Detekcija otočnog pogona foto naponskih sustava metodama umjetne inteligencije

Mlakić, Dragan

Doctoral thesis / Disertacija

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:505475

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Dragan Mlakić

DETEKCIJA OTOČNOG POGONA FOTO NAPONSKIH SUSTAVA METODAMA UMJETNE INTELIGENCIJE

Doktorska disertacija

Osijek, 2019.

Doktorska disertacija izrađena je na Zavodu za elektroenergetiku Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Mentor: prof.dr.sc. Srete Nikolovski

Doktorska disertacija ima 240 stranica.

Disertacija br.:

Povjerenstvo za ocjenu doktorske disertacije:

Predsjednik : Izv.prof.dr. Marinko Barukčić

Član mentor: Prof.dr. Srete Nikolovski

Član: Red.prof.dr. Tatjana Konjić, ETF Tuzla

Zamjenik člana: Izv. prof.dr.Predrag Marić

Datum obrane doktorske disertacije: 09.05.2019.godine.

Hvala mojim najmilijima, supruzi i ocu, na strpljivosti i razumijevanju, a posebno mentoru na velikodušnoj pomoći i prijateljstvu

SADRŽAJ

1. UVOD ……..……1

1.1 Opis problema 2

1.2 Motivacija istraživanja 6

1.3 Cilj istraživanja 6

1.4 Hipoteza 7

1.5 Organizacija i struktura disertacije 8

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA ....……...……...…10

2.1. Otočni pogon i prepoznavanje otočnog rada distribuiranog izvora unutar distribucijske mreže 11

2.2. Primjene metoda umjetne inteligencije u energetici .....……..……34

2.3. Primjene metoda umjetne inteligencije u otkrivanju otočnog rada .....……..61

3. OTOČNI RAD DISTRIBUIRANIH IZVORA ENERGIJE .....…….65

4. METODE DETEKCIJE ……...…….……..78

4.1. Pasivne metode ……..85

4.1.1. Pod/nad napon i pod/nad frekvencija ……86

4.1.2. Otkrivanje naponskog faznog pomaka ……..88

4.1.3. Otkrivanje naponskih harmonika i detekcija harmonika.....….89

4.2. Aktivne metode ……...……..91

4.2.1. Mjerenje impedancije .....……..…….92

4.2.2. Detekcija impedancije na određenoj frekvenciji ……..……..94

4.2.3. Pomicanje frekvencije klizanjem (Slip Mode Frequency Shift – SMS)..……....94

4.2.4. Odstupanje frekvencije ....…….96

4.2.5. Sandija frekvencijsko pomjeranje (Sandia Frequency Shift - SFS) ...…….98

4.2.6. Sandija naponsko pomjeranje (eng. Sandia Voltage Shift – SVS) .....…...…..…99

4.2.7. Frekvencijski skok (Frequency Jump – FJ) ……...…....100

4.2.8. Jedinice mrežnog nadzora s dodijeljenim višeslojnim serijskim sklopnim uređajima ....….101

4.3. Komunikacijske metode .....…….....103

4.3.1. Napojni vod koji služi kao nosač za komunikaciju.....…….....104

4.3.2. Signal generiran na isključenu distribucijskoj mreži-a.....……..…….106

4.3.3. Nadzor, kontrola i prikupljanje podataka (Supervisory Control and Data Acquisition - SCADA) ……...……..……107

5. METODE UMJETNE INTELIGENCIJE …..……...……..……..……109

5.1. Adaptivni sustav neuro-neizrazitog zaključivanja (ANFIS).....……..…110

5.1.1. Slojevi ANFIS-a .....……....……....115

5.2. Duboko Učenje (DL) .....……..……..……..…..…118

5.2.1. Konvolucijske neuronske mreže (eng. Convolutional Neural Network – CNN) .....……...123

5.3. Support Vector Machine (MPV) ……....……..127

5.3.1. Algoritam hiperprostora mekane margine .....……....…….....130

6. METODOLOGIJA PRIKUPLJANJA ULAZNIH PODATAKA I PREPORUČENE METODE DETEKCIJE ……..……...…..……..….132

6.1. Uzorkovanje podataka sa distribucijske mreže u točki zajedničkog spajanja (točki zajedničkog spajanja) .....……..…...133

6.2. Slaganje podataka i treniranje umjetne inteligencije metoda ……..……142

6.2.1. Adaptivni sustav neuro-neizrazitog zaključivanja (eng. Adaptive Neuro-Fuzzy Inference System - ANFIS) .....……..….142

6.2.2. Duboko učenje (eng. Deep Learning - DL) ……....….148

6.2.3. Metoda potpornih vektora (eng. Support Vector Machine - MPV) ..……..…155

7. ISPITNI MODEL, STANDARDI, MODELI ISPITIVANJA …..……. 166

7.1. Ispitni model niskonaponske distribucijske mreže .....……166

7.2. Ul 1741 i IEEE 1547 Standardi …….…….……...171

7.3. Modeliranje kvarova na mreži ……176

7.4. Paralelni rad sa drugim distribuiranim izvorima energije ..…….…….…177

8. REZULTATI TESTIRANJA ....……..……....…179

8.1. Adaptivni sustav neuro-neizrazitog zaključivanja (ANFIS) .....…….180

8.2. Metoda dubokog učenja (DU) ..…...……..……..…188

8.3. Metoda Potpornih Vektora (MPV) …….....……...192

8.4. Usporedba rezultata rezultata .....……...……203

9. ZAKLJUČAK ...……...……208

10. LITERATURA ...……...…….....210

11. SAŽETAK …….……....…238

12. ŽIVOTOPIS .…….……240

1. UVOD

Distribuirani izvori (DI) danas su široko rasprostranjeni u distribucijskoj mreži (DM) i preuzimaju sve više udjela u potrošnji električne energije na sebe. Sve veća zastupljenost distribuiranog izvora donosi mnoge prednosti: povećava se pouzdanost sustava, kvaliteta energije u nekim slučajevima, postojanost napona, sigurnost napajanja itd. Uz prednosti pojavljuju se i mogući nedostaci i rizici za mrežu i korisnike, u ovom slučaju to su potrošači i ostali proizvođači električne energije. Nedostaci mogu biti, ali nisu ograničeni na: povećanu razinu iznosa struja kratkog spoja, namjerno ili nenamjerno odvajanje od distribucijske mreže, loša kvaliteta energije u nekim slučajevima i rizik od otočnog rada. Otočni rad u sklopu distributivne mreže nije željeno mrežno uklopno stanje, a javlja se kada je jedan dio mreže od spojen od ostatka mreže s najmanje jednim distribuiranim izvorom koji može autonomno napajati taj dio mreže. Rad u otočnom pogonu je opasan za komponente distribucijskog sustava, sigurnost radnika, mogući su kvarovi uređaja potrošača i druge opasnosti. Zaštita od otočnog rada distribuiranog izvora je jedan od važnih zahtjeva kada se novi distribuirani izvor treba instalirati u mrežu, što čini zaštitu od otočnog rada kao jednu od standardnih i važnih zaštita distribuiranog izvora. Mnogi istraživači predložili su neka rješenja za detekciju otočnog rada te su na osnovu dosadašnjih istraživanja pojavljuju četiri glavna načina: zaštita temeljena na komunikaciji, pasivne, aktivne i hibridne metode zaštite.

Zaštita u mreži koja ima veliki udio foto naponskih elektrana različitih instaliranih snaga je postala kompleksno područje u kojem složenost problema raste s brojem foto naponskih elektrana u mreži bilo da je to na niskom, srednjem i/ili visokom naponu. Optimizacija zaštita takve mreže definitivno postaje problem koji se ne može baš lako riješiti i takav rezultat traži promjenu koncepta distribucijske mreže u novije vrijeme. Dodatnu složenost otkrivanju otočnog rada predstavlja i činjenica da fotonaponske elektrane ne proizvode niti troše jalovu energiju u većem iznosu koji bi utjecao na kvalitetu električne energije u distribucijskoj mreži, bilo da je riječ o kapacitivnoj ili induktivnoj. Izmjenjivači (DC/AC), koji su sučelje fotonaponske elektrane sa distribucijskom mrežom, su izrađeni u modernoj tehnologiji mikrokontrolera, te time doprinose brzim promjenama na pojedinačne pojave u mreži, tako što djeluju na faktor snage i poboljšavaju kvalitetu el. energije. Primjerice kao što su brze i spore promjene napona ili prekoračenje veličina koje nisu nadzirane veličine od zaštitnih uređaja (harmonici, istosmjerna komponenta izmjeničnog napona, signalni naponi itd.). Naravno, zbog njihove velike sposobnosti praćenja određenih veličina te pravovremene reakcije na određene pojave, izmjenjivači postaju središte samih zaštita od određenih pojava, samim time i otočnog rada. Da bi se ovo istraživanje provelo uspješno, potrebno je istraživanje usmjeriti na problematiku otočnog rada iz jednostavnijeg kuta a kasnije se

fokusirati na samu izvedbu rješenja. Zbog toga nema potrebe ulaziti u detaljnu analizu pojedinih veličina koji se nadgledaju, da bi se pojava mogla identificirati bez ulaženja u diskusiju oko matematskog aparata. Taj zadaću, izvrsne matematske pozadine, imaju metode umjetne inteligencije gledano s inženjerske strane, čiju implementaciju preuzima izmjenjivač koji prati stanje rada fotonaponske elektrane na distribucijskoj mreži, tj. da li je distribuirani izvor u otočnom radu ili ne.

Prema saznanjima autora, tematsko područje istraživanja je u području elektrotehnike i informatike dosta raširenо, te izravno ili neizravno vezano za elektroenergetiku, a nekim svojim rješenjima i za područje umjetne inteligencije. Međutim nije obrađeno na način kako je ovim istraživanjem to urađeno, s obimom od sedam (7) ulaznih podataka koji su različiti a zajedno su kao jedinstveni skup podataka koji se opet razlikuje od jedne do druge metode umjetne inteligencije, a samim time nije istraženo sve što će biti učinjeno u ovoj disertaciji. Područje istraživanja zaštite od otočnog rada je još uvijek ogromno i nakon ovog istraživanja, ali su ovdje date smjernice koje će biti od velike koristi u detekciji pojave otočnog rada, te njegovog prepoznavanja u distributivnim mrežama.

