opsegu od 0.58% do 9.62% i sa prosečnom apsolutnom greškom od 4.68%. Vremenska razlika između nalaženja maksimalne vrednosti HDU2357 i vremena kada je MAN dostignut tokom propada napona su predstavljeni u tabeli 6.3 i slici 6.7 i 6.8 kao vreme koje predikovana vrednost dubine propada prednjači stvarnoj vrednosti MAN (skraćeno vremenska prednost predikcije je obeležena VR). VR je takođe vizuelno predstavljen na slikama 6.7 i 6.8 za kvarove #1 i #2.8. Za testirane signale vrednosti VR su u opsegu od 33 ms do 646 ms, sa prosečnom vrednošću od 292 ms.

Tabela 6.3 Rezultati testiranja funkcije predikcije sa 10 merenja koja su odvojena za testiranje

No.	Predikovana vrednost MoVS* [%]	Merena vrednost MoVS [%]	Srednja vrednost greške [%]	VR [ms]
#2.1	84.39	80	4.39	567
#2.2	11.065	5.5	5.56	124
#2.3	84.42	85	0.58	358
#2.4	42.01	48.5	6.49	33
#2.5	59.8	59	0.8	52
#2.6	77.17	68.9	8.27	502
#2.7	83.15	87	3.85	646
#2.8	45.59	47	1.41	224
#2.9	78.52	68.9	9.62	158
#2.10	55.38	49.5	5.88	256
Srednja vrednost greške predikcije			<b>4.68</b>	<b>Srednja vrednost VR</b> <b>292</b>
Kvadratna greška predikcije			<b>5.53</b>	


Drugi parametri kvara, kao što su harmonici u naponu ili specifični uzroci poremećaja (magnećenje transformatora, propad usled opterećenja motora, neobični višestruki događaji, itd.) mogu uticati na tranzijentne harmonike i estimirani MHDU2357. Zbog toga, za neke specifične slučajeve, predikovana vrednost MAN može odstupati od funkcije predikcije u određenoj meri. Osim toga, uslovi u mreži pre kvara, posebno THD, mogu u maloj meri uticati na tranzijent MHDU2357. Ovi parametri nisu uzeti u obzir, jer je ciljano da rezultati koji su predstavljeni budu što je moguće više generalizovani (uopšteni). Nešto preciznija predikcija je moguća ako je funkcija predikcije prilagođena specifičnim uslovima u mreži, tj. ako je korišćena manje generalna funkcija ili se koristi komplikovaniji model za predikciju.

Kao ilustrativni primer primene algoritma za detekciju napona i predikciju MAN funkciju prikazan je na slici 6.7: Na slici 6.7 a) je predstavljen signal napona, b) HDU2357 i c) efektivna vrednost napona za kvar #1 iz tabele A1. Takođe, globalni maksimum HDU2357 (skraćeno MHDU2357) je prikazan a takođe obeležen je trenutak gde je MAN dostignut. Za estimirani MHDU2357 od 43% i koristeći (6.6) izračunata predkiovana vrednost MAN je 1.56% što je skoro savršena predikcija prekida napajanja. Može se videti da u ovom slučaju MHDU2357 prethodi MAN (prekid) za 127.5 ms.



Slika 6.7 a) Naponski signal, b) HDU2357 i c) RMS napona, za kvar #1 iz tabele P1

Na slici 6.8, još jedan ilustrativni primer predikcije MAN-a je prikazan za kvar #2.8. Kao i na slici 6.7, svi značajni parametri za predikciju i VR su prikazani vizuelno.



Slika 6.8 a) Naponski signal, b) HDU2357 i c) RMS napona, za kvar #2.8 iz tabele 6.3

U tabeli 6.4 prikazani su rezultati testiranja funkcije predikcije samo za C tip propada napona, korišćeni kao u (2), sa dva C tipa propada napona iz tabele P2 (#2.3 i #2.9). Ova funkcija prikazuje mnogo bolje rezultate nego generalizovana funkcija, kao što je očekivano, i to sa prosečnom greškom od 1.15%.

Tabela 6.4 Rezultati testiranja funkcije predikcije sa 2 merenja koja su odvojena za testiranje a koja sadrže propade napona C tipa

No.	Predikovana vrednost MoVS* [%]	Merena vrednost MoVS [%]	Srednja vrednost greške [%]	VR [ms]
#2.3	83.49	85	1.51	358
#2.9	69.7	68.9	0.8	128
<b>Srednja vrednost greške predikcije</b>			1.15	<b>Srednja vrednost VR</b> <b>243</b>
<b>Kvadratna greška predikcije</b>			1.208	

## 6.10 TESTIRANJE METODE ZA PREDIKCIJU U RAČUNARSKIM SIMULACIJAMA

Kod simulacija korišćena je ista IEEE13 modifikovana mreža opisana u poglavlju 5.2. U tabeli 6.5 su prikazani rezultati testiranja u simulacijama za različite parametre distributivne test mreže. Rezultati simulacija i proračun različitih nivoa harmonika, maksimalne vrednosti MHDU2357 i MAN, kao i parametara mreže su predstavljeni u tabeli 6.5. Harmonici su normalizovani sa vrednošću prvog harmonika koji je izračunat u stacionarnom stanju za normalne uslove u mreži. Različiti tipovi kvarova sa različitim parametrima (otpornost kratkog spoja – FR i otpornost uzemljenja - GR) su simulirani na različitim lokacijama u mreži, u različitim vremenskim trenucima i za različite fazne uglove napona u trenutku nastanka kvara. Takođe, različite sprege transformatora preko kojih su DG povezani na mrežu su testirani.

Tabela 6.5 – Rezultati simulacija za predikciju dubine propada napona

Kvar	MH DU2357 [%]/MoVS [%] /MoVS*[%]		
	$\Delta Y_g$	$\Delta \Delta$	$Y_g Y_g$
#3.1. Trofazni kvar, 20 perioda, PAJ 89 ° . /Čvor 671 /0.001/0.01 /1.612	35.8 /2/9.1	35.5 /2/9.7	34.6 /1/11.5
#3.2. Kvar dve faze sa zemljom, 35 perioda, PAJ 32 ° /Čvor 671 /0.01/0.01 /1.612	33.7 /6 /13.5	33.8 /4/13.3	34.5 /2/11.7
#3.3. Kvar dve faze sa zemljom, PAJ -50 ° /Čvor 684 /0.001/0.01 /1.301	26.6 /22.5/34.5	26.5 /25/36.9	27.2 /25/34.2
#3.4. Propad napona C tipa, PAJ 80 ° , 15 perioda/Čvor 675/0.01/0.01/ 1.069	27 /24.6/34.9	27.4 /21/33.4	27.1 /21/34.6
#3.5. Propad napona usled kvara jedne faze sa zemljom sa skokom napona u ostale dve faze, PAJ 60 deg. /Čvor 680 /0.001/0.01 /2.27	23.4 /44/49.2	24.3 /39/45.6	22.9 /37/51.1
#3.6. Propad napona G tipa, 30 perioda, PAJ 53 ° /Čvor 684/0.001/- /1.301	23.5 /45.2/48.8	25.7 /45.8/40	23.3 /45.7/49.6
#3.7. Kvar dve faze sa zemljom, PAJ 17 ° /Čvor 646/0.001/0.01 /1.165	21.8 /55.6/55.4	26.1 /47/38.5	24.8 /47/43.6
#3.8. Propad napona usled kvara jedne faze sa zemljom sa skokom napona u ostale dve faze sa PAJ 60 ° /Čvor 611 /0.01/0.01 /1.204	25 /45.1/42.8	29.3 /36/26.5	29.5 /36/25.8
#3.9 Propad napona tipa A, mali PAJ, ≈10 ° /Čvor 634/0.001/0.01 /*	11.7 /73/81.8	7.1 /84/84.4	10.9 /72/82.6
#3.10 Propad napona C tipa, mali PAJ (7 °), 40 perioda. /Čvor 634/0.001/0.01 /*	8.7 /81/84.1	11.3 /77/82.2	11.4 /76/82.1
<b>Srednja vrednost greške predikcije</b>	6.11	7.73	9.31
<b>Kvadratna greška predikcije</b>	7.03	8.41	9.96

\*linijski transformator, 4.16/0.48 KV, kvar na NN strani



Takođe na testovima u simulacijama je potvrđeno da zavisnost između maksimalne vrednosti HDU2357 i MAN ima snažna inverzna zavisnost, koja je formulisana i dokazana. Takođe testirana je i hipoteza da li promena faznog stava (PAJ) napona prilikom kvara ili različit X/R odnos imaju uticaj na preciznost metode predikcije.

Različite vrednosti X/R odnosa su ostvarivane u simulaciji sa promenom mesta u kome nastaje kvar, a samim tim se i menjao X/R odnos između mesta kvara i posmatrane lokacije. Različite vrednosti PAJ su u simulaciji ostvarivane promenom trenutka nastanka kvara, tj. promenom faznog stava napona u trenutku nastanka kvara u mreži. Tip uzemljenja DG je menjan promenom uzemljenja odgovarajućih transformatora preko kojih su DG izvori povezivani na mrežu.


Za proveru hipoteza o zavisnosti različitih uticaja u mreži, kao i samih parametara kvara na preciznost predikcije korišćene su iste statističke metode koje su korišćene i za proveru zavisnosti i formiranje funkcije za predikciju, opisani u poglavlju 9.3.

Pearson-ov test i P-vrednost su pokazali da ne postoji korelacija između različitih vrednosti X/R odnosa i greške koju predikcioni algoritam pravi. Za ovaj test vrednost Pearson-ovog koeficijenta je 0.124 dok je  $P=0.771$ . Takođe dokazano je da ne postoji ni veza između MHDU2357 i X/R odnosa (Pearson-ov koeficijent=0.197 i P-vrednost=0.641).

Isti testovi pokazali su da ne postoji veza između PAJ i greške algoritma za predikciju. Za ove testove dobijeni su rezultati: Pearson-ov koeficijent = -0.2 i P-vrednost = 0.579. Predstavljeni rezultati su za  $\Delta Y_g$  tip sprege distributivnog transformatora, dok su za druge dve sprege rezultati slični i potvrđuju date zaključke.

Test mreža koja je korišćena u simulacijama ima određene, značajne razlike u odnosu na realnu distributivnu mrežu u kojoj su dobijeni mereni podaci, korišćeni za formulisanje i testiranje funkcije predikcije koje je predstavljeno u prethodnim sekcijama. IEEE13 test mreža je model realne mreže u koji su uneta određena zanemarenja, mreža radi na 60 Hz i to je model Američke mreže, koji je nesimetričan, postoje čitavi delovi mreže koji su monofazni ili dvofazni. Mereni podaci su dobijeni merenjem u Evropskim mrežama koje rade na 50 Hz, i koje su projektovane i pridržavaju se značajno drugačijih pravila i standarda. Uzimajući ove razlike u obzir, rezultati koje je metoda za predikciju ostvarila u simulacijama mogu se smatrati uspešnim. Srednja vrednost greške je 6.11% (za  $\Delta Y_g$  tip distributivnog transformatora, dok je za druge dve sprege nešto veća – za  $\Delta \Delta$  je 7.73% a za  $Y_g Y_g$  je 9.31%)

Na slici 6.9 prikazan je primer rada metode za predikciju testirano u računarskoj simulaciji.



Slika 6.9 – Rezultati testiranja u simulaciji za kvar #5 iz tabele 6.5 (a.) Napona kvara na mestu kvara, (b.) Napon na mernom mestu, (c.) rms vrednost napona, (d.) drugi, treći, peti i sedmi harmonik predstavljeni zasebno, (e.) HDU2357.

## 6.11 ZAKLJUČAK

U ovom poglavlju je formulisana i dokazana druga hipoteza ovoga rada, a to je da je moguća predikcija vrednosti MAN. U ovu svrhu takođe je korišćen harmonijski otisak, tj. signal koji formira set harmonika (drugi, treći, peti i sedmi harmonik).

Dokazano je da maksimalna vrednost HDU2357 tokom tranzijenta je snažno povezana (zavisna) sa vrednošću maksimalne dubine propada napona tokom kvara. Odgovarajuća funkcija za predikciju je predstavljena, kao i njena primena i formiranje odgovarajućeg algoritma za predikciju.

Funkcija za predikciju je testirana sa 10 signala iz realnih mreža koji nisu korišćeni za njeno formiranje. Kod svih 10 testiranih signala metoda je pokazala uspešnu predikciju, sa prosečnom greškom od 4.68%. Pokazano je takođe da izračunata vrednost predikcije prednjači u vremenu stvarnoj maksimalnoj vrednosti propada za prosečno 292 ms.

## **POGLAVLJE 7**

---

### **ZAKLJUČAK I PRAVCI DALJEG ISTRAŽIVANJA**

## 7.1 ZAKLJUČAK DISERTACIJE

Istraživanje koje je sprovedeno u okviru ove disertacije je poboljšanje brzine predikcije, kao i ostvarivanje mogućnosti za predikciju bitnog parametara kvara, tj. konkretno dubine propada napona tokom kvara u mreži.

U cilju ispunjenja prve hipoteze koja je postavljena: "Detekciju propada napona u savremenim distributivnim mrežama je moguće uraditi unutar vremenskog intervala od 1 ms, posmatrano od početka kvara u mreži," urađena su istraživanja u cilju poboljšanja brzine detekcije propada napona u mreži i predstavljena je nova metoda. Metoda je bazirana na korišćenju harmonijske analize, konkretno praćenja specijalno odabranog seta harmonika, koji se sastoji od drugog, trećeg, petog i sedmog harmonika (HDU2357) i specifičnog oblika koji se javlja prilikom nastanka kvara u mreži. Ovaj specifičan oblik je nazvan "harmonijski otisak". Da bi se ostvarila detekcija bazirana na praćenju oblika, tj. početka harmonijskog otiska, prilagođena je Rekurentna neuronska mreža (RNN) u kombinaciji sa dugim kratko-pamtećim memorijskim jedinicama (long short-term memory unit - LSTM). RNN je klasa neuronskih mreža gde konekcije između neurona mreže imaju direktnu vezu, što mreži omogućava da prati i prepoznaje brze i nagle promene u signalu sa kompleksim međusobnim korelacijama, upravo što je i potrebno u konkretnoj primeni za brzu detekciju poremećaja tokom tranzijenta kvara. Takođe, ove napredne neuronske mreže imaju mogućnost učenja i unapređenja performansi tokom svog rada.

Metoda je testirana u računarskim simulacijama kao i sa velikim setom snimaka različitih propada napona, uzrokovanih širokim spektrom različitih kvarova nastalih u elektroenergetskom sistemu, posmatrano i mereno na dva različita naponska nivoa. Takođe, i jedan set od 10 snimaka propada napona emuliranih i snimljenih u laboratorijskim uslovima je iskorišćen za testiranje. U svim testovima, metoda je pokazala da je prosečno vreme detekcije unutar zadatog intervala od 1 ms, sa prosečnim vremenom detekcije za realna merenja od 0.9268 ms, u simulacijama 0.687 i testirano sa signalima emuliranim u laboratorijskim uslovima 0.743 ms. U literaturi za napredne metode brzina detekcije najčešće varira u rangu od 1 ms do 5 ms, dok za klasične metode (FFT, KF) od 3 ms do preko 10 ms. Može se istaći i dobra osobina metode da kvarove koji imaju kao posledicu pad napona na niže naponske nivoe se detektuju brže od kvarova koji izazivaju male propade napona. Pored smanjenja vremena potrebnog za detekciju propada napona, metoda je pokazala i visoku

pouzdanost od 97.56 %. Ograničenje u primeni metode može se pojaviti ako je hardver na kom se primenjuje metoda star više od npr. 5 godina, i ne može da podrži dovoljan broj operacija za proračun predložene metode. U tom slučaju može se pojaviti problem nedovoljne procesorske snage. U vilju ovog problema može se smanjiti računaska zahtevnost metode korišćenjem jednostavnijeg tipa neuronskih mreža (što bi vrlo verovatno donelo manju pouzdanost), ili detaljnom optimizacijom samog koda Rekurentne neuronske mreže u cilju smanjenja broja računskih operacija. Drugo rešenje je bolje rešenje. Ovaj deo spada u domen optimizacije izvršenja samog programa, i nije deo teme ovog rada.

U radu je postavljena i druga hipoteza „da je moguće izvršiti predikciju dubine propada napona na osnovu harmonijskog otiska“ koja zajedno sa prvom čini celinu u unapređenju odziva i reakcije na kvarove u mreži. Druga hipoteza je statistički dokaza korišćenjem nekoliko statističkih testova i razvijena je kompletna metoda za predikciju dubine propada napona, nakon uspešne brze detekcije, dok je RMS napona iznad ili blizu vrednosti 0.9 p.u., tj. nekoliko desetina do nekoliko stotina milisekundi pre nego što propad se razvije u potpunosti. Ova hipoteza je takođe ostvarena korišćenjem harmonijskog otiska i njegovom detaljnom statističkom analizom na velikom uzorku merenja dobijenih u realnim distributivnim mrežama. Od 122 snimka, snimci sa 112 poremećaja su iskorišćeni za statističku analizu i dobijanju odgovarajuće funkcije koja se koristi za predikciju, dok je preostalih 10 iskorišćeno za testiranje dobijene funkcije. Odgovarajuća generalizovana funkcija je formulisana, bazirana na statistički utvrđenoj zavisnosti između MAN i MHDU2357. Pokazano je da može biti korišćena za predikciju za sve slučajeve poremećaja napona (propadi napona tipa A-G, za propade izazvane magnjećenjem transformatora, prekidima napajanja koji nisu izazvani kvarovima, kratkim i prolaznim kvarovima, itd.), tj. to je generalizovana predikciona funkcija koja obuhvata sve tipove kvarova koji dovode do propada napona u mreži. Predikcija se pokazala kao uspešna, sa srednjom vrednošću greške od 4.68% uz korišćenje generalizovane funkcije za predikciju.

Pored signala dobijenih iz realnih distributivnih mreža, za testiranje metode za predikciju MAN korišćene su i računarske simulacije. Uprkos razlikama i uprošćenjima u modelovanju distributivnih mreža u računarskim simulacijama, predložena metoda je ostvarila dobre rezultate, uz rednju grešku od 6.11%.

Predstavljena funkcija za predikciju dubine propada napona može biti korišćena za unapređenje kontrolnog algoritma kod različitih uređaja u okviru DG, kao i kod uređaja za

ublažavanje ili rešavanje problema propada ili potpunog nestanka napona u mreži: UPS, DVR, UPQC, zatim kod algoritama namenjenim za PQ monitoring elektroenergetskog sistema, jer sama dubina i opasnost koju kvar može izazvati mogu se proračunati znatno unapred. Pokazano je na uzorku od 10 kvarova iz distributivnih mreža, da predikcioni algoritam ostvaruje vremensku predikciju (VR), tj. prednjači stvarnoj vrednosti MAN u iznosu od 33 ms pa do 646 ms, sa srednjom vrednošću VR od 292 ms.

## **7.2 PRAVCI DALJEG ISTRAŽIVANJA**

Pravci daljeg istraživanja biće usmereni na formiranju kompletne metode za detekciju, analizu i klasifikaciju kvarova u distributivnim mrežama koje sadrže distribuirane energetske resurse. Buduća istraživanja će takođe da obuhvate i razvoj i testiranje metode bazirane na neuronskoj mreži koja ima mogućnost učenja i unapređenja svojih performansi tokom rada. Takođe, u cilju smanjenja računске zavisnosti metode izvršiće se detaljna optimizacija rada rekurentne neuronske mreže, koja će računski u potpunosti biti prilagođena predloženoj primeni.

Jedan od pravaca istraživanja će biti i unapređenje metode sa analizom istinitosti dobijenih podataka i pronalaženja šablona da bih se mogli razlikovati stvarni propadi napona od eventualnih grešaka merenja ili kompjuterskih napada na komunikacionu infrastrukturu između elektroenergetskog sistema i mernih uređaja.

## LITERATURA

---



- [1] Bollen MH. Understanding Power Quality Problems. IEEE; 1999. doi:10.1109/9780470546840.
- [2] Kasikci I. Short Circuits in Power Systems: A Practical Guide to IEC 60909-0. vol. 39. Weinheim, Germany: Wiley-VCH Verlag GmbH & Co. KGaA; 2018. doi:10.1002/9783527803378.
- [3] Sabin DD, Grebe TE, Sundaram A. RMS voltage variation statistical analysis for a survey of distribution system power quality performance. IEEE Power Eng. Soc. 1999 Winter Meet. (Cat. No.99CH36233), IEEE; 1999, p. 1235–40 vol.2. doi:10.1109/PESW.1999.747390.
- [4] IEEE Std 1159-1995 Recommended Practice for Monitoring Electric Power Quality. IEEE, The Institute of Electrical and Electronics Engineers, 345 East 47th Street, New York, NY 10017-2394, USA Copyright; 1995. doi:10.1109/IEEESTD.2009.5154067.
- [5] Institute of Electrical and Electronics Engineers. IEEE Std 1564 - Guide for Voltage Sag Indices. 2014.
- [6] Sabin DD, Sundaram A. Quality enhances reliability. IEEE Spectr 1996;33:34–41. doi:10.1109/6.482272.
- [7] Vegunta SC, Milanović J V. Estimation of cost of downtime of industrial process due to voltage sags. IEEE Trans Power Deliv 2011;26:576–87. doi:10.1109/TPWRD.2009.2035366.
- [8] McGranaghan MF, Mueller DR, Samotyj MJ. Voltage sags in industrial systems. IEEE Trans Ind Appl 1993;29:397–403. doi:10.1109/28.216550.
- [9] Bhavaraju VB, Enjeti P. A Fast Active Power Filter to Correct Line Voltage Sags. IEEE Trans Ind Electron 1994;41:333–8. doi:10.1109/41.293904.
- [10] Rufer A, Katic V, Graovac D. Power quality compensation using universal power quality conditioning system. IEEE Power Eng Rev 2000;20:58–60. doi:10.1109/39.890381.
- [11] Mark Stephens P. Power Quality Standards : CBEMA , ITIC, SEMI FE47, IEC 61000-4-411/34 2009:2–7.
- [12] Electromagnetic compatibility (EMC), Measurement P 4-30: T and measurement techniques – P quality, Methods. IEC 61000-4-30 Edition 3.0 2015-02. 2015.
- [13] Akagi H. New trends in active filters for power conditioning. Ind Appl IEEE Trans