Ovom disertacijom razvijene su i predložene metode zaštita distribuiranih izvora, posebice fotonaponskih sustava temeljene na metodama umjetne inteligencije u potpuno aktivnoj mreži koja se ponaša kao živi organizam: širi se i sužava, usvaja nove osobine, ima nove komponente koje su do tada nepoznanica, omogućava protok informacija u oba smjera te se sukladno tim osobinama ponaša aktivno u realnom vremenu. Sve metode korištene u ovom radu za otkrivanje otočnog rada su iz područja umjetne inteligencije, te su po mišljenju autora ove disertacije veoma pogodne za otkrivanja otočnog rada distribuiranog izvora u mreži.

1.1. Opis problema

Zaštita od otočnog rada integrirana u izmjenjivaču, podrazumijeva integraciju unutar aktivne pametne mreže koja je već duboko prožeta distribuiranim izvorima, u ovom konkretnom slučaju s foto naponskim elektranama. Navedeni distribuirani izvori, ustvari fotonaponske elektrane su proizvođači djelatne energije, tj. proizvode najčešće samo djelatnu energiju za razliku od uobičajenih konvencionalnih izvora energije. Ovo je isključivo propisano mrežnim pravilima distribucije, a podržano povoljnim ekonomskim dobitcima za vlasnika fotonaponske elektrane. Samim time se ograničava udio distribucije u regulaciji snaga po povoljnim naponskim prilikama

za krajnjeg korisnika. Tim više je dodatni zahtjev prema distribuiranim izvorima da brzo otkriju nepravilnosti u radu a koje su nedopustive od strane distributera električne energije, a jedna od njih je otočni rad fotonaponske elektrane. Znanstveno istraživanje predstavljeno u ovoj disertaciji razmatra nekoliko metoda koje su iz područja umjetne inteligencije u svrhu što efikasnijeg otkrivanja otočnog rada fotonaponske elektrane. Za potrebe otkrivanja otočnog rada distribuiranog izvora, koriste se tri grupe metoda koje će detaljnije biti opisane u narednom tekstu.

Način zaštite temeljen na komunikaciji pokriva većinu zona ne detekcije (NDZ) pomoću komunikacijskih tehnologija za potvrdu uklopnog stanja prekidača izvora, koji sprječava otočni rad [1]. Problem s tim metodama je cijena opreme i radova koji je potreban za instalaciju sustava zaštite i cijena komunikacijske sheme zaštite svaki put kada se dodaje nova komponenta u mreži ili se dodaje novi element u distribucijskoj mreži. Aktivne i pasivne metode predstavljaju lokalizirane algoritme za prepoznavanje otočnog rada praćenjem promjene određenih električnih veličina u mreži kao što su napon [1], jalova snaga [2], frekvencija [3] itd.

Pasivne metode prate vrijednosti nekih veličina u točki zajedničkog spajanja (PCC –Point of Common Copuling) kontinuirano uspoređujući njihove vrijednosti s unaprijed definiranim pragom. Pasivne metode generalno imaju najveću zonu ne detekcije (NDZ), prvenstveno ovisno o praćenoj veličini bez ikakvog štetnog utjecaja na kvalitetu napajanja. Neke od pasivnih metoda se temelje na promjeni frekvencije (ROCOF) [4], promjeni kutne razlike (ROCPAD), promjeni nezavisnosti energetskih veličina [5] itd.

Aktivne metode baziraju se na utiskivanju poremećaja u mrežu na mjestu priključenja elektrane i praćenju odziva mreže. Ove metode imaju znatno manju zonu ne detekcije nego pasivne metode, ali stoga imaju mnogo veći utjecaj na kvalitetu električne energije, uglavnom negativan. Iako neke metode imaju mogućnost optimiranja u cilju poboljšanja predložene metode, čime se smanjuje zona ne detekcije [6] [11]. Neke od popularnih aktivnih metoda su utiskivanje (injektiranje) signala visoke frekvencije [6] [7], npr. jalove snage, ili aktivni poremećaj struje.

Hibridne metode su najnovija skupina rješenja zaštite od otočnog rada. Hibridne metode nastoje kombinirati koristi pasivnih i aktivnih metoda u jednu lokaliziranu shemu zaštite od otočnog rada [6] [7]. Iako se na prvom mjestu čini da je zona ne detekcije pokrivena, pojavljuju se novi problemi kada se kombiniraju pasivne i aktivne metode i jer se uključuje više parametara u analizu pa se javlja: problem kvalitete električne energije, teška prilagodba na različite vrste distribuiranih izvora.

Mnogo više o navedenim metodama prepoznavanja otočnog rada slijedi u narednim poglavljima.

Ovaj rad predlaže novu metodologiju pristupa otkrivanju otočnog rada uz pomoć tehnika iz područja Umjetne Inteligencije (AI- Artificial Intelligence). Predložena metodologija može se klasificirati kao podskup pasivnih ili kao nova metodologija pored navedene tri, sve zavisi od autora koji je obrađuju, a autor ove disertacije će je smatrati podskupom pasivnih metoda. U svakom slučaju po načinu detekcije otočnog rada jeste pasivna metoda, samo što koristi napredne tehnike umjetne inteligencije za analizu promatranih veličina u električnoj mreži.

Predložene korištene metode su adaptivni neuro-fazi sustav zaključivanja (en. Adaptive Neuro-Fuzzy Inference System - ANFIS), duboko učenje konvolucijskim neuronskim mrežama (en. Deep Learning Convolution Neural Network - CNN) i metoda potpornih vektora (en. Support Vector Machine - SVM). Glavni ciljevi ovog istraživanja su :

- smanjiti utjecaj detekcije otočnog pogona na kvalitetu električne energije s uz održavanje točnosti detekcije i smanjenje zone ne detekcije što je više moguće,
- povećati preciznost tehnika detekcije bez povećavanja rizika od lažnog odvajanja distribuiranog izvora od distribucijske mreže,
- prilagoditi za rad pod različitim uvjetima rada distribucijske mreže: višestruki distribuirani izvori u istoj točki zajedničkog spajanja, kvarovi na distribucijskoj mreži, različita kvaliteta Q_f mreže, UL1741 standard, brzo punjenje električnih automobila (PHEV) na distribucijskoj mreži.

Bit predloženih metoda je obrada podataka na način da se svi potrebni podaci snimaju uz pomoć uređaja smještenog na točki priključka elektrane na mrežu. ANFIS, CNN i SVM kao ulazne podatke koriste sedam veličina mjerenih na mjestu priključenja elektrane, a to su: frekvencija (f), djelatna snaga (P), jalova snaga (Q), efektivna vrijednost struje (RMS_I), efektivna vrijednost napona (RMS_V), ukupno harmonijsko izobličenje struje (THD_I), te ukupno harmonijsko izobličenje napona (THD_V). Uspješnost detekcije otočnog rada se zasniva na uspješnom snimanju i uzorkovanju veličina koje ulaze u obradu na ove tri predložene metode.

ANFIS kombinira robusnost umjetne neuronske mreže za rješavanje problema i fleksibilnost neizrazite logike (FL) za generalizaciju ulaznih vrijednosti i klasifikaciju problema. Ova kombinirana hibridna metoda je vrlo fleksibilna i pogodna u smislu predviđanja i odnosa između ulaza i izlaza. Kombinirajući gore navedenih sedam veličina pomoću ANFIS-a, ovdje je uveden novi pristup i dokazana njegova učinkovitost. Kako bi se pokazala učinkovitost predložene

strategije za zaštitu od otočnog rada, u MATLAB / Simulink okruženju provode se simulacijske analize u vremenskim intervalima i rezultati se provjeravaju usporedbom s prethodno postojećim metodama iz literature. Dobiveni rezultati pokazuju da predložena metoda otkrivanja otočnog rada može detektirati otočni rad mreže u različitim konfiguracijama i uvjetima opterećenja, te zadovoljiti točnost zaštite, brzinu rada, selektivnost i vjerodostojnost. Koeficijent kvalitete mreže (Q_f) dotjeruje se prema UL1741 standardu. Navedeni standard je usvojen u SAD-u 1999. godine te je postao standard za testiranje izmjenjivača za fotonaponske elektrane. Također, predložena metoda detekcije otočnog rada daje zonu ne detekcije znatno manju, u usporedbi s prethodno istraživanim tehnikama.

Druga tehnika koja je korištena je konvolucijska neuronska mreža (KNM). KNM je jedna od najnovijih metoda umjetne inteligencije, koja se koristi za prepoznavanje ponašanja, pa je pogodna za analizu ponašanja u distribucijskoj mreži u kontekstu otkrivanja otočnog rada. Zasnovana je uglavnom na neuronskim mrežama sa jako velikim skrivenim slojem u kojem se obavlja klasifikacija signala s ulaza. Specifičnost konvolucijske mreže je u tome da je prvenstveno kreirana za prepoznavanje slika. S tim na umu, kreiran je poseban ulazni set podataka za ovu metodu umjetne inteligencije.

Treća metoda korištena u ovom istraživanju je Support Vector Macine (SVM) ili Metoda potpornih vektora. Dvije različite situacije pokrivene su SVM algoritmom: za slučaj otočnog rada, te slučaj kvara u mreži. Predložena metoda otkrivanja otočnog rada i kvara razvijena je pomoću učenja metode potpornih vektora s optimalnim izlazom među raspoloživim klasifikacijskim izborima: križna validacija za zaštitu od zasićenosti treninga uključena je prema zadanim postavkama i Gaussove funkcije.

Inovativnosti ove metode su:

- Predlaže razlikovanje dviju glavnih sustava zaštite u naprednim mrežama : otočni rad distribuiranih izvora i mrežnih kvarova. Predložena metoda koristi uzorkovanje temeljeno na jednom mjestu mjerenja, u točki zajedničkog spajanja elektrane na mrežu. Ovaj rad klasificira navedene anomalije u jednom okviru temeljenom na dva algoritma SVM.

- Predloženi algoritmi potpornih vektora razvrstavaju otočni rad i kvar na mreži pomoću istih unesenih podataka, bez posebne segmentacije ili filtriranja. S prethodno obrađenim sirovim podacima u nizu ulaznih podataka, klasifikatori predviđanja imaju skup podataka s dovoljno informacija za prepoznavanje anomalije na temelju učenja.