- 1996;32:1312–22. doi:10.1109/28.556633.
- [14] Nielsen JG, Blaabjerg F. A detailed comparison of system topologies for dynamic voltage restorers. *IEEE Trans Ind Appl* 2005;41:1272–80. doi:10.1109/TIA.2005.855045.
- [15] Katic VA, Stanisavljevic AM. Smart Detection of Voltage Dips Using Voltage Harmonics Footprint. *IEEE Trans Ind Appl* 2018;54:5331–42. doi:10.1109/TIA.2018.2819621.
- [16] Strezoski L. PRORAČUN KOMPLEKSNIH KRATKIH SPOJEVA NEURAVNOTEŽENIH DISTRIBUTIVNIH MREŽA SA DISTRIBUIRANIM ENERGETSKIM RESURSIMA. Fakultet tehničkih nauka, Novi Sad; 2017.
- [17] Ackermann T, Prevost T, Vittal V, Roscoe AJ, Matevosyan J, Miller N. Paving the Way: A Future Without Inertia Is Closer Than You Think. *IEEE Power Energy Mag* 2017;15:61–9. doi:10.1109/MPE.2017.2729138.
- [18] Zhong QC. Virtual Synchronous Machines: A unified interface for grid integration. *IEEE Power Electron Mag* 2016;3:18–27. doi:10.1109/MPEL.2016.2614906.
- [19] Magueed FA, Sannino A, Svensson J. Transient performance of voltage source converter under unbalanced voltage dips. 2004 IEEE 35th Annu Power Electron Spec Conf 2004:1163–8. doi:10.1109/PESC.2004.1355587.
- [20] Bae Y, Vu TK, Kim RY. Implemental control strategy for grid stabilization of grid-connected PV system based on German grid code in symmetrical low-to-medium voltage network. *IEEE Trans Energy Convers* 2013;28:619–31. doi:10.1109/TEC.2013.2263885.
- [21] Yang Y, Blaabjerg F, Zou Z. Benchmarking of Grid Fault Modes in Single-Phase Grid-Connected Photovoltaic Systems. *IEEE Trans Ind Appl* 2013;49:2167–76. doi:10.1109/TIA.2013.2260512.
- [22] Mohanty SR, Ray PK, Kishor N, Panigrahi BK. Classification of disturbances in hybrid DG system using modular PNN and SVM. *Int J Electr Power Energy Syst* 2013;44:764–77. doi:10.1016/j.ijepes.2012.08.020.
- [23] Yang Y, Blaabjerg F. Low-voltage ride-through capability of a single-stage single-phase photovoltaic system connected to the low-voltage grid. *Int J Photoenergy* 2013;2013. doi:10.1155/2013/257487.
- [24] Afshari E, Moradi GR, Rahimi R, Farhangi B, Yang Y, Blaabjerg F, et al. Control Strategy for Three-Phase Grid-Connected PV Inverters Enabling Current Limitation Under

- Unbalanced Faults. IEEE Trans Ind Electron 2017;64:8908–18. doi:10.1109/TIE.2017.2733481.
- [25] Technical requirements for connecting photovoltaic power station to power system, GB/T 19964-2012: Translated English of Chinese Standard. (GBT 19964-2012) 2012.
- [26] Lopes A, Nascimento A, Vieira J. Reactive Power Control of Direct Drive Synchronous Generators to Enhance the Low Voltage Ride-Through Capability. CdnIntechopenCom 2011. doi:10.5772/15879.
- [27] Sizhan Z, Liu J, Linyuan Z, Yangque Z, Xu Y. Sag detection algorithm for dynamic voltage restorer used in wind farms under unbalanced and distorted grid voltage conditions. 2013 IEEE ECCE Asia Downunder, IEEE; 2013, p. 601–6. doi:10.1109/ECCE-Asia.2013.6579160.
- [28] Ding G, Gao F, Tian H, Ma C, Chen M, He G, et al. Adaptive DC-Link Voltage Control of Two-Stage Photovoltaic Inverter during Low Voltage Ride-Through Operation. IEEE Trans Power Electron 2016;31:4182–94. doi:10.1109/TPEL.2015.2469603.
- [29] Tian H, Gao F, Ma C, He G, Li G. A review of low voltage ride-through techniques for photovoltaic generation systems. 2014 IEEE Energy Convers Congr Expo ECCE 2014 2014:1566–72. doi:10.1109/ECCE.2014.6953605.
- [30] Dantas JL, Lima FKA, Branco CGC, Guerrero JM, Vasquez JC. A robust and fast generic voltage sag detection technique. 2015 IEEE 13th Brazilian Power Electron Conf 1st South Power Electron Conf COBEP/SPEC 2016 2015. doi:10.1109/COBEP.2015.7420252.
- [31] Zhang M, Li K, Hu Y. A real-time classification method of power quality disturbances. Electr Power Syst Res 2011;81:660–6. doi:10.1016/j.epsr.2010.10.032.
- [32] Xiao F, Dong L, Li L, Liao X. Fast voltage detection method for grid-tied renewable energy generation systems under distorted grid voltage conditions. IET Power Electron 2017;10:1487–93. doi:10.1049/iet-pel.2016.0738.
- [33] Chen G, Zhang L, Wang R, Zhang L, Cai X. A novel SPLL and voltage sag detection based on les filters and improved instantaneous symmetrical components method. IEEE Trans Power Electron 2015;30:1177–88. doi:10.1109/TPEL.2014.2318051.
- [34] Khoshkbar Sadigh A, Smedley KM. Fast and precise voltage sag detection method for dynamic voltage restorer (DVR) application. Electr Power Syst Res 2016;130:192–207. doi:10.1016/j.epsr.2015.08.002.

- [35] Ma C, Gao F, He G, Li G. A Voltage Detection Method for the Voltage Ride-Through Operation of Renewable Energy Generation Systems Under Grid Voltage Distortion Conditions. *IEEE Trans Sustain Energy* 2015;6:1131–9. doi:10.1109/TSTE.2014.2331684.
- [36] Mahela OP, Shaik AG, Gupta N. A critical review of detection and classification of power quality events. *Renew Sustain Energy Rev* 2015;41:495–505. doi:10.1016/j.rser.2014.08.070.
- [37] Zhang L, Loh PC, Gao F. An integrated nine-switch power conditioner for power quality enhancement and voltage sag mitigation. *IEEE Trans Power Electron* 2012;27:1177–90. doi:10.1109/TPEL.2011.2115256.
- [38] Bollen MHJ, Gu IYH. *Signal processing of power quality disturbances*. New York: Wiley-IEEE Press; 2006.
- [39] Electromagnetic compatibility (EMC), Part 4 S 30: P quality measurement methods. International Standard IEC 61000-4-30. vol. 0–7. 2003.
- [40] Jain SK, Singh SN. Harmonics estimation in emerging power system: Key issues and challenges. *Electr Power Syst Res* 2011;81:1754–66. doi:10.1016/j.epsr.2011.05.004.
- [41] Stanisavljević AM, Katić VA, Popadić BP, Dumnić BP, Radišić RJ, Kovačević IM. Reduced FFT algorithm for network voltage disturbances detection. 2016 Int. Symp. Ind. Electron. INDEL 2016 - Proc., 2016. doi:10.1109/INDEL.2016.7797810.
- [42] Katic VA. Networking harmonic pollution-review and discussion international and nation standards and recommendations. 3rd Int. Power Electron. Congr. Tech. Proceedings. CIEP '94, IEEE; 1994, p. 145–51. doi:10.1109/CIEP.1994.494413.
- [43] Katic VA, Stanisavljevic AM. Smart Detection of Voltage Dips Using Voltage Harmonics Footprint. *IEEE Trans Ind Appl* 2018. doi:10.1109/TIA.2018.2819621.
- [44] Albu M, Heydt GT. On the use of RMS values in power quality assessment. *IEEE Trans Power Deliv* 2003;18:1586–7. doi:10.1109/TPWRD.2003.817518.
- [45] Stanisavljević AM, Katić VA, Popadić BP, Dumnić BP, Radišić RJ, Kovačević IM. Reduced FFT algorithm for network voltage disturbances detection. 2016 Int Symp Ind Electron INDEL 2016 - Proc 2016. doi:10.1109/INDEL.2016.7797810.
- [46] Ingale R. Harmonic Analysis Using FFT and STFT. *Int J Signal Process Image Process Pattern Recognit* 2014;7:345–62. doi:10.14257/ijpsip.2014.7.4.33.
- [47] Stanisavljevic AM, Katic VA, Popadic BP, Dumnic BP. Voltage dips detection in a

- microgrid with distributed generation for grid-tie inverter protection purposes. 2017 19th Eur. Conf. Power Electron. Appl. (EPE'17 ECCE Eur., IEEE; 2017, p. P.1-P.10. doi:10.23919/EPE17ECCEEurope.2017.8099204.
- [48] Katic VA. Computer Based Harmonic Measurement Systems: Discussion And A Realization. ICHPS V Int. Conf. Harmon. Power Syst., IEEE; n.d., p. 16–22. doi:10.1109/ICHPS.1992.558990.
- [49] Belega D, Petri D. Frequency estimation by two- or three-point interpolated Fourier algorithms based on cosine windows. *Signal Processing* 2015;117:115–25. doi:10.1016/j.sigpro.2015.05.005.
- [50] Wen H, Teng Z, Wang Y, Hu X. Spectral Correction Approach Based on Desirable Sidelobe Window for Harmonic Analysis of Industrial Power System. *IEEE Trans Ind Electron* 2013;60:1001–10. doi:10.1109/TIE.2012.2189531.
- [51] Barros J, Diego RI. On the use of the Hanning window for harmonic analysis in the standard framework. *IEEE Trans Power Deliv* 2006;21:538–9. doi:10.1109/TPWRD.2005.852339.
- [52] Ren Z, Wang B. Estimation algorithms of harmonic parameters based on the FFT. *Asia-Pacific Power Energy Eng Conf APPEEC* 2010;2:0–3. doi:10.1109/APPEEC.2010.5448836.
- [53] Chintakindi SR, Varaprasad OVSR, Sarma DVSSS. Improved Hanning window based interpolated FFT for power harmonic analysis. *IEEE Reg 10 Annu Int Conf Proceedings/TENCON* 2016;2016-Janua:0–4. doi:10.1109/TENCON.2015.7373150.
- [54] Wen H, Zhang J, Meng Z, Guo S, Li F, Yang Y. Harmonic Estimation Using Symmetrical Interpolation FFT Based on Triangular Self-Convolution Window. *IEEE Trans Ind Informatics* 2015;11:16–26. doi:10.1109/TII.2014.2362491.
- [55] Diao R, Meng Q. An interpolation Algorithm for Discrete Fourier Transform of weighted damped sinusoidal signals. *IEEE Trans Instrum Meas* 2014;63:1505–13. doi:10.1109/TIM.2013.2289585.
- [56] Wu JWJ, Zhao WZW. New precise measurement method of power harmonics based on FFT. *2005 Int Symp Intell Signal Process Commun Syst* 2005:365–8. doi:10.1109/ISPACS.2005.1595422.
- [57] Belega D, Petri D, Dallet D. Iterative sine-wave frequency estimation by generalized fourier interpolation algorithms. *2014 11th Int Symp Electron Telecommun ISETC*

- 2014 - Conf Proc 2015:8–11. doi:10.1109/ISETC.2014.7010759.
- [58] Qian H, Zhao R, Chen T. Interharmonics analysis based on interpolating windowed FFT algorithm. *IEEE Trans Power Deliv* 2007;22:1064–9. doi:10.1109/TPWRD.2007.893187.
- [59] Aiello M, Cataliotti A, Nuccio S. A Chirp-Z Transform-Based Synchronizer for Power System Measurements. *IEEE Trans Instrum Meas* 2005;54:1025–32. doi:10.1109/TIM.2005.847243.
- [60] Aiello M, Cataliotti A, Cosentino V, Nuccio S. Synchronization techniques for power quality instruments. *IEEE Trans Instrum Meas* 2007;56:1511–9. doi:10.1109/TIM.2007.903585.
- [61] Cataliotti A, Cosentino V, Nuccio S. A phase-locked loop for the synchronization of power quality instruments in the presence of stationary and transient disturbances. *IEEE Trans Instrum Meas* 2007;56:2232–9. doi:10.1109/TIM.2007.908350.
- [62] Zhao F, Yang R. Power-quality disturbance recognition using S-transform. *IEEE Trans Power Deliv* 2007;22:944–50. doi:10.1109/TPWRD.2006.881575.
- [63] Zhu TX. Exact harmonics/interharmonics calculation using adaptive window width. *IEEE Trans Power Deliv* 2007;22:2279–88. doi:10.1109/TPWRD.2007.899526.
- [64] Van Der Byl A, Inngs MR. Recursive sliding discrete Fourier transform with oversampled data. *Digit Signal Process A Rev J* 2014;25:275–9. doi:10.1016/j.dsp.2013.10.008.
- [65] Thirumala K, Umarikar AC, Jain T. Estimation of single-phase and three-phase power-quality indices using empirical wavelet transform. *IEEE Trans Power Deliv* 2015;30:445–54. doi:10.1109/TPWRD.2014.2355296.
- [66] Poisson O, Rioual P, Meunier M. Detection and measurement of power quality disturbances using wavelet transform. *IEEE Trans Power Deliv* 2000;15:1039–44. doi:10.1109/61.871372.
- [67] Yang L, Yu J, Lai Y. Disturbance source identification of voltage sags based on Hilbert-Huang transform. *Asia-Pacific Power Energy Eng Conf APPEEC* 2010;0:2–5. doi:10.1109/APPEEC.2010.5448916.
- [68] Stanisavljević AM, Katić VA, Dumnić BP, Popadić BP. Overview of voltage dips detection analysis methods. *19th Int. Symp. Power Electron. Ee* 2017, vol. 2017–Decem, 2017. doi:10.1109/PEE.2017.8171703.

- [69] Santoso S, Powers EJ, Grady WM, Hofmann P. Power quality assessment via wavelet transform analysis. *IEEE Trans Power Deliv* 1996;11:924–30. doi:10.1109/61.489353.
- [70] Lin C-H, Tsao M-C. Power quality detection with classification enhancible wavelet-probabilistic network in a power system. *IEE Proc - Gener Transm Distrib* 2005;152:969. doi:10.1049/ip-gtd:20045177.
- [71] Barros J, Diego RI, De Apráiz M. Applications of wavelets in electric power quality: Voltage events. *Electr Power Syst Res* 2012;88:130–6. doi:10.1016/j.epsr.2012.02.009.
- [72] Kezunovic M, Liao Y. A novel software implementation concept for power quality study. *IEEE Trans Power Deliv* 2002;17:544–9. doi:10.1109/61.997935.
- [73] Perez E, Barros J. A proposal for on-line detection and classification of voltage events in power systems. *IEEE Trans Power Deliv* 2008;23:2132–8. doi:10.1109/TPWRD.2008.921121.
- [74] Ray PK, Kishor N, Mohanty SR. Islanding and Power Quality Disturbance Detection in Grid-Connected Hybrid Power System Using Wavelet and S-Transform. *IEEE Trans Smart Grid* 2012;3:1082–94. doi:10.1109/TSG.2012.2197642.
- [75] Dash P, Panigrahi BK, Panda G. Power quality analysis using s-transform. *IEEE Trans Power Deliv* 2003;18:406–11. doi:10.1109/TPWRD.2003.809616.
- [76] Stanisavljevic AM, Katic VA, Popadic BP, Dumnic BP, Kovacevic IM. Voltage dips detection in a system with grid-tie inverter. 2016 18th Eur. Conf. Power Electron. Appl. (EPE'16 ECCE Eur., IEEE; 2016, p. 1–10. doi:10.1109/EPE.2016.7695622.
- [77] Amarís H, Álvarez C, Alonso M, Florez D, Lobos T, Janik P, et al. Computation of voltage sag initiation with Fourier based algorithm, Kalman filter and Wavelets. 2009 IEEE Bucharest PowerTech Innov Ideas Towar Electr Grid Futur 2009:1–6. doi:10.1109/PTC.2009.5282055.
- [78] Perez E, Barros J. Voltage Event Detection and Characterization Methods: A Comparative Study. 2006 IEEE/PES Transm Distrib Conf Expo Lat Am 2006:1–6. doi:10.1109/TDCLA.2006.311552.
- [79] Ingale R, Tawade L. Detection and Comparison of Power Quality Disturbances using Different Techniques. *Int J Comput Appl* 2013;75:48–53.
- [80] Gu Y, Bollen MHJ. Time-frequency and time-scale domain analysis of voltage disturbances. *IEEE Trans Power Deliv* 2000;15:1279–84. doi:10.1109/61.891515.

- [81] Bollen MHJ. Algorithms for characterizing measured three-phase unbalanced voltage dips. *IEEE Trans Power Deliv* 2003;18:937–44. doi:10.1109/TPWRD.2003.813879.
- [82] Jayasree T, Devaraj D, Sukanesh R. Power quality disturbance classification using Hilbert transform and RBF networks. *Neurocomputing* 2010;73:1451–6. doi:10.1016/j.neucom.2009.11.008.
- [83] Daponte P, Menniti D, Testa A. Segmented Chirp Z-Transform and multiple deep dip windows for electrical power system harmonic analysis. *Meas J Int Meas Confed* 1996;18:215–24. doi:10.1016/S0263-2241(96)00058-9.
- [84] Gu IYH, Bollen MHJ, Styvaktakis E. The use of time-varying AR models for the characterization of voltage disturbances. *2000 IEEE Power Eng Soc Conf Proc* 2000;4:2943–8. doi:10.1109/PESW.2000.847353.
- [85] Chang GW, Cheng-I Chen. Performance evaluation of voltage sag detection methods. *IEEE PES Gen. Meet., IEEE; 2010*, p. 1–6. doi:10.1109/PES.2010.5589426.
- [86] De Apráiz M, Barros J, Diego RI. A real-time method for time-frequency detection of transient disturbances in voltage supply systems. *Electr Power Syst Res* 2014;108:103–12. doi:10.1016/j.epsr.2013.11.007.
- [87] Abdelsalam AA, Eldesouky AA, Sallam AA. Characterization of power quality disturbances using hybrid technique of linear Kalman filter and fuzzy-expert system. *Electr Power Syst Res* 2012;83:41–50. doi:10.1016/j.epsr.2011.09.018.
- [88] Joorabian M, Mortazavi SS, Khayyami AA. Harmonic estimation in a power system using a novel hybrid Least Squares-Adaline algorithm. *Electr Power Syst Res* 2009;79:107–16. doi:10.1016/j.epsr.2008.05.021.
- [89] Costa FB, Driesen J, Member S. Assessment of Voltage Sag Indices Based on Scaling and Wavelet Coefficient Energy Analysis *2013*;28:336–46.
- [90] Latran MB, Teke A. A novel wavelet transform based voltage sag/swell detection algorithm. *Int J Electr Power Energy Syst* 2015;71:131–9. doi:10.1016/j.ijepes.2015.02.040.
- [91] Valtierra-Rodriguez M, De Jesus Romero-Troncoso R, Osornio-Rios RA, Garcia-Perez A. Detection and classification of single and combined power quality disturbances using neural networks. *IEEE Trans Ind Electron* 2014;61:2473–82. doi:10.1109/TIE.2013.2272276.
- [92] Kothari DP. Application of neural networks to power systems. *Proc. IEEE Int. Conf.*



- Ind. Technol. 2000 (IEEE Cat. No.00TH8482), vol. 2, Jaico Publishing House; 2017, p. 621–6. doi:10.1109/ICIT.2000.854240.
- [93] Wan C, Xu Z, Pinson P, Dong ZY, Wong KP. Probabilistic forecasting of wind power generation using extreme learning machine. *IEEE Trans Power Syst* 2014;29:1033–44. doi:10.1109/TPWRS.2013.2287871.
- [94] Cardelli E, Faba A, Laudani A, Antonio SQ, Fulginei FR, Salvini A. Computer Modeling of Nickel-Iron Alloy in Power Electronics Applications. *IEEE Trans Ind Electron* 2017;64:2494–501. doi:10.1109/TIE.2016.2597129.
- [95] Lin F, Member S, Lu K, Yang B. Recurrent Fuzzy Cerebellar Model Articulation Neural Network Based Power Control of a Photovoltaic System During Grid Faults 2017;64:1258–68. doi:10.1109/TIE.2016.2618882.
- [96] Biscaro AAP, Pereira RAF, Kezunovic M, Mantovani JRS. Integrated Fault Location and Power-Quality Analysis in Electric Power Distribution Systems. *IEEE Trans Power Deliv* 2016;31:428–36. doi:10.1109/TPWRD.2015.2464098.
- [97] Valtierra-Rodriguez M, Granados-Lieberman D, Torres-Fernandez JE, Rodriguez-Rodriguez JR, Gomez-Aguilar JF. A new methodology for tracking and instantaneous characterization of voltage variations. *IEEE Trans Instrum Meas* 2016;65:1596–604. doi:10.1109/TIM.2016.2540866.
- [98] Mishra S, Bhende CN, Panigrahi BK. Detection and Classification of Power Quality Disturbances Using S-Transform and Probabilistic Neural Network. *IEEE Trans Power Deliv* 2008;23:280–7. doi:10.1109/TPWRD.2007.911125.
- [99] Hooshmand R, Enshae A. Detection and classification of single and combined power quality disturbances using fuzzy systems oriented by particle swarm optimization algorithm. *Electr Power Syst Res* 2010;80:1552–61. doi:10.1016/j.epsr.2010.07.001.
- [100] Khokhar S, Mohd Zin AAB, Mokhtar ASB, Pesaran M. A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances. *Renew Sustain Energy Rev* 2015;51:1650–63. doi:10.1016/j.rser.2015.07.068.
- [101] Hosseini SA, Abyaneh HA, Sadeghi SHH, Razavi F, Nasiri A. An overview of microgrid protection methods and the factors involved. *Renew Sustain Energy Rev* 2016;64:174–86. doi:10.1016/j.rser.2016.05.089.
- [102] Saini MK, Kapoor R. Classification of power quality events - A review. *Int J Electr*