- Predloženi okvir sastoji se od dva klasifikacijska bloka algoritma metode potpornih vektora: otkrivanje otočnog rada i otkrivanje kvara. Oba bloka uče koristeći različite podatke koji se dobivaju od mjernih podataka. Prvi algoritam koristi sedam (7) Gaussian-ovih klasifikatora metode potpornih vektora s kernel skale (kernel- klasifikator koji odvaja prostor skupova onih čestica koje želimo izolirati od onih koje ne želimo) od 8 dimenzija za otkrivanje otočnog rada. Drugi algoritam koristi sedam sustava provjere prototipa (eng. Prototype Verification System – PVS) Gaussovog klasifikatora i obučen je korištenjem kernelove ljestvice od 8 dimenzija i istih 7 spomenutih signala. Kombinacija tih dvaju algoritama čini jasnu razliku između otočnog rada i kvara u mreži.

1.2. Motivacija istraživanja

Uvidom u dostupnu literaturu koja je jako bogata raznim idejama za otkrivanje otočnog rada, ali i drugih problema u elektroenergetici uz pomoć umjetne inteligencije, je dala uvid u općenitost i ozbiljnost korištenih metoda. S tim na umu, metodama umjetne inteligencije je moguće je bez mnogo ulaska u rješavanje matematskog aparata, uraditi mnogo stvari koje su u suštini dosta kompleksnije i zahtijevaju jako puno vremena za proračun, te ne daju garanciju uspjeha u svim situacijama. Metode koje su u literaturi dale su uvid u ogromno područje koje je u začetku, ne samo u elektroenergetici nego u telekomunikacijama, klasifikacijama pojava u medicini, biologiji [13], rješavanju matematskih problema koji su do sada bili nerješivi [14], preventivnoj dijagnozi bolesti, te raznim drugim oblastima. Činjenica o broja istraživača koji se bave time i uzimaju kao glavnu metodu neku od metoda umjetne inteligencije, potvrda je motivacije prilikom usmjeravanja vlastitog znanstveno-istraživačkog rada.

Jasno je da individualno istraživanje ne može biti na nivou skupine istraživača, ali može doprinos istraživanjima koja granice oblasti elektroenergetike pomične jedan korak dalje, a samim time i metode umjetne inteligencije plasira u nova područja primjene.

1.3. Cilj istraživanja

Cilj istraživanja je na jasan i sustavan način prikazati spoznajni proces kojim se došlo do slijedećih znanstvenih doprinosa:

- Hibridna metoda prepoznavanja otočnog rada fotonaponske elektrane temeljena na metodama umjetne inteligencije: ANFIS, CNN i SVM.
- Prikupljanje ulaznih veličina kroz standardna mjerenja na izmjenjivaču, te njihov prikaz u obliku prilagođenom za navedene metode umjetne inteligencije pojedinačno.

- Validacija navedenih metoda prema tri pokazatelja: preciznost, zona ne detekcije i brzine detekcije otočnog rada.

U nastavku disertacije se detaljno opisuju navedena istraživanja i opisuju načela otkrivanja otočnog rada kroz detaljan opis korištenih metoda. Iscrpnim prikazom navedenih metoda se jasno prezentira korisnost kroz konkretni primjer na modelu FN sustava.

1.4. Hipoteza

U prethodnom tekstu je navedena važnost prikazane problematike i uočen je izazov u njegovom rješavanju u predstavljenom znanstvenom području. Glavna ideja na kojoj se temelji prikazano znanstveno istraživanje jeste, kako rješenje za otkrivanje otočnog rada u distribucijskoj mreži može biti u potpunoj mjeri zasnovano na ponuđenim metodama koje su potvrđene u znanstvenim radovima raznih autora, baveći se istom tematikom. Postupni i temeljiti razvoj distribucijska mreža u smjeru integracije distribuiranih izvora unutar nje, podrazumijeva isti takav tempo pri napretku zaštita u distribucijskoj mreži čija je glavna tematika zaštita ljudskih života i materijalnih dobara. Novi problem koji se postavlja pred znanstvenu zajednicu jeste otkrivanje otočnog rada distribuiranih izvora, u slučaju ovog istraživanja to je foto naponska elektrana. U znanstvenim radovima koji će biti tema jednog od slijedećih poglavlja ove disertacije, obrađuju se metode koje su srodne spomenutoj tematici, s osvrtom na metode koje su predložene ovim istraživanjem.

Slijedi trend konstantnog kretanja u smjeru što točnijeg otkrivanja otočnog rada distribuiranih izvora u distribucijskoj mreži, sa naglaskom na zadržavanje kvalitete napajanja bez manjkavosti po preciznost metode koja otkriva otočni rad, vremenu detekcije i smanjenju zone ne detekcije.

Detaljno pojašnjenje osnovne ideje ovog doktorskog rada je kako analizom jedne jednostavne distribucijske mreže, koja ima sve osobine mreže sa instaliranim distribuiranim izvorom u cilju otkrivanja otočnog rada kroz nekoliko situacija na samoj mreži, se može pristupiti mnogo kompleksnijoj mreži sa dosta više parametara distribucijska mreža, prema istoj analogiji. Određivanju spomenutih ciljeva pristupilo se odmah na početku znanstveno-istraživačkog rada ove disertacije, a upotrjebljene metode u svrhu tematike istraživanja su potvrđena objavom 3 znanstvena rada u IEEE časopisima, te nekoliko međunarodnih konferencija iz područja otkrivanja kvarova na distribucijska mreža. Nastavkom istraživanja su dalje definirani ciljevi koji su profilirani, u manjoj mjeri promijeni, te predstavljeni kroz istraživački rad. Konačni rezultat jeste predstavljena metodologija koja koristi tri metode umjetne inteligencije, svaka na svoj način, u svrhu otkrivanja otočnog rada fotonaponske elektrane unutar distribucijska mreža.

U kraćem obliku, predstavljena hipoteza ovog istraživanja bi bila: " Metodama umjetne inteligencije moguće je uspješno prepoznati i otkriti otočni rad fotonaponske elektrane u distributivnoj mreži".

1.5. Organizacija i struktura disertacije

Disertacija je izrađena prema sljedećim poglavljima koja obrađuju temu istraživanja:

Prvo poglavlje donosi detaljan opis izazova koji su predmet ovog istraživanja i koji je dokumentiran ovom disertacijom. U poglavlju je naveden doprinos kolega istraživača koji su u dotičnom polju istraživanja dosegnuli određeni rezultat, te time motivirali autora ove disertacije na istraživački rad u ovom području.

U drugom se poglavlju analizira konkretne objavljene znanstvene članke u časopisima i zbornicima konferencija, znanstvene i stručne knjige, doktorske disertacije i druge vrste radova iz kategorija stručne i znanstvene literature predmetnog područja istraživanja. Prikazani pregled je upotpunjen komentarima autora ove disertacije s ciljem detaljnije analize i uvida u znanstveni doprinos ove disertacije.

Treće poglavlje opisuje pojavu koju nazivamo otočni rad distribuiranog izvora u distribucijskoj mreži. Naglasak je na sve tipove distribuiranih izvora električne energije, te kako se navedena pojava manifestira na distribucijskoj mreži i njenim parametrima. Također je u poglavlju 3 riječ o motivaciji koja je utjecala na ovo istraživanje iz perspektive zaštita distribucijske mreže.

Četvrto poglavlje obrađuje dosadašnje usvojene metode otkrivanja otočnog rada, sa posebnim osvrtom na lokalne metode kojima po svojim parametrima pripada i metodologija predložena ovim istraživanjem. Navedeni osvrt na dosadašnja istraživanja je prožet autorovim mišljenjem s ciljem boljeg uvida u pojašnjenje hipoteze ovog doktorskog rada.

Peto poglavlje predstavlja detaljan opis metoda umjetne inteligencije koje su korištene u disertaciji u svrhu istraživačkog rada. Metode umjetne inteligencije su predstavljene iz aspekata efikasnosti, te prirode problema koje rješavaju.

Šesto poglavlje predstavlja sustav prikupljanja podataka koji su ulazni podaci za metode prepoznavanja otočnog rada. Sustav prikupljanja podataka je kao jedan od najvažnijih dijelova same predmetne metodologije ove disertacije obrađen detaljno s naglaskom na uzorkovanju, te je blok ulaznih podataka podijeljen po metodama umjetne inteligencije. Svaka navedena metoda

umjetne inteligencije je posebna po svom skupu ulaznih veličina, te je kao motivacija što efikasnijem korištenju metode umjetne inteligencije, svaki ulaz definiran posebno.

Sedmo poglavlje donosi prikaz alata koji je korišten u modeliranju mreže za potrebe testiranja, kroz simulaciju distribucijske mreže sa distribuiranim izvorom. Naglasak je dan na simulacijsku paket Matlab/Simulink koji se koristi za integraciju proračunskog/trening postupka metode umjetne inteligencije, sa zadanim okvirima distribucijske mreže koja je pod testnim propisima UL 1741. Također, naveden je i prikaz slučajeva simulacije kvarova te brzog punjenja električnih/hibridnih automobila.

Osmo poglavlje konačno predstavlja rezultate testiranja na predstavljenom modelu sukladno navedenim standardima i prilikama u distribucijskoj mreži. Rezultati su prikazani u 4 logičke cjeline: tri se odnose na svaku od predloženih metoda umjetne inteligencije detekcije otočnog rada i jedno poglavlje je usporedba dobivenih rezultata iz simulacije, te je isto ukratko prodiskutirano.

Deveto poglavlje daje konačna razmatranja autora o doprinosima doktorske disertacije u polju koje obrađuje zaštitu elektroenergetskih postrojenja i električne mreže u području distribucije električne energije.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Svrha ovog poglavlja jeste istraživanjem dostupne literature, pod kojom se smatraju objavljeni znanstveni i stručni radovi te doktorske disertacije utvrditi znanstvenu opravdanost istraživačkog rada za primjenu metoda umjetne inteligencije u otkrivanju otočnog rada fotonaponske elektrane u distribucijskoj mreži. Ciljevi koji su postavljeni unutar radova koji su analizirani su smanjenje zone ne detekcije koliko je god moguće, zadržavajući preciznost metode uglavnom samo na otočni rad distribuiranog izvora, te provođenje procedure detekcije što je moguće brže.

Ono što se može zaključiti analizom dostupnih znanstvenih članaka u renomiranim časopisima jeste da je su metode umjetne inteligencije već zadnjih 10 godina veoma zastupljene kao metode korištene u znanstveno istraživačkim radovima, bilo da je to u sklopu neke druge znanosti ili isključivo informacijskih tehnologija. Rezultat toga jeste da su te metode jako evoluirale od svog originalnog oblika, te time postale određeni standard za pitanja optimizacije, klasifikacije, razdjeljivanja, tj. odvajanja, kripcije i dekripcije itd. Sukladno tome, svoje mjesto su našle unutar elektroenergetike.

S druge strane, također uvidom u dostupnu znanstvenu literaturu se može primijetiti da pojavu otočnog rada tek u zadnje dvije-tri godine počinju koristiti mnogi autori u svojim istraživanjima. To je prvenstveno zahvaljujući tome što rastući trendovi udjela obnovljivih izvora energije u elektroenergetskoj mreži nisu samo rezervirani isključivo za velike ulagače kao što su državne firme ili konzorciji, nego zato što sada na scenu dolaze manji ulagači koji imaju financijsku korist ulažući mnogo manje novca nego prije u takve projekte. Iako je namjera poticati energetsku neovisnost malih potrošača, čime se čuva okoliš, mnogo obnovljivih izvora energije postaju dominantni proizvođači el. energije unutar distribucijske mreže. Zahvaljujući tome dolazi do novih trendova u elektroenergetici i njenim znanstvenim pod područjima. Jedno od tih područja jeste otočni rad obnovljivih izvora energije unutar distribucijske mreže. Tema mnogih radova fokusiranih na ovoj području nije samo otkrivanje otočnog rada, nego njegova integracija u postojeću arhitekturu naprednih mreža prema kojima distributivni sustav postupno, ali sigurno ide.

Naravno, lako je zaključiti da se dvije spomenute teme nadopunjuju i nastavljaju jedna na drugu zbog prirode problema i mogućnosti rješenja dostupnih primjenom umjetne inteligencije. Zahvaljujući toj sintezi objavljeni su mnogi radovi, te time pokriveno dosta toga, ali opet ne potpuno, područje otočnog rada i metoda umjetne inteligencije. Razlog za ovo istraživanje je upravo u tome međuprostoru, gdje nema svih ili nekih obrađenih metoda umjetne inteligencije u svrhu detekcije otočnog rada obnovljivih izvora energije u distribucijskoj mreži. Naravno, tema

otočnog rada također daje prostora da se u samoj analizi pojave napravi pomak, te time unese nova spoznaja o prilikama u distribucijskoj mreži kada dođe do pojave otočnog rada. Te nove spoznaje obuhvaćaju analizu novih parametara kvaliteta električne energije koji su do sada djelomično ili nisu nikako istraživani u sklopu istraživanja detekcije otočnog rada distribuiranih izvora. Ovim istraživanjem također su obuhvaćeni i navedeni parametri, te se daje slika o tome što se događa pri otočnom radu sa frekvencijom, THD_V i THD_I.

Ovo poglavlje je sastavljeno od tri cjeline:

2.1. potpoglavlje je bavi pregledom literature koja daje uvid u razne tehnike otkrivanja otočnog rada u distribucijskoj mreži, gdje su pokrivene sve glavne vrste distribuiranih izvora, to jest obnovljivih izvora energije (OIE).

2.2 potpoglavlje se bavi primjenom metoda umjetne inteligencije koje su korištene u ovom istraživanju, a to su ANFIS, CNN/DU, SVM u području elektroenergetike kao što je otkrivanje kvarova u elektroenergetskoj mreži, procjena stanja nekog pogonskog dijela unutar distribucijske mreže, klasifikacija pojava, te optimizacija pogona distribucijske mreže.

2.3. potpoglavlje se bavi direktnim korištenjem navedenih metoda umjetne inteligencije u cilju otkrivanja otočnog rada distribuiranih izvora električne energije u distribucijskoj mreži, s tim da nije ograničeno samo na fotonaponske elektrane.

2.1 Prepoznavanje otočnog rada distribuiranog izvora unutar distribucijske mreže

Važnost detekcije otočnog rada distribuiranog izvora u distribucijskoj mreži proizlazi iz posljedica koje ovakvo pogonsko stanje može uzrokovati u slučaju neadekvatnog otkrivanja same pojave. Dva su aspekta prema kojima se razmatra otočni rad iz perspektive sigurnosti i kvalitete rada distribucijske mreže: sigurnost osoblja koje radi na elementima distribucijske mreže, te kvalitete električne energije i ispravnosti uređaja i opreme [15]. Za vrijeme pojave otočnog rada, rizik za osoblje mora se minimizirati na bilo koji dostupan način, tako da ne bude posljedica za distribuirani izvor niti distribucijsku mrežu. Kvaliteta energije za vrijeme otočnog rada nije pod kontrolom mreže koja je bila referentni izvor napajanja prije pojave otočnog rada. Samim time je izvan kontrole sustava upravljanja kvalitetom unutar distribucijske mreže. Kvarovi na opremi se mogu pojaviti nakon ponovnog uključivanja dijela distribucijske mreže na izvodu s kojeg se napaja

potrošač od strane distribuiranog izvora. Ovim se uspostavlja novi režim napajanja sa novim parametrima električne energije, te time dovodi u opasnost pravilan rad već postojeće opreme. Također autori navode IEEE 1547 standard po kojem se otočni rad klasificira i mora biti prepoznat od strane distribuiranog izvora u mjestu točke zajedničkog spajanja i prestati raditi u otočnom radu u vremenskom roku od 2 sekunde. Jedna od prevencija otočnog rada distribuiranog izvora jeste pravilo „dva prema jedan“. To znači da se distribucijska mreža realizira na takav način da se u otočnom radu mora desiti da minimalni teret bude dva puta veći od nominalne snage distribuiranog izvora, te time otočni rad nije održiv. Naravno, ovakav način štićenja je jako teško primijeniti u realnim distributivnim mrežama gdje je udio distribuiranih izvora veoma visok te je snaga distribuiranih izvora dovoljno velika da pokriva dosta konzuma ili čak cijeli konzum distributivne mreže. S tim u vezi je potrebno tražiti novo rješenje za prepoznavanje otočnog rada u bilo kojoj situaciji neovisno o iznosu potrošnje.

Autori referata [16] navode još jednu veoma bitnu činjenicu koja nije bila razmatrana u drugim istraživanjima, a to je kolika je zaista vjerojatnost da se dogodi nenamjerni otočni rad u praksi. Razmatrano je da zbog gustoće vjerojatnosti po operetečenjima samog distribuiranog izvora, nenamjerni otočni rad u praksi je toliko mali da ga se ne smatra problemom. Međutim, postoje tri suprotna argumenta:

Prvo, niska vjerojatnost otočnog rada je temeljena na pretpostavci jednakosti snaga distribuiranog izvora i otočnog opterećenje. U stvari, otočni režim rada se može lako oblikovati čak i bez 100% snage podudaranja potrošnje i proizvodnje, podudarnost snage može biti do 30% ako se koriste samo tradicionalne zaštite, npr. nad/pod naponska/frekventna. Stanje od 30% podudaranja proizvodnje i potrošnje moći će jako povećati vjerojatnost otočnog rada, što na kraju opet stvara otočni pogon.

Drugo, čak i uz veću podudarnost proizvodnje i potrošnje, vrijeme potrebno da se napon ili frekvencija dovoljno promijene i uzrokuje veliku promjenu naponskih prilika je duže, a pored toga potrebno je i dodatno vrijeme za preklop u novo stanje (osobito ako se ima konvencionalno rasklopno postrojenje), tada vrijeme može biti veće od tipičnog vremena automatskog pomoćnog uklopa na distribucijskoj mreži.

Treće, argument niske vjerojatnosti temelji se na proučavanju foto naponskih (FN) izvora. Foto naponski distribuirani izvori su uglavnom istosmjerni (DC) i imaju nižu penetraciju istosmjerne mreže u distribucijski sustav. Vjerojatnost da distribuirani izvor dođe do razine generirane snage i da dođe do napajanja izvoda slijedećeg naponskog nivoa, vrlo je mala. Međutim ono što autori

nisu diskutirali jeste da se prebacivanjem sa DC na AC foto naponski sustav se ponaša kao čisto aktivni energetski izvor, te time ima veći prodor u distribucijsku mrežu. Nedostatak reaktivne energije nadopunjuje se priključenom kompenzacijom koja itekako utječe na efektivnu vrijednost napona. Ne izuzimajući današnje trendove distribuiranih izvora u praksi, gdje je činjenica da pod povlaštenim cijenama otkupa električne energije iz distribuiranih izvora, a također i sve nižim cijenama opreme koja se koristi za instalaciju distribuiranog izvora (pogotovo FN sustava), FN distributivni sustavi su sve više zastupljeni u distribucijskoj mreži i sve više preuzimaju ulogu pomoćnog napajanja u cilju smanjenja računa za električnu energiju iz distribucije.

Također autori [16] su se osvrnuli na standard u sklopu IEEE standardizacijskog tijela koji se bavi između ostalog i nenamjernim otočnim radom. Tablica 1 daje pregled sadržaja standarda IEEE 1547 ("Standard za povezivanje distribuiranih izvora na elektroenergetske sustave") koji definira jedinstveni skup zahtjeva za bilo koju vrstu distribuiranog izvora snage manje od 10 MW. Kako se može vidjeti iz priloženih podataka, većina zahtjeva po standardu je već zadovoljena od strane postojećih standardnih zaštita. Može se zaključiti iz postojećih praktičnih iskustava, da je jedno područje ostavljeno za definiranje mehanizma zaštite od ne namjernog otočnog rada distribuiranih izvora, a to je područje otočnog rada. Iako je propisano vrijeme 2 sekunde za otkivanje nenamjernog otočnog rada, ipak metoda nije definirana u tehničkom smislu, niti je navedena praksa kako se to radi na terenu.

Tablica 2.1. Pregled sadržaja IEEE 1547 standarda vezanog za zaštitu distribuiranog izvora i distribucijske mreže [16].