- Power Energy Syst 2012;43:11–9. doi:10.1016/j.ijepes.2012.04.045.
- [103] Granados-Lieberman D, Romero-Troncoso RJ, Osornio-Rios RA, Garcia-Perez A, Cabal-Yepez E. Techniques and methodologies for power quality analysis and disturbances classification in power systems: a review. IET Gener Transm Distrib 2011;5:519. doi:10.1049/iet-gtd.2010.0466.
- [104] Gururajapathy SS, Mokhlis H, Illias HA. Fault location and detection techniques in power distribution systems with distributed generation: A review. Renew Sustain Energy Rev 2017;74:949–58. doi:10.1016/j.rser.2017.03.021.
- [105] Khokhar S, Zin AAM, Mokhtar AS, Ismail NAM, Zareen N. Automatic Classification of Power Quality Disturbances : A Review. IEEE Student Conference Res Dev 2013:16–7. doi:10.1109/SCORED.2013.7002625.
- [106] Pillaya Bhattacharjee P. Application of wavelets to model short-term power system disturbances. IEEE Trans Power Syst 1996;11:2031–7. doi:10.1109/59.544681.
- [107] Santoso S, Powers EJ, Grady WM. Power quality disturbance data compression using wavelet transform methods. IEEE Trans Power Deliv 1997;12:1250–7. doi:10.1109/61.637001.
- [108] Wilkinson WA, Cox MD. Discrete wavelet analysis of power system transients. IEEE Trans Power Syst 1996;11:2038–44. doi:10.1109/59.544682.
- [109] Angrisani L, Daponte P, D’Apuzzo M, Testa A. A measurement method based on the wavelet transform for power quality analysis. IEEE Trans Power Deliv 1998;13:990–8. doi:10.1109/61.714415.
- [110] Stanisavljevic AM, Katic VA, Popadic BP, Dumnic BP, Kovacevic IM. Voltage dips detection in a system with grid-tie inverter. 2016 18th Eur. Conf. Power Electron. Appl. EPE 2016 ECCE Eur., 2016. doi:10.1109/EPE.2016.7695622.
- [111] Dumnic B, Milicevic D, Popadic B, Katic V, Corba Z. Advanced laboratory setup for control of electrical drives as an educational and developmental tool. IEEE EuroCon 2013 2013:903–9. doi:10.1109/EUROCON.2013.6625090.
- [112] Katic VA, Stanisavljevic AM, Dumnic BP, Popadic BP. Comparison of voltage dips detection techniques in microgrids with high level of distributed generation. 17th IEEE Int. Conf. Smart Technol. EUROCON 2017 - Conf. Proc., 2017. doi:10.1109/EUROCON.2017.8011145.
- [113] Aleksandar M. Stanisavljević, Vladimir A. Katić, Radovan Lj. Turović BPDBPP. Voltage

- dips detection using Kalman filter in a microgrid with high level of distributed generation. 2018 20th Eur. Conf. Power Electron. Appl. (EPE'18 ECCE Eur., 2018, p. In press.
- [114] Kovački N. Operation Planning of Distribution Network Reconfiguration by the Multiobjective Optimization. University of Novi Sad, Faculty of Technical Science, 2018.
- [115] dr Vladica Mijailović. Distribuirani izvori energije – principi rada i eksploatacioni aspekti. Akademska misao Beograd; 2011.
- [116] BOSETTI M. Operation of distribution networks with distributed generation. Alma Mater Studiorum – Università di Bologna, 2009.
- [117] Massoud Amin. The Case for Smart Grid. Fortn Mag 2015.
- [118] Postigo Marcos F, Mateo Domingo C, Gómez San Román T, Palmintier B, Hodge B-M, Krishnan V, et al. A Review of Power Distribution Test Feeders in the United States and the Need for Synthetic Representative Networks. *Energies* 2017;10:1896. doi:10.3390/en10111896.
- [119] Mahela OP, Shaik AG. Power quality improvement in distribution network using DSTATCOM with battery energy storage system. *Int J Electr Power Energy Syst* 2016;83:229–40. doi:10.1016/j.ijepes.2016.04.011.
- [120] Emmanuel M, Rayudu R, Welch I. Grid capacity released analysis and incremental addition computation for distribution system planning. *Electr Power Syst Res* 2017;152:105–21. doi:10.1016/j.epsr.2017.06.013.
- [121] IEEE PES Distribution System Analysis Subcommittee's Distribution Test Feeder Working Group. <http://sites.ieee.org/pes-testfeeders/> n.d.
- [122] Stanisavljevic A, Katic V, Dumnic B, Popadic B. A brief overview of the distribution test grids with a distributed generation inclusion case study. *Serbian J Electr Eng* 2018;15:115–29. doi:10.2298/SJEE1801115S.
- [123] Electric grid test case repository TAU. <https://electricgrids.engr.tamu.edu/electric-grid-test-cases> n.d.
- [124] Birchfield AB, Xu T, Gegner KM, Shetye KS, Overbye TJ. Grid Structural Characteristics as Validation Criteria for Synthetic Networks. *IEEE Trans Power Syst* 2017;32:3258–65. doi:10.1109/TPWRS.2016.2616385.
- [125] Electric Power Research. Distributed PV Monitoring and Feeder Analysis n.d.

- [http://dpv.epri.com/feeder\\_k.html](http://dpv.epri.com/feeder_k.html).
- [126] T.K. Vrana, Y. Yang, D. Jovcic, S. Denetiere, J. Jardini HS. The CIGRE B4 DC Grid Test System. n.d.
- [127] Katic VA, Stanisavljevic AM. Novel voltage dip detection algorithm using harmonics in the dip's transient stage. Proc IECON 2017 - 43rd Annu Conf IEEE Ind Electron Soc 2017;2017-Janua:351–6. doi:10.1109/IECON.2017.8216063.
- [128] Weninger F, Bergmann J, Schuller B. Introducing CURRENNT: The Munich Open-Source CUDA RecurREnt Neural Network Toolkit. J Mach Learn Res 2015;16:547–51.
- [129] G. Sybille. <https://www.mathworks.com/help/physmod/sps/examples/ieee-13-node-test-feeder.html> n.d.
- [130] Richard Gagnon. <https://www.mathworks.com/help/physmod/sps/examples/wind-farm-dfig-detailed-model.html> n.d.
- [131] <https://www.mathworks.com/help/physmod/sps/examples/single-phase-240-vrms-3500-w-transformerless-grid-connected-pv-array.html> n.d.
- [132] Elmitwally A. A new algorithm for allocating multiple distributed generation units based on load centroid concept. Alexandria Eng J 2013;52:655–63. doi:10.1016/j.aej.2013.08.011.
- [133] Lee J, Ko J, Choi YJ. Dhystone million instructions per second–based task offloading from smartwatch to smartphone. Int J Distrib Sens Networks 2017;13. doi:10.1177/1550147717740073.
- [134] <http://www.bitkistl.com/2015/03/cortex-ax-vs-performnace.html>. n.d.: [67]  
<http://www.bitkistl.com/2015/03/cortex-ax-vs->
- [135] Bollen MHJ, Styvaktakis E. Characterization of three-phase unbalanced dips (as easy as one-two-three?). Ninth Int. Conf. Harmon. Qual. Power. Proc. (Cat. No.00EX441), vol. 1, IEEE; 2012, p. 81–6. doi:10.1109/ICHQP.2000.897002.
- [136] Bollen MHJ. Voltage sags: effects, mitigation and prediction. Power Eng J 1996;10:129–35. doi:10.1049/pe:19960304.
- [137] Qader MR, Bollen MHJ. Stochastic prediction of voltage sags in a large transmission system. IEEE Trans Ind Appl 1999;35:152–62. doi:10.1109/28.740859.
- [138] dos Santos A, Correia de Barros MT. Voltage sag prediction for network planning. Electr Power Syst Res 2016;140:976–83. doi:10.1016/j.epsr.2016.03.033.
- [139] Aung MT, Milanović J V. Stochastic prediction of voltage sags by considering the

probability of the failure of the protection system. IEEE Trans Power Deliv 2006;21:322–9. doi:10.1109/TPWRD.2005.852385.

- [140] Adler J, Parmryd I. Quantifying colocalization by correlation: The Pearson correlation coefficient is superior to the Mander's overlap coefficient. Cytom Part A 2010;77A:733–42. doi:10.1002/cyto.a.20896.
- [141] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever and RS. Dropout: A simple way to prevent neural networks from overfitting. In: Styner MA, Angelini ED, editors. J. Mach. Learn. Res., vol. 15, 2014, p. 1929–58. doi:10.1117/12.2254234.

## SPISAK PUBLIKACIJA AUTORA

---

### M21a

- [1] Aleksandar M. Stanisavljević, Vladimir A. Katić, "Magnitude of voltage sags prediction based on the harmonic footprint for application in DG control system," IEEE Transaction on Industrial Electronic, Early Access, 2018, pp: 1-11, doi: 10.1109/TIE.2018.2881934

### M21

- [2] Vladimir A. Katić, Aleksandar M. Stanisavljević, "Smart Detection of Voltage Dips Using Voltage Harmonics Footprint," IEEE Transaction on Industrial Applications, vol. 54, no. 5, pp. 5331–5342, Sep. 2018, doi: 10.1109/TIA.2018.2819621

### M51

- [3] Aleksandar M. Stanisavljević, Vladimir A. Katić, Boris P. Dumnić Bane P. Popadić, "A Brief Overview of the Distribution Test Grids with A Distributed Generation Inclusion Case Study", Serbian journal of electrical engineering, Vol. 15, No. 1, February 2018, 1–10

### M33

- [4] Aleksandar M. Stanisavljević, Vladimir A. Katić, Radovan Lj. Turović, Boris P. Dumnić, Bane P. Popadić, "Voltage dips detection using Kalman filter in a microgrid with high level of distributed generation", 20th European Conference on Power Electronics and Applications, EPE'18 ECCE Europe, Riga, Latvia, 17-21 Sep. 2018, Paper No.0274, P.1-P.10.
- [5] Vladimir A. Katić, Aleksandar M. Stanisavljević, Radovan Lj. Turović, Boris P. Dumnić, Bane P. Popadić, "Extended Kalman filter for voltage dips detection in grid with distributed energy resources", 8th IEEE PES Innovative Smart Grid Technologies – ISGT 2018, Sarajevo, Bosnia and Herzegovina, 21-25 Oct. 2018, Paper No.264, pp.1-6.