	IEEE 1547 Tehnički zahtjevi	**Funkcija među veza**	**Objašnjenja**
4.1	Općeniti zahtjevi		
4.1.1	Regulacija napona	Dostupno	Uređaj za povezivanje ne smije aktivno regulirati napon.
4.1.2	Integracija s uzemljenjem površine EPS-a	Dostupno	Zaštita za različite priključke transformatora.
4.1.3	Sinkronizacija	N/A	Postojeće funkcije.
4.1.4	Distribuirani resursi na distribucijskim sekundarnim mrežama i mrežama na licu mjesta	Dostupno	Ova se tema razmatra za buduće revizije.
4.1.5	Nenamjerna energija područja EPS-a	Dostupno	Postojeća funkcija: kontrola mrtvog kruga.
4.1.6	Odredbe o praćenju	Dostupno	Može se zadovoljiti trenutnom praksom.
4.1.7	Izolacijski uređaji	Dostupno	Može se zadovoljiti trenutnom praksom.
4.1.8	Povezani integritet		
4.1.8.1	Zaštita od EMI	Dostupno	Može se zadovoljiti trenutnom praksom.
4.1.8.2	Izlazna izdržljivost	Dostupno	Može se zadovoljiti trenutnom praksom.
4.1.8.3	Paralelizacija uređaja	Dostupno	Može se zadovoljiti trenutnom praksom.
4.2	Odgovor na abnormalne uvjete u području EPS-a		
4.2.1	Kvarovi u EPS području	Dostupno	Može se zadovoljiti trenutnom praksom.
4.2.2	Koordinacija povrata EPS-a	**Zaštita od otočnog rada**	Da se distribucijskoj mreži ne zatvara u uređaj za ponovno uključivanje, potrebna je anti-otočna funkcija, osim ako nisu uključena druga skupa sredstva.
4.2.3	Napon	Dostupno	Može se zadovoljiti trenutnom praksom.
4.2.4	Frekvencija	Dostupno	Može se zadovoljiti trenutnom praksom.
4.2.5	Gubitak sinkronizacije	Dostupno	Može se zadovoljiti trenutnom praksom.

4.2.6	Prespajanje na područje EPS	Dostupno	Može se zadovoljiti trenutnom praksom.
4.3	Kvaliteta energije		
4.3.1	Ograničenje DC injektiranja	Dostupno	Može se zadovoljiti trenutnom praksom.
4.3.2	Ograničenje treperenja izazvano od strane distribuiranog izvora	Dostupno	Može se zadovoljiti trenutnom praksom.
4.3.3	Harmonici	Dostupno	Može se zadovoljiti trenutnom praksom.
4.4	Otočni rad		
4.4.1	Nenamjerno ulaženje u otočni rad	**Zaštita od otočnog rada**	Detekcija ispod 2s.
4.4.2	Namjerno ulaženje u otočni rad	N/A	Ova se tema razmatra za buduće revizije.

Značajke otočnog rada definirane ovim standardom predstavljaju polazište za istraživanje utjecaja istih na detekciju nenamjernog otočnog rada u mreži. Autori također navode najpoznatije grupe metoda za otkrivanje otočnog rada kroz njihove prednosti i mane.

U propisanom standardu [17] se kroz tehničke uvjete propisuje vrijeme prepoznavanja otočnog rada u vremenskom intervalu od 2 sekunde. Međutim, u nekim postrojenjima se to prepoznavanje mora obaviti mnogo brže. Razlog tomu jeste koordinacija podešenja zaštita na samom postrojenju, te vremenu zatvaranja prekidača na mrežnim sabirnicama. Naravno, takav sklop automatike je veoma skup, ako se ide na komunikacijsku metodu prenošenja signala od prekidača referentnog energetskog izvora do prekidača distribuiranog izvora. To povlači za sobom obveznu primjenu neke od lokaliziranih metoda prepoznavanja otočnog rada. Sukladno tome, vrijeme detekcije je jedan od ključnih parametara kroz koji se ocjenjuje efektivnost ponuđenih metoda detekcije. Već spomenuta preciznost i zone ne detekcije su druga dva parametra kroz koje se metode ocjenjuju.

Jedna od često korištenih aktivnih metoda detekcije otočnog rada jeste promjena napona i frekvencije uzrokovana pojavom otočnog rada. Autori [18] obrađuju navedenu tehniku kroz promjenu djelatne i jalove energije iz distribuiranog izvora u trenutku pojave otočnog rada. Ideja je bazirana na kutnom pomaku između napona distribuiranog izvora i napona u točki zajedničkog

spajanja. Autori kroz referentnu izračunatu P i Q snagu, usporede sa proizvedenom P_{GEN} i Q_{GEN}, te ako su one iste onda se preko korektivnog faktora σ unese amplitudni pomak na napon i frekvenciju, te time inicira djelovanje konvencionalne zaštite nad naponske i nad frekvencijske. Povezanost ili veza P i Q sa *V* i *f* je predstavljeno preko izraza (1) i (2), [18]:

$$P = \frac{V_{DG}V_{PCC}}{X_f} cos\sigma = kcos\sigma \tag{2-1}$$

$$Q = \frac{V_{DG}V_{PCC}}{X_f} sin\sigma = ksin\sigma \tag{2-2}$$

Predstavljena metoda je testirana po IEEE UL 1741 standardu za kvalitetu mreže, te je pokazala rezultate brzine prepoznavanja otočnog rada od 40 do 80 ms., kada je sučelje prema distribucijskoj mreži sa izmjenjivačem, što podrazumijeva primjenu foto naponskog sustava, ali ne nužno. Ono što predložena metoda podrazumijeva jeste da između mjerenja napona na samom izlazu izmjenjivača i točke zajedničkog vezivanja, postoji RLC strujni krug koji za određeni kutni pomak mijenja strujni i naponski dijagram distribuiranog izvora pri samom spoju sa distribucijskom mrežom. Iako se terenska primjena metode može relativno lako instalirati, postoji mogućnost da u trenutku kada se desi da je impedancija konzuma invertna po iznosu RLC kruga između izlaza sa izmjenjivača i točke zajedničkog spajanja, te time poništava kutnu razliku između dvije navedene točke, pri čemu dolazi do lažne signalizacije prekidaču. Ako su mjerenja reda nekoliko milisekundi, onda s obzirom na brzinu promjene uklopnog stanja na distribucijskoj mreži u vrijednostima instaliranog RLC strujnog kruga, može doći do trenutno pogrešnog signaliziranja prekidaču da odvoji distribuirani izvor od mreže. Također autori navedenog referata ne obrađuju utjecaj predložene metode na kvalitetu električne energije, što je bitno kada je u pitanju aktivna metoda prepoznavanja otočnog rada distribuiranog izvora.

Još jedna predložena metoda [19] je predstavljena od grupe autora, u radu gdje se ispituje preko 5 mogućih scenarija u mreži pri kojima može doći do pojave otočnog rada. Metoda se bazira na promjeni frekvencije, te brzini promjene frekvencije i razlici kuta između napona. U navedenoj metodi se uspoređuju vrijednosti veličina mjerenih na dvije sabirnice, a samim time koriste dvije pasivne metode u kombinaciji sa metodom temeljenoj na komunikacijskim tehnologijama. Iako autori navode testne rezultate koji potvrđuju uspješnost metode prepoznavanja otočnog rada u tri različite situacije opterećenja distribuiranog izvora u odnosu na njegovu nazivnu snagu, te nekoliko situacija promjene uklopnog stanja na mreži, ipak nisu predvidjeli kvarove koji se mogu

dogoditi u mreži, a koji ne rezultiraju otočnim radom promatranog distribuiranog izvora. Ono što se ovim izostavlja jeste brzina promjene frekvencije, te promjena u samoj amplitudi frekvencije koja je toliko zamjetna da će reagirati i metoda detekcije otočnog, te može dati lažni signal prekidaču da odvoji distribuirani izvor od mreže.

Takva pojava nije dopuštena iz razloga što tu ulogu obavljaju releji konvencionalne zaštite, a njihovo djelovanje ne mora rezultirati odvajanjem distribuiranog izvora od distribucijskoj mreži. Ovo istraživanje je diskutirano u ref. [19], poglavlje 6. pod naslovom hr. „Uspješan otočni rad“ (otočni rad koji je namjeran te je nakon toga zadržao parametre mreže impedancija potrošača na mreži, koji su bili i prije njegove pojave). To znači da u toj opciji koja može biti realno stanje i/ili zahtjev određenih korisnika u distribucijskoj mreži, koji trebaju imati neprekidno napajanje električnom energijom. U tu kategoriju spadaju određene javne ustanove kao što su bolnice, određeni laboratorij, određene industrije koje se bave osjetljivim materijalima, rudnici u pogonu itd. Pošto takvi kupci zahtijevaju neprekidno napajanje realna je situacija da se oni ostanu sami napojeni sa distribuiranog izvora bez referentnog izvora napajanja iz mreže. U tom slučaju je potrebno donijeti, te implementirati shemu smanjenja tereta koja bi koristila vremenski sinkronizirane poruke, zajedno sa lokalnim rezervnim generatorima, da bi se prioriteti kao što su bolnice, rudnici itd., napojili električnom energijom. Tipična je praksa u takvim situacijama da se inicira predefinirano smanjenje vrha tereta, praćeno sa već prisutnim otočnim radom. Da bi se optimizirala potrebna energija, najbolje je da se odvoji samo teret koji je nepotreban kako bi se uspostavila i održala stabilnost distribucijske mreže. Sam algoritam koji se primjenjuje računa iznos snage koja treba biti isporučena prema jednadžbi [19](3):

$$P_{SD} = \sum_{n=1}^{k} P_T - \sum_{n=1}^{m} (P_{GMax} - P_G) \tag{2-3}$$

gdje su:

P_T – radna snaga iz promjenjivih veza u trenutku promjene ubrzanja,

k- broj inercijskih veza,

P_{GMax}-P_G – količina snage (MW) rezerve u svakom distribuiranom izvoru u distribucijskoj mreži,

m – broj distribuiranih izvora.

Procesor koji računa P_{SD}, svoj proračun zasnova na prioritetima napajanja i potrebnoj angažiranoj snazi izmjerenoj na napojnim sabirnicama. Za održavanje sigurnosti osoblja koje radi na

infrastrukturi distribucijskoj mreži, moraju se propisati dodatne operativne procedure, i primijeniti, jer bez novih regulativa propisanih od strane distribucije, ovakvo rješenje za prioritetno napajanje ne može se primijeniti.

Autori Jang i Kim [20] uzimaju veoma uspješnu kombinaciju praćenja promjene dva parametra kvalitete električne energije, a to su totalna harmonijska izobličenja struje i promjena napona. Autori su kroz svoje istraživanje razvili testno okruženje za otočni rad prema IEEE 34 standardu za testnu mrežu. Ideja se zasniva na promjeni amplitude napona i promjeni THD_I, uslijed odvajanja referentnog napajanja distribucijske mreže i time daju jedinstven uzorak prema kojem metoda za prepoznavanje otočnog rada detektira nastupanje otočnog pogona. Pošto se topologija mreže mijenja, a također različite kombinacije uklopnog stanja mijenjaju THD_I i utječu na promjenu napona, autori su se odlučili na konstantan nadzor i praćenje ovih veličina kroz mjerenja između kojih je vremenski pomak od ¼ ciklusa signala napona, a to je 4,17 ms. Nakon svakog mjerenja se ponovno upisuje ΔTHD_I i ΔV_U u jednadžbu, zbog čega je metoda preciznija. Izraz [19] (4) definira ključni dio algoritma prema kojem se predložena metoda orijentirana.

$$Pravilo = \left\{\left(\Delta THD_t > 75\%\right) ili \left(\Delta THD_t < -100\%\right)\right\} i \left\{\left(\Delta VU_t > 50\%\right) ili \left(\Delta VU_t < -100\%\right)\right\} \quad (2\text{-}4)$$

Predložena metoda je testirana kroz nekoliko scenarija gdje se mijenja stanje potrošača na distribucijskoj mreži, dodano uključuje novi teret, te isključuje reaktivni teret i na kraju pokreću motori. Međutim, metoda nije testirana sa više distribuiranih izvora na istoj distribucijskoj mreži, te nije u izvještaju o testiranju uključen testni standard UL 1741. Metoda je pokazala veoma brz odziv i uspješno prepoznavanje otočnog rada kroz ograničene uvjete koje su bile na snazi za vrijeme iniciranja otočnog rada. Vrijeme za koje je metoda otkrila otočni rad jeste 53 ms. Bitno je naglasiti da je metoda potpuno pasivnog karaktera, te sukladno tome ne unosi smetnje i ne narušava kvalitetu električne energije u distribucijskoj mreži. Pored toga primjetno je da ima veoma kratko vrijeme djelovanja nakon iniciranja otočnog rada što je za jednu pasivnu metodu jako dobro, međutim uvjetovano je veoma kvalitetnim uzorkovanjem sa veoma malim vremenskim razmakom između dva uzorkovanja. Ovim istraživanjem je jasno prezentirano koliko su uzorkovanje i preciznost mjerenja bitno za sustav detekcije, pa time i za zaštitu od otočnog rada. Ono što je tipično za pasivne metode, jeste veliko područje zone ne detekcije što se vidi iz broja parametara koji se prate, te jednostavnosti mreže koja je bila testno okruženje.

Autori članka [21] se među prvima bave analizom ulaznih signala koji se koriste za prepoznavanje otočnog rada. Iako su signali odabrani za prepoznavanje otočnog rada osnovne veličine kao što su

napon, *V*, struja *I*, frekvencija *f*, radna snaga *P i* jalova snaga *Q*, ipak njihova priprema za analizu mora proći analitičku proceduru prilagođavanja, tako da promjena pri ulasku u otočni rad bude što jasnija. Sukladno toj namjeri, izdvojeno je 5 signala, a to su:

a) normalizirana frekvencija f,
b) brzina promjene frekvencije $\rho_f = df/dt$,
c) normalizirani kut između napona θ,
d) normalizirani napon V,
e) brzina promjene napona $\rho_V = dV/dt$.

Obzirom da su navedeni signali izvedenice osnovnih veličina, također njihovo kombiniranje iziskuje matematsku pripremu koja mora zadovoljiti metodu kojom se nadzire stanje mreže, te zaključivanje o pojavi otočnog rada. Metoda je testirana kroz nekoliko scenarija:

i) Prekidanje glavnog dovodnog voda od referentnog izvora energije
ii) Otvaranje bilo kojeg prekidača između referentnog izvora i elektrane
iii) Događaji koji bi mogli inicirati otvaranje prekidača
iv) Odvajanje tereta sa mreže
v) Promjena uklopnog stanja ubacivanjem kapaciteta na mrežu
vi) Promjena uklopnog stanja izbacivanjem kapaciteta sa mreže
vii) Promjena uklopnog stanja mreže gubitkom dijela tereta
viii) Trofazni kratki spoj na mreži

Rezultati testiranja jasno pokazuju da je metoda jako precizna, do 97,2 % otkrivenih otočnih pogona, te je vrijeme za prepoznavanje od 200 ms. Autori ne navode koliko je vremena trebalo predloženoj metodi da prepozna sam otočni rad distribuiranog izvora, nego se cijelo istraživanje prilagođava standardu IEEE 1547 standarda u kojem je propisano da vrijeme otvaranja prekidača bude manje od 2 sekunde.

Nekoliko metoda je korišteno koje po svojoj prirodi spadaju u aktivne metode, međutim nisu primjenjive na fotonaponske izvore, već samo na one koje imaju sinkrone generatore kao što su hidroelektrane, termoelektrane i sl. Jedna od metoda koja koristi uključivanje kapacitivnih elemenata u mrežu, te na osnovu odziva mreže, tj. kutnog pomaka donosi zaključak o pojavi otočnog rada. Metoda je od autora D. Bejmert i T. S. Sidhu [22] koji su istraživanje radili na sinkronim generatorima, te su posebnu pažnju posvetili zoni ne detekcije, koja je kod ove vrste distribuiranih izvora u otočnom radu posebna tema. Iako su testirani izvori i s izmjenjivačima, ipak

predložena metoda ima prednosti samo kod sinkronih generatora. Praktičnost predložene metode je očigledna s aspekta potrebne opreme, jer se metoda primijenila na mrežu koja je uglavnom RLC tipa, te se dodatni kapacitet lako može uključiti u samu mrežu. Autori su na kraju zaključili da metoda ima nekoliko nedostataka koji će biti tema slijedećih istraživanja, a to su: djelovanje automatskog regulatora napona (ARN) mikroelektroničkih komponenti koje bi mogle biti pogođene prijelaznim pojavama kod uključivanja i/ili isključivanja kapaciteta u distribucijskoj mreži, zatim prolaz kroz niski napon i prolaz kroz kvarove na mreži koje je tema naprednih metoda upravljanja FN sustava. Predložena metoda bi morala biti sinkronizirana sa tim sustavom upravljanja, i imuna na utjecaj statičkih kompenzacijskih baterija i statičkih kompenzacijskih generatora (STATCOM-a).

Autori referata [23] S. A. Saleh, A. S. Aljankawey, Ryan Meng, J. Meng, L. Chang, C. P. Diduch koriste pasivnu metodu provjere razlike kutnog pomaka između prividne snage, između dvije točke na istoj apsici. Virtualna apscisa je linija spajanja distribuiranog izvora i distribucijske mreže, što govori da prolazi kroz točku zajedničkog spajanja. Autori se oslanjaju na visokofrekventnu promjenu prisutnu na *d-q* osi trofaznog sustava. U samoj ideji nema razlike od prepoznavanja otočnog rada pomoću visokofrekventne promjene udjela reaktivne snage u proizvedenoj ukupnoj prividnoj snazi distribuiranog izvora, međutim novina koju autori predstavljaju jeste valna transformacija (WPT) promjene intervala. U ovom slučaju je interval na liniji spajanja distribuiranog izvora i distribucijske mreže, a veličina jeste brzina promjene prividne snage. Izlaz iz navedene metode jeste signal koji govori da li to trenutno jeste otočni rad ili nije. Sama analiza signala prema kojoj se WPT odvija je zasnovana na Daubechies valovima, gdje se glavni signal pretvara u vidljivu valovitu krivulju koja jednoznačno određuje promjenu u signalu. Metoda je primijenjena u slijedećem izrazu za prividnu snagu u točki koja je bliža distribuiranom izvoru i onoj koja je dalja od distribuiranog izvora:

$$S_{dq}[n] = \sum_{k=0}^{K-1} M[k]\,h[n-k], \qquad k,n,K \;\in\; Z \tag{2-5}$$

$$M[n] = \left(S_d[n]\right)^2 + \left(S_q[n]\right)^2 \tag{2-6}$$

Na kraju se provjerava samo izlaz od $S_{dq}[n]$ je li on jednak 0 ili nije. Ako jeste onda nije otočni rad, ako jeste jednako bilo čemu drugome, onda nastaje otočni rad.

U navedenim izrazima je:

$S_{dq}[n]$ vektor prema WPM koeficijentima urađenima prema Daubechies valovnim transformacijama,

$S_d[n]$ i $S_q[n]$ su promjene prividne snage u određenom uzorku.

Međutim, autori su testirali metodu u laboratorijskim uvjetima na 3,6 kVA generatoru sa nekoliko testnih scenarija koji uključuju: ubacivanje dodatnog tereta, izbacivanje tereta, kvarove na mreži itd.

U istraživanju [24] provedenom od strane autora Daniel Motter, Fabricio A. Mourinho i José Carlos M. Vieira, prezentirano je kako različita uklopna stanja gdje je prisutno više od jednog tereta, utječe na prepoznavanje otočnog rada, metodom baziranoj na analizi frekvencije, ali samo u slučaju distribuiranog izvora sa sinkronim generatorima. Interesantan rezultat je dobiven u relaciji krivulje ponašanja sa najkonzervativnijim slučajem, a to je F= ∞, gdje je F odnos između raznih opterećenja na mreži. Rezultat pokazuje da u kompleksnijim sustavima sa više od dva tereta, rezultat se može dobiti raspoređujući teret po sabirnicama koje su fizičkom lokacijom bliže distribuiranom izvoru. Također je naglašeno da je navedena analiza urađena uzimajući u razmatranje jednostavan primjer sa distribuiranim izvora koji kontrolira aktivnu snagu i napon, dva tereta, te se jedino višak snage plasira u mrežu. Sa aspekta zaštita, ovdje se vrijeme prepoznavanja otočnog rada smanjuje kako F teži u ∞. Time se jasno daje do znanja da ako su tereti bliže distribucijskom izvoru, a time i kada je samo jedan distribuirani izvor na mreži, onda prepoznavanje otočnog rada daje bolje rezultate kod sinkronih generatora kao distribuiranih izvora.