- [6] Aleksandar Stanisavljević, Vladimir Katić, Boris Dumnić, Bane Popadić, "Overview of the Distribution Test Grids With Distributed Generation and HVDC", 4th International Conference on Electrical, Electronic and Computing Engineering - IcETRAN 2017, Kladovo, Serbia, 5-8 June 2017, pp. EEI1.2.1-6.
- [7] Vladimir A. Katić, Aleksandar M. Stanisavljević, Bane P. Popadić, Boris P. Dumnić, Dragan M. Milićević, Zoltan J. Čorba, "Experimental Procedure for Testing of Voltage Dip Detection Algorithms", 8th PSU-UNS International Conference on Engineering and Technology (ICET-2017), Novi Sad, Serbia, June 8-10, 2017, ISBN 978-86-7892-934-2, COBISS.SR-ID 314741767, paper no. T5-1.2, pp. 1-5.
- [8] Vladimir A. Katić, Aleksandar M. Stanisavljević, Boris P. Dumnić, Bane P. Popadić, "Comparison of Voltage Dips Detection Techniques In Microgrids With High Level of Distributed Generation", 17th IEEE International Conference on Smart Technologies IEEE EUROCON 2017, Ohid, Republic of Macedonia, July 5-8, 2017, ISBN 978-1-5090-3842-8, pp.417-422.
- [9] Vladimir A. Katić, Aleksandar Stanisavljević, "Wavelet transform for voltage dips detection in a microgrid with distributed generation", 19th European Conference on Power Electronics and Applications, EPE'17 ECCE Europe, Warsaw, Poland, 12-14 Sep. 2017, Paper No.0627, P.1-P.10.
- [10] Aleksandar M. Stanisavljević, Vladimir A. Katić, Bane P. Popadić, Boris P. Dumnić, "Voltage dips detection in a microgrid with distributed generation for grid-tie inverter protection purposes", 19th European Conference on Power Electronics and Applications, EPE'17 ECCE Europe, Warsaw, Poland, 12-14 Sep. 2017, Paper No.0419, P.1-P.10.
- [11] Aleksandar M. Stanisavljević, Vladimir A. Katić, Boris P. Dumnić, Bane P. Popadić, "Overview of voltage dips detection analysis methods," 19th International Symposium on Power Electronics - Ee2017, Novi Sad, Serbia, Oct.19-21, 2017, Paper No. T6.1-4, pp.1-6, ISBN 978-86-7892-980-9, COBISS.SR-ID 317617415.
- [12] Vladimir A. Katić, Aleksandar M. Stanisavljević, "Novel voltage dip detection algorithm using harmonics in the dip's transient stage", The 43rd Annual Conference of the IEEE Industrial Electronics Society, IECON 2017, Beijing, China, Oct.29 - Nov.1, 2017, Paper No. BD-039055, pp.1-6. ISBN 978-1-5386-1126-5 (USB), DOI: 10.1109/IECON.2017.8216063
- [13] Aleksandar M. Stanisavljević, Vladimir A. Katić, Bane P. Popadić, Boris P. Dumnić, Ilija M. Kovačević, "Voltage dips detection in a system with grid-tie inverter", 18th

European Conference on Power Electronics and Applications, EPE'16 ECCE Europe, Karlsruhe, Germany, 5-9 Sept. 2016. Paper No.: 0541, P.1-P.10, ISBN: 9789075815252 and CFP16850-USB.

[14] Aleksandar Stanisavljevic, Vladimir Katic, Bane Popadic, Boris Dumnic, Rade Radisic and Ilija Kovačević, "Reduced FFT Algorithm for Network Voltage Disturbances Detection", 2016 International Symposium on Industrial Electronics (INDEL), Banja Luka, Bosnia and Herzegovina, 3-5 November 2016, pp.1-6., ISBN: 978-1-5090-2329-5

[15] Aleksandar Stanisavljević, Vladimir A. Katić, Bane Popadić, Boris Dumnić, Ilija Kovačević "Grid connected inverter current harmonics during faults in the network", 18th International Symposium on Power Electronics, Ee2015, Novi Sad, Oct. 28-30, 2015, Paper No.T6-2, pp.1-4, ISBN 978-86-7892-757-7



## **PRILOZI**

---

**P.1 REZULTATI KORIŠĆENI ZA FORMIRANJE I TESTIRANJE FUNKCIJE ZA PREDIKCIJU**

Tabela P1 - Tipovi kvara, Minimalna amplituda napona tokom kvara i maksimalna vrednost harmonika HDU2357 tokom tranzijenta za signale korišćene u statističkoj analizi

<b>Tip kvara i kratak opis</b>	<b>MoVS [%]</b>	<b>MHDU 2357 [%]</b>
1. Početak prekida posle nesimetričnog kvara	0.02	43
2. Početak dvofaznog kvara sa zemljom	91.6	4
3. Pad napona, povratak na nominalnu vrednost nije snimljen, snimak od 10 sekundi	91	3
4. Propad sa harmonijskim zasićenjem na početku događaja	90	12
5. Početak dvofaznog kvara sa zemljom	92	3.9
6. Tip C, 15 perioda, pomeraj faznog ugla	87	5.1
7. Propad koji se razvija kroz više faza, kvar koji se razvija	48	18.6
8. Tip C, 12 perioda, pomeraj faznog ugla, veoma konstantan rms napona	54	20.5
9. Tip G, 9 perioda. Karakteristični fazni pomeraj oko -50 stepeni	14	35.6
10. Početak prekida bez kvara sa varničenjem usled opterećenja motora	0.01	50.1
<b>11. Kraj prekida (od 0 do 100%), zasićenje transformatora praćeno velikim harmonijskim izobličenjem-nije korišćen za statistiku (NK)</b>	<b>100</b>	<b>46</b>
12. Nesimetrični propad sa neobičnim oporavkom: motor + transformator?	57.4	15.2
13. Tip D propada sa pomerajem faznog ugla, 5 perioda	88.5	3.4
14. Tip C, 12 perioda, pomeraj faznog ugla, konstantan rms napona	68	14
15. Tip C, 4 periode, mali pomeraj faznog ugla, značajan uticaj opterećenja	81.5	7.12
16. Tip C, 10 perioda, pomeraj faznog ugla, veoma konstantan rms napona	85	7.2
17. Trofazni kvar; trajanje kvara oko 70 perioda, oko -50 stepeni pomeraj faznog ugla	24	33
<b>18. Oporavak nakon tipa D od 92% do 100%. NK</b>	<b>100</b>	<b>2</b>

19. Trofazni kvar, trajanje kvara 20 perioda, mali pomeraj faznog ugla	90	4.6
20. Propad napona sa porastom napona u jednoj fazi, moguć dvofazni kvar sa zemljom	96	3.3
21. Propad u dve faze, jedna faza sa porastom napona, 6 perioda	96	3.3
22. Propad napona sa porastom napona u jednoj fazi, moguć dvofazni kvar sa zemljom	96	3.3
23. Tip C, 18 perioda, mali pomeraj faznog ugla, mali uticaj opterećenja	50	25
24. Tip propada C sa dugum trajanjem, mali pomeraj faznog ugla	49.5	24.5
25. Tip C, 15 perioda, koji se razvija u Tip G, 2 perioda. Propad se razvijao iz propada jedne faze sa zemljom u propad dve faze sa zemljom. Linijski naponi su mereni.	50.5	21
26. Tip D, 30 perioda, neispravan rad prekidača koji dovodi do izobličenja talasa tokom događaja. m distortion during the event.	65	9.4
27. Kratak propad, verovatno proladni kvar	46	27
28. Početak prekida bez kvara, porast napona na početku	0.05	53.3
29. Magnećenje transformatora sa porastom napona usled harmonika	87	17.7
30. Magnećenje transformatora sa stabilnim porastom napona	92	20
31. Tip D, bez skoka, oporavak u dve etape	85	7.3
32. Tip C sa 11 perioda koji se razvije u tip A od 6 perioda sa oporavkom u dve etape. Linijski naponi su mereni.	25.7	29
33. Kvar koji se razvija sa oporavkom u dve etape	63.5	15
34. Trofazni kvar, pri čemu postoje razlike u trenutnom oporavku u sve tri faze	55	16.3
35. Tip C sa 11 perioda koji se razvija u tip A sa 3 perioda. Sa pomerajem faznog ugla.	55	16
36. Propad usled kvara u jednoj fazi, sa porastom napona u fazama bez kvara.	24	29.8
37. Trofazni kvar, mali pomeraj faznog ugla.	88.5	4.1
38. Veoma plitak propad samo u fazi c (plavoj), 5 perioda	99	0.6
39. Propad usled kvara u jednoj fazi, sa porastom napona u fazama bez kvara.	21.3	33.2
40. Tip C, 16 perioda, umeren pomeraj faznog ugla, komplikovan oporavak	75	11
41. Tip C, 10 perioda, sa pomerajem faznog ugla, sa određenim uticajem opterećenja	75	11
42. Početak prekida bez kvara sa porastom napona na početku	0.02	50

Nova metoda detekcije propada napona u mreži sa distribuiranim generatorima

43. Tip C, 15 perioda, sa pomerajem faznog ugla	64	12.9
44. Prekid bez kvara sa varničenjem zbog opterećenja motora	1	37
45. Propad zbog jednofaznog kvara, sa porastom napona u fazama bez kvara.	22	31.3
46. Tip C, 25 perioda, nema pomeraja faznog ugla, konstantan rms napona	85	7
47. Nebalansirani propad (Tip C) sa velikim napajanjem mesta kvara od strane mašina prilikom početka propada. Oporavak u dve etape. Spor oporavak posle kvara.	72	9.3
48. Tip C, 4 periode, mali pomeraj faznog ugla, značajan uticaj opterećenja	82.5	6.91
49. 8% propad napona u tri faze. Trajanje najmanje 10 sekundi. Oporavak napona nije snimljen.	92	3.9
50. Kvar koji se razvija	62.5	16
<b>51. Oporavak posle Tipa C, sa 90% do 100%, NK</b>	<b>100</b>	<b>2.4</b>
52. Tip B, 5 perioda (porast napona), razvija se u tip E (porast napona), 3 perioda	85	7.2
53. Tip C, 40 perioda, umeren pomeraj faznog ugla	70	13
54. Tip C, 10 perioda, umeren pomeraj faznog ugla	67	14.2
55. Tip C, 2 perioda, razvija se u tip A, 10 perioda. Uključuje pomeraj faznog ugla.	87	7
56. Kvar u jednoj fazi sa porastom napona u fazama bez kvara. Oporavak u dve etape. Nema uticaja opterećenja.	5.5	34.5
57. Propad usled kvara u jednoj fazi, nestabilnost, prekid. Ovo bi moglo biti nenamerno izolovanje. Kvar sa više etapa.	69	10.9
<b>58. Kraj prekida, od 0 do 100%. NK</b>	<b>100</b>	<b>39</b>
59. Plitak prekid, samo 1% između dve faze	99	1.5
60. Tip C ili D, veliki pomeraj faznog ugla, 50 perioda. Pomeraj faznog ugla oko -18 stepeni u jednoj fazi, dok nema nikakvih pomeraja faznog ugla u druge dve faze.	72.5	12.3
61. Tip C, 3 periode, veliki pomeraj faznog ugla. Karakteristični pomeraj faznog ugla od -10 stepeni.	76.3	10.2
62. Tip C, 7 perioda, razvija se u tip G, 7 perioda.	73	13.6
63. Tip D, dve periode. Karakteristični pomeraj faznog ugla od -40 stepeni.	39.8	26.5
64. Tip F, 15 perioda. Karakteristični pomeraj faznog ugla od -40 stepeni.	40	26
65. Početak prekida bez kvara sa varničenjem zbog opterećenja motora	0.04	50.5
66. Tip C, 15 perioda, razvija se u tip A, 15 perioda.	71	12.9

67. Trofazni kvar, oko dve periode sa uticajem na opterećenje na početku. Veliki pomeraj faznog ugla.	68.8	16.5
68. Početak prekida bez kvara	0.03	48.8
69. Trofazni kvar, oko dve periode na početku oseti se uticaj opterećenja. Mali pomeraj faznog ugla.	77.5	8.1
70. Trofazni kvar, sa veoma konstantnim rms-om napona. Pomeraj faznog ugla od -2 do -5 stepeni ya vreme kvara.	77	8.6
71. Plitak, balansirani propad sa sporim oporavkomč – 3 stepeni je pomeraj faznog ugla, verovatno kvar u distributivnom delu mreže	91.3	2.4
72. Tip F, 5 perioda. Karakteristični pomeraj faznog ugla -55 stepeni.	17.7	38.4
73. Prolazni kvar: dve faze--> jedna faza --> bez kvara, sve za oko dve periode	46	16.9
74. Tranzijent sa povećanjem amplitude praćen prekidom	0.05	47.8
75. Završetak prekida + zasićenje transformatora	<b>100</b>	<b>42.6</b>
76. Tip D razvija se u tip A posle otprilike 5 perioda	83	6.9
77. Početak dvofaznog kvara sa zemljom	90	4.1
78. 3x oporavak nakon dugog trofaznog kvara, koji se razvio iz dvofaznog kvara sa zemljom	<b>100</b>	<b>4.4</b>
79. 3x Tip C, 4 periode, mali pomeraj faznog ugla, značajni uticaj opterećenja	89.5	4
80. Tip C, 4 periode, mali pomeraj faznog ugla, značajni uticaj opterećenja, oporavak u dve etape	85.3	6.2
81. Kvar koji se dugo razvija, od jednofaznog do trofaznog, sa from single-phase to three-phase sa snažnom indukcionom mašinom koja napaja na početku svake nove etape.	67	6
82. Propad usled kvara u jednoj fazi, sa porastom napona u fazama bez kvara.	54	14.5
83. 2x Trofazni kvar, oko 5 perioda doprinos motora na početku propada. Pomeraj faznog ugla oko -5 stepeni, znatno veći tokom doprinosa motora.	68	9.1
84. Tip C, 5 perioda, razvija se u tip A, 15 perioda. Nestabilan rms napona.	74.3	15
85. Veoma kratak propad, teško je reći šta je u pitanju.	41.3	39
86. Tip D, 15 perioda; Tip F, 30 perioda, Tip A, 5 perioda.	68.6	12.9
87. Još jedan kvar koji se duže vreme razvija.	87	5.47
88. Trofazni kvar, sa neobičnim tranzijentom u sredini. Moguće da je u pitanju greška pri merenju.	35.3	31.1
89. Nekoliko perioda tranzijenta napona sa jako izraženim šumom. Moguće je da je kvar koji se nije razvio u potpunosti.	84.6	15.2

Nova metoda detekcije propada napona u mreži sa distribuiranim generatorima		
---	--	--

90. Trofazni kvar sa čudnim špicovima u naponu. Moguća greška merenja.	35.5	32.8
89. Nekoliko perioda tranzijentnog napona i šumova. Moguće da je kvar koji se nije razvio u potpunosti.	21.5	36.4
90. Trofazni kvar, sa nekim čudnim pikovima. Moguće da je u pitanju greška pri merenju.	78	7.8
91. 2x kvar koji se razvija u jednoj periodu. Počinje kao kvar između dve faze; treća faza se pridružuje jednu period kasnije.	85.6	5.41
94. Trofazni kvar, oporavak u dve periode	84.8	5.82
95. Tip C, 25 perioda, oporavak u dve etape.	79.4	8.8
96. Mali propad napona u tri faze, ostaje na nižem nivou barem 10 sekundi.	89.6	3.45
97. Pad napona, oporavak nije snimljen.	35.2	33
98. Kratak propad, verovatno prolazni kvar	47.5	44
99. Propad napona prilikom magnećenja transformatora	83.5	13.6
100. Interesantna serija tranzijenata/veoma kratiki propadi praćeni malim porastom u rms naponu.	80.6	21.6
101. Tranzijent sa porastom amplitude, praćen prekidom	0.5	42.2
102. Tip C, 30 perioda, bez promene faznog ugla, oporavak u dve etape.	79	8.66
103. Tip C, 5 perioda, manje-više normalan napon tokom 5 perioda, prekid bez kvara sa velikim porastom napona na početku.	0.02	61.3
104. Propad napona usled magnećenja transformatora	90.6	7.75
105. Tip C, 10 perioda, razvija se u tip A, 30 perioda. Nestabilan rms napon tokom trofaznog kvara.	72	16.8
106. 2x Trofazni kvar, velika impedansa kvara. Impedansa kvara se resetuje na pola puta od kvara.	69.1	19
107. Trofazni kvar, velika i rastuća impedansa kvara.	68.8	19.5
108. Tip C --> Tip F --> Tip A u oko 100 perioda. Oporavak napona nije snimljen.	88.9	4
109. Trofazni kvar u dve periode	84.9	6
110. Trofazni kvar u dve periode	87.3	5.32
111. Trofazni kvar u dve periode	83.2	7.1
112. Tip C, 30 perioda, bez promene faznog ugla, oporavak u dve etape.	79.6	9.04

Tabela P2 - Tipovi kvara, Minimalna amplituda napona tokom kvara i maksimalna vrednost harmonika HDU2357 tokom tranzijenta za signale korišćene za testiranje predikcije dubine propada napona

Vrsta kvara i kratak opis	MoVs [%]	MHDU 2357 [%]
#2.1. Tip G, 5 perioda, razvija se u Tip A, 60 perioda, kvar se razvija kroz nekoliko perioda.	<b>80</b>	<b>7.34</b>
#2.2. Prekid bez kvara sa određenim malim preostalim naponom između dve faze.	<b>5.5</b>	<b>34.8</b>
#2.3. Tip C, 15 perioda, karakteristični pomeraj faznog ugla oko -7 stepeni dve faze sa zemljom.	<b>85</b>	<b>6.7</b>
#2.4. Balansirani propad sa nebalansiranim oporavkom, razvija se u nekoliko etapa, prvo propadaju faze a i b, a potom i faza c.	<b>48.5</b>	<b>25.2</b>
#2.5. Izuzetan višestruki događaj, bez jasnog objašnjenja. Počinje kao Tip C, sa sporim oporavkom posle nekoliko perioda; potpuni oporavak, porast u jednoj fazi, a pad u druge dve faze.	<b>59</b>	<b>20.6</b>
#2.6. Trofazni kvar, oko 5 perioda, doprinos motora na početku propada. Promena faznog ugla oko -5 stepeni, nešto malo više tokom doprinosa motora.	<b>67.5</b>	<b>14.6</b>
#2.7. Tip F, 15 perioda, razvija se u tip A, 15 perioda, sporo razvijanje.	<b>87</b>	<b>4.8</b>
#2.8. Trofazni kvar. Oporavak posle kvara u dve etape.	<b>47</b>	<b>24.3</b>
#2.9. Nebalansirani propad (Tip C) sa velikim napajanjem mesta kvara od strane mašina prilikom početka propada. Oporavak u dve etape. Smanjeni naponi nakon kvara. Moguće zaustavljanje indukcionih mašina.	<b>68.9</b>	<b>13.9</b>
#2.10. Jednofazni kvar sa porastom napona u fazama bez kvara. Oporavak u dve etape.	<b>49.5</b>	<b>21.8</b>

## P.2 NEURONSKE MREŽE

Neuronske mreže predstavljaju jednu od metoda mašinskog učenja. Mašinsko učenje je skup metoda koji opisuje algoritme i strukture podataka pomoću kojih računar može da nauči određeni set podataka. Ono što odvaja mašinsko učenje od ostalih algoritama i struktura podataka koje rešavaju neki problem jeste sloboda i široke mogućnosti učenja. Za razliku od tradicionalnog rešavanja problema gde se algoritmi pišu direktno u cilju rešavanja određenog problema, i gde je neophodan uslov da se dobro poznaje domen kao i sam problem, a i da je tako nešto moguće napisati, kod metode mašinskog učenja se postavlja početno stanje metode, tj. daju joj se adekvatni ulazni podaci, i potom se dobijena izlazna rešenja algoritma ocenjuju po unapred definisanom kriterijumu. U odnosu na to da li su odgovori odgovarajući (dovoljno tačni-zadovoljavaju kriterijum) daje se pozitivna ocena, odnosno u slučaju nedovoljno tačnog odgovora daje se negativna ocena. Shodno dobijenoj oceni, potrebno je potom ažurirati stanje metode tako da ona u narednoj iteraciji da bolje, tj. tačnije rešenje i/ili dobije rezultat koji u većoj meri odgovara stvarnom. Ovaj proces se ponavlja iterativno dok se ne postigne željena tačnost.


### P.2.1 Struktura modela neuronske mreže

Neuronske mreže kao metoda su nastale po ugledu na funkcionisanje ljudskog mozga, i odatle i drugi naziv za ove metode, a to je „pametne metode“. Ljudski mozak se može posmatrati kao skup nervnih ćelija, tj. neurona, po kojima je ova metoda i dobila naziv. Kao i u ljudskom mozgu, u neuronskoj mreži neuron je osnovna gradivna jedinica celokupne metode. Neuron u neuronskoj mreži se ponaša analogno nervnoj ćeliji ljudskog mozga. Tokom rada u određenom vremenskom trenutku prima ulaz od više drugih ćelija, i ukoliko zbirni rezultat signala pređe određenu predefinisanu vrednost, neuron se aktivira i šalje svoj signal dalje na ulaze neurona sa kojima je povezan. Zbog toga, vaki neuron ima skup ulaznih signala, koji u stvari predstavljaju izlaze iz drugih neurona, zatim aktivacionu funkciju koja prima kao ulaz zbir ulaznih signala i izračunava da li neuron treba da se aktivira ili ne i na kraju izlazni signal koji nakon izračunavanja aktivacione funkcije prosleđuje svoj signal na druge povezane neurone. Na slici P2.1 dat je prikaz modela jednog neurona.

Ovako opisani neuroni se grupišu u slojeve. U okviru sloja, svaki neuron tog sloja dobija isti ulaz. Mada ovakav način rada izgleda redundantno, slanjem istog ulaza u različite neurone omogućava se da različiti neuroni otkrivaju različite informacije i donose drugačije



zaključke o ulaznim podacima. Ovo se postiže tzv. težinama koje se definišu po za svaki ulazni signal neurona i svaka od njih direktno promeni svoj ulazni signal pre nego što stigne u aktivacionu funkciju (može se posmatrati kao da svaki ulaz ima određenu težinu u nekom neuronu, koja je različita za više neurona). Npr. u slučaju da se proverava kog je oblika određena figura, moguće je imati sedam neurona od kojih svaki govori za tačno jedan od sedam proizvoljnih oblika da li je figura odgovarajućeg oblika ili nije. Neuronska mreža se formira slaganjem i spajanjem prethodno opisanih slojeva, pri čemu postoje 3 tipa ovih slojeva, u zavisnosti od njihovog položaja.



Slika P2.1 Diagram neurona

Ulazni sloj je skup neurona koji zapravo direktno dobijaju ulazne podatke koje treba da obrade. Ovi ulazni digitalni podaci moraju biti prilagođeni. U ovom radu, digitalni ulazni signal napona je primenom RFFT metode prebačen iz vremenskog u harmonijski domen, izvršeno je izdvajanje potrebnog seta harmonika sa kojima je zatim izračunata vrednost HDU2357 po formuli (5.1).