Članak [25] predstavlja analizu prepoznavanja otočnog rada metodom opadanja krivulje Q-f karakteristike u slučaju kada otočni krug sadrži distribuirani izvor sastavljen od izmjenjivača zajedno sa distribuiranim izvorom koji ima sinkroni generator. Prema istraživanju autora ovog članka, preciznost metoda prepoznavanja otočnog rada znatno opada kada se sinkroni generator kao distribuirani izvor nalazi u distribucijskoj mreži. Ovo se događa isključivo sa metodom pada Q-f karakteristike gdje se prati utjecaj reaktivne snage na trend frekvencije u slučaju prelaska u otočni rad. Frekvencija se ne može direktno mijenjati injektiranjem reaktivne snage u mrežu, jer je prisutan sinkroni generator, a on je sam po sebi izvor reaktivne snage. Ipak, dodavanje reaktivne snage u distribucijskoj mreži još uvijek utječe na frekvenciju, a samim time i trend Q-f pada, koji može poslužiti kao metoda za prepoznavanje otočnog rada. Istraživanje je pokazalo da je prethodna tvrdnja točna. Međutim, reaktivna snaga još uvijek utječe na vrijeme Q-f pada što mijenja amplitudu napona, a samim time i aktivnu energiju, pa se ta korelacija može iskoristiti

paralelno sa Q-f metodom pri prepoznavanju otočnog rada. Međutim, autori nisu testirali navedenu metodu ni pod jednim standardom, te nisu testirali samu tvrdnju da reaktivna snaga u navedenom slučaju utječe na napon, te to testirali u svrhu prepoznavanja otočnog rada.

Priroda zaštite od otočnog rada po svojim karakteristikama spada u kategoriju naglih promjena u parametrima napona i struja, te kombinacijom ove dvije veličine. Isti princip rada imaju standardne zaštite kao što su prenaponska, prekostrujna, kratkospojna itd. Autori članka [26] iskorištavaju upravo mogućnost raspoređivanja distribuiranog izvora sa sinkronim generatorom u mreži po parametrima smanjenja gubitaka, te što efikasnijem djelovanju relejnih zaštita uključujući u njih zaštitu od otočnog rada. Predložena metodologija uzima navedene parametre optimizacije raspoređivanja distribuiranog izvora, po slijedećim kategorijama:

1) gubici aktivne energije,
2) gubici aktivne i reaktivne energije u trenucima maksimalne snage,
3) promjene napona,
4) ulaganje u infrastrukturu mreže,
5) brzina prorade prekostrujne zaštite,
6) brzina prorade zaštite od otočnog rada.

Navedena ograničenja kojih se metoda mora držati su:

a) snaga sabirnica,
b) maksimalni limit udjela distribuiranog izvora zbog zaštite od otočnog rada,
c) naponski limit,
d) sačuvati koordinaciju prekostrujne zaštite,
e) diskretna veličina snage distribuiranih izvora.

Predloženi metoda je testiran na IEEE 14-sabirničkom modelu u kojem su modelirane različite veličine koeficijenta kvalitete mreže, te otočnog rada.

Naime, zaštita od otočnog rada koja je korištena u ovom slučaju je zasnovana na brzini promjene frekvencije (ROCOF metodi). Kroz devet veličina i tri scenarija u kojima se testira model, pokazali su da ROCOF relej za otkrivanje otočnog rada prepoznaje otočni rada ispod 0,5 sekundi, te se povećava kako je distribuirani izvor dalji od referentnog izvora napajanja. S tim na umu se može reći da udio distribuiranih izvora može biti usko vezan za brzinu prepoznavanja otočnog rada, s tim da se mora voditi računa o topologiji mreže, ako se želi eventualno smanjiti brzina otočne zaštite. Naravno, ovo se odnosi na ROCOF koji spada u pasivne metode. Kroz ovo istraživanje se

proteže ideja da zaštita od otočnog rada treba biti usko vezana za druge vrste zaštita u distribucijskoj mreži, koja teži da postane pametna mreža. Sukladno tome je priložena ekonomsko-tehnička analiza rasporeda distribuiranih izvora unutar distribucijske mreži. Sa aspekta zaštite od otočnog rada, ovdje je bitno primijetiti da relacija zaštite od otočnog rada sa drugim zaštitama mreže, postoji i to u uskoj relaciji. Zaštita od otočnog rada, ne misleći samo na prepoznavanje otočnog rada, može biti oslonjena na jednu od klasičnih zaštita, s tim da se parametar na koji aktivno djeluje bude pasivno promatran od jedne od navedenih zaštita. Sukladno tome, metoda koja bi se kombinirala s klasičnim zaštitama treba biti aktivna, ali ne narušavajući kvalitetu električne energije ispod određene mjere da ne bi došlo do lažnog isključivanja distribuiranog izvora sa mreže. U članku [27] se upravo bave autori O. Raipala, A. Makinen, S. Repo i P. Jarventausta, gdje koriste navedenu ROCOF metodu prepoznavanja otočnog rada preko injektiranja reaktivne energije promatrajući brzinu promjene frekvencije, a djelujući na promjenu frekvencije na klasičnim zaštitama. Pošto autori navode da nema kontinuirane prekomjerne frekvencije, tako da nema utjecaja na kvalitetu električne energije, ipak djelovanje na napon mora biti dovoljno kratko da ne bi djelovala pod/nad naponska zaštita, te dala lažni signal za isključenje distribuiranog izvora sa mreže. Simulacijski model je rađen prema IEEE 1547 standardu, međutim nije testirana metoda kada ima više od jednog distribuiranog izvora na mreži. Pod normalnim pogonskim uvjetima predložena metoda daje signal da je otočni rad prepoznat za 200 ms, što je veoma povoljno vodeći se standardom IEEE 1547.

Ranije metode za prepoznavanje otočnog rada distribuiranog izvora su uglavnom bile zasnovane na brzini promjene frekvencije i/ili na promjeni vektorskog kuta aktivne i reaktivne snage između distribucijske mreže i sinkronih generatora. Kasnija istraživanja su pokazala da su ove dvije metode, koje su inače bili fizički odvojene pri primjeni na terenu, u suštini iste po svojim osobinama za otkrivanja otočnog rada. Jedina razlika jeste u brzini otkrivanja otočnog rada, gdje je relej frekventne zaštite brži, u zavisnosti od visine reaktivne energije iz distribuiranog izvora koju daje sinkroni generator. Takvo istraživanje su proveli autori članaka [28], [29] i [30]. Ovakva istraživanja su uglavnom rađena na samo jednoj vrsti distribuiranog izvora i to onoj sa sinkronim generatorima. Međutim osobine navedenih releja postaju lošije kada je u pitanju distribuirani izvor sa izmjenjivačem. Veoma brza elektronika unutar izmjenjivača su toliko efikasna u peglanju vala napona da relej zaštite od nesimetrije zvjezdišta ne može zabilježiti promjenu uklopnog stanja između sinkronog rada distribuiranog izvora sa distribucijskoj mreži i njegovog otočnog rada. U cilju pokrivanja zone ne detekcije za sustave s izmjenjivačima, brzina promjene frekvencije je promijenjena sa pasivne u aktivnu metodu u vidu injektiranja frekventnih poremećaja u

distribucijsku mrežu, vodeći računa o parametrima kvalitete električne energije. Metode zaštite bazirane na aktivnoj metodi brzine promjene frekvencije imaju nekoliko izvedbi koje su istražene prema svojoj efikasnosti. Istraživanje od autora Bohan Liu, David Thomas, Ke Jia i Malcolm Woolfson u ref. [31], te od autora CF. Ten, PA Crossley u ref. [32] gdje se ocjenjuju releji koji imaju ugrađenu metodu ROCOF za otkrivanje otočnog rada distribuiranog izvora. Navedena istraživanja su prikazala sveobuhvatnu analizu ROCOF releja, gdje je na detaljan način prikazano povećanje vremena otkrivanja otočnog rada sa smanjenjem nesimetrije snage po fazama. Algoritmi koji su mjerili frekvenciju, različiti mjerni uzorci, su značajke koje jako utječu na osobine navedenih releja. Naravno, što je manji vremenski razmak uzoraka, to je vrijeme prepoznavanja otočnog rada kraće, ali je također relej osjetljiviji, a time se dovodi i do smanjenja preciznosti same ROCOF metode. Suprotno ovome, kako se vrijeme između uzoraka povećava, tako je vrijeme otkrivanja duže, ali povećava preciznosti metode. Ovo navodi na zaključak da je ključ efikasne ROCOF metode u optimalnim podešenjima samog releja, što stavlja u nezgodan položaj inženjera koji ugrađuje relej, jer mora pronaći optimalne postavke za konkretnu situaciju, što iziskuje dodatne troškove terenskog rada i specifičnog znanja. Tijekom sinkronog rada distribuiranog izvora, kako predlažu navedeni autori radova, ROCOF relej ne bi trebao biti aktivan kako bi se smanjio utjecaj na kvalitetu električne energije. Samo u slučaju nestabilnog rada distribuiranog izvora u točki zajedničkog spajanja otvara se unutarnji prekidač koji stavlja ROCOF u stanje pripravnosti testirajući frekvenciju i time zaključujući stanje rada distribuiranog izvora. Bez obzira da li u distribucijskoj mreži ima još distribuiranih izvora sa sinkronim generatorima ili sinkronim motorima, karakteristike ostaju gotovo iste, jer se ravnoteža potrošnje energije prije uključivanja ROCOF releja odradi tako što prioritet ima distribuirani izvor nad referentnim izvorom napajanja.

Optimalne instalacijske postavke su obrađene u radu [33] autora A. Adrianti i A. Dyśko, gdje su se autori fokusirali na održanje preciznosti i pravovremenog otkrivanja otočnog rada pri sve većem nivou promjene frekvencije pri prijenosu el. energije. Podešavanje se zasniva na predviđenim mogućnostima na određenom geografskom području, koje prema svojim klimatskim uvjetima diktira injektiranje distribuirane energije u mrežu, te se time na godišnjoj bazi rade podešenja ROCOF releja. Korištenjem Bayesian mreže za proračun vjerojatnosti neželjenih prorada ROCOF releja je predložena kao podloga predviđanju stanja mreže, te je na osnovu dobivenih rezultata napravljen plan podešenja prema maksimalnom pragu dozvoljenog rizika od pogrešnog djelovanja releja. Simulacijski model korišten za testiranje predložene metode je urađen prema IEEE test mreži s 5 sabirnica. Rizik od pogrešnog djelovanja od otočnog rada je zadržan ispod 0,1 %, što je

veoma povoljno gledano sa aspekta učestalosti otočnog rada. Ono što je povoljno za predloženo istraživanje jeste kompleksnost mreže na kojoj se radila analiza, a to je prijenosna mreža sa snagom potražnje od 20 GW do 55 GW konzuma, što na godišnjem nivou predstavlja realnu situaciju bez ulaska u detaljnu analizu. Sukladno navedenim podacima, optimalno podešenje ROCOF releja se može promatrati na godišnjem nivou s navedenim dozvoljenim rizikom od pogrešnog djelovanja zaštite. Vrijeme koje je postignuto jeste 500 ms, te se zadržalo na tom vremenu mijenjajući samo postavke na koje će ROCOF relej djelovati sukladno promjeni uklopnog stanja u prijenosnoj mreži. Optimalne postavke releja su odabrane na iznos 0,5 Hz/s.