Izlazni sloj je skup neurona čiji izlazni signali čine ukupan rezultat obrade ulaznih podataka. Minimalno moraju postojati ulazni i izlazni sloj, pri čemu jedan sloj može igrati obe uloge (u kom slučaju je mreža trivijalna i sastoji se od jednog sloja). Ukoliko postoji više od 2 sloja (ulaznog i izlaznog), svi dodatni slojevi se zovu skriveni slojevi (primer rekurentne

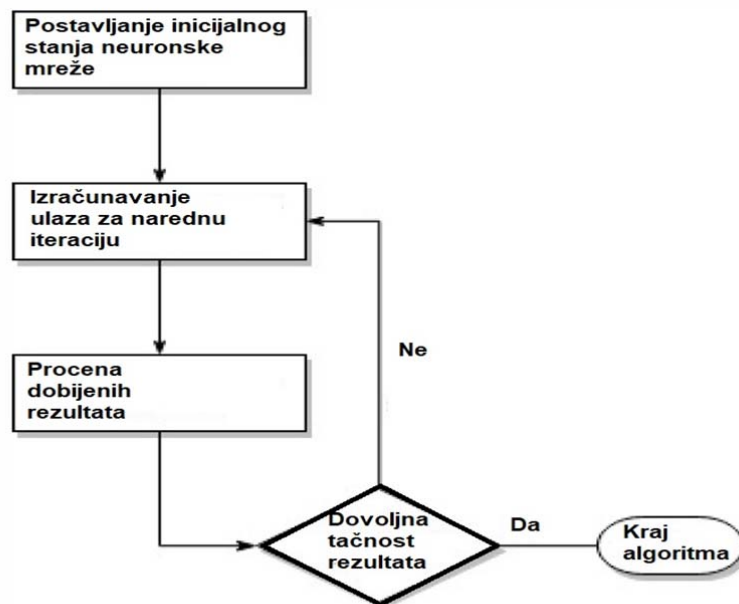
arhitekture neuronske mreže dat je na slici 5.1 u poglavlju 5). RNN mreža korišćena u ovom radu pored ulaznog i izlaznog sloja ima i skriveni sloj neurona.

### P.2.2 Obučavanje modela neuronske mreže

Drugi veoma bitan deo metode neuronskih mreža čine algoritmi za obučavanje i validaciju. Generalni algoritam čine sledeći koraci:

1. postavljanje inicijalnog stanja modela neuronske mreže,
2. izračunavanje izlaza za date vrednosti ulaznih podataka,
3. ocenjivanje dobijenih izlaza,
4. ukoliko je izlaz dovoljno tačan, obučavanje se prekida, u suprotnom se prelazi na narednu iteraciju, uzimaju se sledeći ulazni podaci i ponavlja korak 2.

Blok dijagram algoritma za obučavanje neuronske mreže dat je na slici P.2.2.



Slika P.2.2 Algoritam obučavanja neuronskih mreža

Vezano za ove korake postavljaju se sledeći problemi: kako postaviti inicijalno stanje modela, kako iskoristiti podatke za obučavanje, kako oceniti izlaz iz neuronskih mreža, kako

na osnovu dobijene ocene ažurirati stanje modela da daje bolje izlaze i na kraju, kako oformiti dobar kriterijum ocene rada neuronske mreže odnosno kada obučavanje treba da se zaustavi.

Početno stanje modela je generalno veoma složeno pitanje jer od postavke početnog stanja zavisi čitav proces obučavanja. Metode neuronskih mreža generalno ne garantuju da će model konvergirati ka željenom stanju, čak nema garancije ni da će konvergirati ka bilo kom rešenju ili stanju. Zbog toga veoma je bitno da algoritam koji postavlja početne vrednosti modela bude takav da promenljive vrednosti budu što raznovrsnije i različite od nule. U ovom slučaju raznovrsnost podataka je postignuta time da je uzet veliki broj propada napona snimljenih iz realnih mreža, koji u sebi sadrže različite tipove kvara.

Promenljive vrednosti modela su težine veza između neurona. Nakon što je inicijalno stanje modela postavljeno i dobijen je rezultat za jednu instancu podataka, potrebno je oceniti koliko je rezultat zadovoljavajući, odnosno koliko dobijeni rezultat odstupa od očekivanog rezultata. Ova ocena se naziva funkcija gubitka i direktno utiče na sposobnost modela da se pravilno obuča, bez obzira na to koji algoritam za ažuriranje stanja modela se koristi. Zato je veoma bitno što adekvatnije obrazovati funkciju gubitka, pored toga da postoji i odgovarajući, dovoljno veliki set podataka za učenje. Jedna trivijalna funkcija gubitka je Euklidsko rastojanje između izračunatog i očekivanog rezultata. Međutim, ta se funkcija može unaprediti korišćenjem domenskog znanja. Takođe, bitno je naglasiti da funkcija gubitka treba pažljivo da se projektuje jer od nje direktno zavisi proces obučavanja, kao i način ponašanja modela, odnosno znanja koja će neuronska mreža naučiti i kasnije ispoljiti prilikom upotrebe.

Na dobro formiranu funkciju gubitka nadovezuje se algoritam za učenje, tj. optimizaciju modela. Suštinski, neuronske mreže se mogu smatrati linearnom jednačinom čiji su parametri težine neuronske mreže (veze između neurona). Odatle proizilazi da je obučavanje neuronskih mreža problem optimizacije gde su podaci kojima se parametri prilagođavaju ulazni podaci mreže, predikovani podaci i očekivani podaci. Funkcija koja se optimizuje je zapravo funkcija gubitka (drugačije nazivana i funkcija greške, odnosno funkcija ocene). Obučavanje se svodi na pronalaženje ekstrema funkcije gubitka, prolazeći kroz dati skup podataka. Da li će ekstrem biti minimum ili maksimum, zavisi od semantike optimizacione funkcije. Ukoliko se funkcija optimizacije posmatra kao funkcija gubitka, odnosno greške,

cilj će biti minimizacija kriterijuma, dok će se u suprotnom, ukoliko je funkcija ocene (bolje performanse, veća ocena), tražiti maksimum. Formula po kojoj se optimizuju parametri je:

$$\omega_i = \omega_i + \eta \frac{dE}{d\omega} \quad (p1)$$

U navedenoj formuli  $E$  predstavlja upravo funkciju gubitka,  $\omega_i$  predstavlja vektor svih težina u mreži dok  $\eta$  predstavlja korak učenja. Korak učenja je konstanta koja određuje brzinu učenja same mreže. Korak učenja je veoma bitan parametar čijom promenom kako između iteracija učenja tako i između iteracija ažuriranja može da se utiče na brzinu i kvalitet učenja. Ne postoji jedna tačna vrednost za ovaj parametar, te njegova vrednost zavisi od prirode problema, a postavlja se u skladu sa iskustvom osobe koja vrši obučavanje mreže za konkretnu problematiku.

Obučavanje mreže se vrši obradom vrednosti skupa podataka koji je namenjen treniranju neuronske mreže (skupa za obučavanje). Jedna obrada svih instanci nad ovim skupom se kod obučavanja neuronskih mreža naziva „epoha”. Proces ažuriranja težina je iterativan. Sam momenat ažuriranja je takođe bitan. Ažuriranje težina se može obaviti nakon dobavljanja rezultata predikcija nad jednom vrednosti skupa za treniranje, nad više vrednosti skupa ili nakon proračuna svih rezultata skupa za treniranje (drugim rečima, nakon čitave epohe). Uobičajeno je da se kao broj instanci, bira vrednost iz intervala 5 i 50. Tačna vrednost, ponovo, zavisi od karakteristika skupa podataka sa kojim se neuronska mreža trenira, iskustva osobe koja obučava neuronsku mrežu, ali takođe i tehničkih ograničenja (u pogledu memorije). Nakon što se izvrši predikcija nad svim instancama u okviru paketa, radi se izračunavanje proseka gradijenta nad svim instancama paketa i tek potom se ažuriraju težine. Ekstremi poput jedne instance u paketu, odnosno korišćenje svih instanci skupa za trening neuronske mreže kao paketa u opštem slučaju mogu dovesti do nemogućnosti obučavanja. U slučaju korišćenja jedne instance može se desiti da gradijenti kod uzastopnih instanci naizmenično budu suprotnih smerova sa istim pravcem, dok u drugom slučaju može se desiti da prosek gradijenta teži nuli u kom slučaju obučavanje ne može da se desi.

Predstavljena formula za obučavanje je osnovna, a u praksi postoje unapređenja ove formule. Neki od algoritama koji vrše ažuriranje, tj. optimizovanje po unapređenim


funkcijama za ažuriranje težina su (imena navedena u originalu na engleskom): SGD (Stochastic gradient descent), RMSprop, Adagrad, Adadelata i Adam .

Jedan od uobičajenih problema u obučavanju je preterano specifično obučavanje. To je pojava koja je generalno prisutna u metodama mašinskog učenja i javlja se kada podataka za obučavanje ima mnogo manje od parametara u modelu metode mašinskog učenja. Ispoljava se nesposobnošću metode da na instancama ulaznih podataka nad kojima nije obučavana predikuje očekivane podatke na izlazu. Uzrok ove pojave leži u činjenici da se metoda, umesto da nauči odnose između ulaznih podataka na osnovu kojeg će izračunavati izlaze, optimizuje da za konkretan ulaz da konkretan izlaz i ništa drugo. Da bi se pomenuti problem dijagnostikovao, neophodno je pratiti grafik obučavanja, odnosno, odnos između funkcije gubitka nad trening podacima i funkcije gubitka nad validacionim podacima. Kada je predikcija nad skupom za obučavanje visoke preciznosti, dok je nad instancama kontrolnog skupa predikcija značajno lošija, to je obično pokazatelj problema sa mapiranjem konkretnih ulaza na konkretne izlaze.

Da bi se problem preterano specifičnog obučavanja predupredio, postoje različite metode koje se jednim imenom nazivaju regularizacione metode. Neke od njih su veštačko unapređenje podataka, L1 i L2 regularizaciona metoda, ograničenje maksimalne norme obučavanja, metoda otkaza, paketna normalizacija, itd .

Veštačko unapređenje podataka je tehnika kojom se povećava broj instanci skupa za treniranje uz oslonac na već postojeće instance u skupu. Kako je već napomenuto u prethodnim pasusima, preterano specifično obučavanje je najčešće rezultat većeg broja parametara modela u odnosu na broj instanci obučavajućeg skupa, odnosno premalog broja instanci nad kojima se učenje vrši. Česta praksa je da se u ovom slučaju iskoriste već postojeće instance ulaznih podataka, nad njima izvrši transformacija koja će kao rezultat dati nov izlaz koji prethodno nije postojao.

Metoda otkaza je tehnika kojom se predupređuje previše specifično obučavanje modela neuronske mreže. Zasniva se na onemogućavanju obučavanja neurona po nekom pragu verovatnoće. Prilikom svakog ažuriranja težina u modelu za određeni neuron izračunava se verovatnoća da njegove izlazne težine ne budu ažurirane, odnosno, njihov izlaz se predstavlja nulom prilikom izračunavanja predikcije. Vizuelni prikaz metode otkaza je dat na slici P2.3.



Slika P.2.3 Primer delovanja i razlike kod primene metode za sprečavanje specifičnog obučavanja

Na osnovu slike se može primetiti da se postavljanjem izlaznih težina za jedan konkretan neuron na vrednost nula dobija situacija u kojoj taj neuron više ne utiče na predikciju same mreže, zbog čega se može smatrati da taj neuron ne funkcioniše, odnosno da je otkazao (otuda potiče i naziv metode). Metod se primenjuje svaki put prilikom računanja predikcije i ažuriranja težina, što izaziva pojavu da se svaki neuron u mreži obučavao  $p\%$ , čime se efektivno sprečava da izlaz pojedinih neurona nadjača izlaze ostalih neurona.

Kao zaključak procesa obučavanja se može izvesti da uravnoteženost vrednosti težina veza između neurona sprečava pojavu preobučavanja, da je potrebno imati odgovarajući set podataka za obučavanje, kao i da je potrebno poznavati model i problem za koji se neuronska mreža obučava.