Radovi koji se bave komunikacijskim metodama za prepoznavanje otočnog rada distribuiranog izvora kao što je [34], ne dotiču ili vrlo malo obrađuju dva veoma važna problema navedenih metoda: pouzdanost i sigurnost metode. Navedena rješenja su uglavnom starijeg datuma, te su navedeni problemi razmatrani u radovima koji su uveli agente (inteligentne uređaje zasnovane na umjetnoj inteligenciji) kao posrednike ili kao aktere djelovanja zaštita. Autori istraživanja [35][36] [37] su koristeći metodu zasnovanu na komunikacijskom pristupu rješavanju problema otočnog rada, predložili metodu daljinskog slanja signala do agenta koji kontrolira prekidače u postrojenju distribuiranog izvora.

Metoda je bazirana na agentu koji ima zadaću posredovanja između događaja na distribucijskoj mreži i samog distribuiranog izvora. Predložena shema donosi mogućnost da relej zaštite šalje signale prema distribuiranom izvoru, zbog koordinacije njegovog statusa u mreži koristeći više agentni sustav. distribuirani izvor se smatra da radi u otočnom radu, ako signal sa prekidača daje obavijest da je prekidač otvoren. Nekoliko vrsta agenata je dostupno koji mogu preuzeti navedenu funkciju, a autori su testirali na modeliranom sustavu od 4 distribuirana izvora na istoj distribucijskoj mreži. Simulacija je obuhvaćala dva testna scenarija za procjenu ponašanja modela. Testni scenariji su obuhvaćali nekoliko kvarova na mreži rezultirajući da se neki distribuirani izvor isključi s mreže, kvar na potrošaču, kvar na distribucijskoj mreži, te pri promjeni uklopnog stanja mreže. Dva vrlo bitna čimbenika se javljaju kao dio zaključka ovog istraživanja:

1) pouzdanost komunikacije agenata,
2) sinkronizacija distribuiranog izvora s distribucijskom mrežom.

Prvi čimbenik je problem koju ovakva vrsta otkrivanja otočnog rada ima, a to je pouzdanost komunikacijske mreže na kojoj cijela mreža leži. Pod pouzdanošću se misli dostupnost i sigurnost komunikacijskih kanala. Iako je sigurnost uglavnom tema otvorenih sustava komuniciranja, ipak u zadnje vrijeme to je postala tema svih sustava baziranih na klasičnim metodama komunikacije,

gdje svatko može namjerno ili nenamjerno poslati signal prekidaču inicirajući neželjeni efekt. Ono što autori predlažu jesu serveri kojima će agenti pristupati i provjeravati dostupne informacije, te time praviti dodatni filter povećavajući razinu sigurnosti. Naravno, u praksi serveri mogu biti veoma različiti po svojoj strukturi, te posjedovati različite sigurnosne certifikate unoseći potrebu za standardizacijom, i protokolima što nije tema istraživanja autora. Međutim prvi dio, dostupnost, ipak čvrsto ostaje bez obzira na prije navedene karakteristike servera i agenata, a ona podrazumijeva: inertnost mreže, gubitak signala, što povećava vrijeme otkrivanja otočnog rada.

Drugi čimbenik se usko veže za ponovno uključivanje distribuiranog izvora u mrežu nakon primitka signala da je referentni izvor napajanja ponovno prisutan na mreži. Istovremeno signal je primljen od svih agenata na svim distribuiranim izvorima, a to može dovesti do probleme pri sinkronizacijskih u distribucijskoj mreži. U realnoj mreži referentni izvor napajanja se smatra da ima gotovo neograničenu snagu, te distribuirani izvori sa manjim snagama koji su u praksi prisutni uglavnom ne utječu toliko negativno na uspješnu sinkronizaciju distribucijskoj mreži.

Ono što autori navode kao prednost u odnosu na konvencionalne komunikacijske metode , jeste da nije potrebna posebna dodatna oprema i kabeli, što donosi fleksibilan i dinamičan pristup zaštiti distribucijskoj mreži-e. Još bitno za navesti jeste da agenti koji se upošljavaju na sakupljaju i obradi podataka su razvijani prema generičkoj strukturi, to jeste da se mogu integrirati u različitim komponentama hardvera, od prekidača, rastavljača pa sve do različitih releja zaštite korištenih kod distribuiranog izvora. Osim toga, predloženo posredovanje agenata pojednostavljuje interakciju između agenta bez obzira na njihovu arhitekturu, a time je glavni komunikacijski kanal generalno rasterećen. Rezultati simulacije pri čemu su testirani kvarovi na mreži i promjena topologije mreže kroz dva scenarija, pokazali su da je predloženo rješenje fleksibilno i skalabilno. Ono što autori nisu uzeli kao referencu jeste standard koji obrađuje zaštitu od neželjenog otočnog rada, IEEE 1547 te testni standard UL 1741 za testiranje u različitim kvalitetama distribucijskoj mreži-a.

Autori Xiao Li i Robert S. Balog u radu [38] su obradili dvije aktivne metode prepoznavanja otočnog rada sa aspekta usporedbe osobina u različitim uvjetima rada distribucijske mreže. Dvije metode koje su uspoređene su pomak frekvencije aktivne energije (AFD) i promjena reaktivne snage (RPV), koji su testirani pod različitim ekstremnim okolnostima u distribucijskoj mreži-i: različite smetnje u distribucijskoj mreži-i (THD_V), različite frekvencije, P_{st} (kratki flikeri)), različita uklopna stanja tereta, različita kvaliteta mreže Q_f.

Nakon završetka testiranja, prema rezultatima koji su prezentirani, obje metode imaju svoje zone ne detekcije aktivno vezane uz promjenu glavne frekvencije i to tako da AFD metoda smanjuje

svoju zone ne detekcije, ako se brzina promjene glavne frekvencije povećava, dok za RPV metodu zone ne detekcije se može gotovo neutralizirati povećavajući brzinu promjene reaktivne snage. Ukupno, RPV je relativno bolja od AFD, ako je u pitanju distribuirani izvor koji ima proizvodnju, odnosno potrošnju reaktivne snage, pa se može dinamično regulirati tijekom rada distribuiranog izvora. Pošto je zadano fiksno vrijeme prepoznavanja otočnog rada zbog različitih smetnji koje su pretpostavljane tijekom testiranja, najduže vrijeme zabilježeno za prepoznavanje je 1,6 sekundi što je prihvatljivo prema IEEE 1547 standardu. Međutim generalno gledajući po rezultatima u svim slučajevima, RPV ima malo veće vrijeme prepoznavanja od AFD metode.

Utjecaj na kvalitetu napona svojim djelovanjem zbog same prirode metode je takav da: RPV ima manji negativan utjecaj na kvalitetu napona na mreži od AFD metode. Razlog tomu je utjecaj AFD metode na aktivnu komponentu snage koju konzumiraju potrošači, za razliku od RPV metode gdje je reaktivna snaga sama nosilac signala.

Pouzdanost metoda je provjeravana kroz tri vrste smetnji na mreži koje su primijenjene kao odvojeni slučajevi: THD_V, promjenu frekvencije (f) i P_{st} (kratkotrajni flikeri). THD_V je razmatran prema standardu IEEE 519, gdje mrežni napon ima slijedeće udjele naponskih harmonika:

1 harmonika 100%, 3 harmonika 2%, 5 harmonika 2% i 7 harmonika 4%.

Rezultati testiranja su pokazali da je metoda RPV dosta pouzdanija od AFD metode po gotovo svim scenarijima testiranja. AFD metoda ima problema kada se frekvencija smanji ispod nominalne pod Q_f=2,5 i pod pogonskim uvjetom da se P_{st} smanjuje u trenutku kada je Q_f=2,5.

U istraživanju koje su proveli autori Yiding Jin, Qiang Song i Wenhua Liu [39], predstavljen je izmjenjivač kod FN sustava koja radi u zatvorenom krugu kontrole izlazne snage u odnosu na distribucijsku mrežu, koja negativno utječe na detekciju otočnog rada zasnovanoj na faznom pomaku, kao što su aktivni frekvencijski pomak (AFD), klizni frekvencijski pomak (SMS) itd. Na temelju toga, autori su ponudili svoje rješenje detekcije otočnog rada, koji nadzire frekvenciju kao povratni signal od podešene reaktivne snage distribuiranog izvora (izmjenjivača). Ova aktivna metoda može imati brzi frekvencijski pomak u otočnom radu, te na osnovu toga djelovati na odvajanje distribuiranog izvora od mreže. Osobina koja predstavlja prepreku otkrivanju otočnog rada i znatno povećava zone ne detekcije i smanjuje preciznost metode, je da aktivne metode otkrivanja otočnog rada bazirane na frekvencijskom pomaku se vezuju uz promjenu aktivne i reaktivne snage iz distribuiranog izvora, prikazano na (22).

$$\Delta P = \frac{\cos\left(\delta - \theta_Z^{`}\right) - \cos\delta}{\cos\delta} P_{ref} \tag{2-7}$$

$$\Delta Q = \frac{\sin\left(\delta - \theta_Z^{`}\right) - \sin\delta}{\sin\delta} Q_{ref} \tag{2-8}$$

gdje su P_{ref} i Q_{ref} referentne vrijednosti izlaza aktivne i reaktivne snage. U nekim situacijama, aktivna snaga izmjenjivača treba se regulirati u zatvorenom krugu upravljanja sa povratnom spregom da bi se održao istosmjerni napon konstantnim na DC strani izmjenjivača. Kako se prema (22) može vidjeti, ΔP je veličina koja je odgovorna za tu regulaciju svojim iznosom. Kontrola P_G-a i δ nisu vezana zajedno, pa kompenzacija ΔP u stvari reducira fazni pomak $\theta`_Z$, što dovodi do povećanja zone ne detekcije u metodi otkrivanja otočnog rada. Predložena metoda autora se bazira na promjeni izlazne frekvencije reaktivne snage prema (23).

$$Q_{d/t} = K_f \left(f_0 - f \right) \tag{2-9}$$

gdje je $Q_{d/t}$ promjena reaktivne snage, f_0 je referentna frekvencija sustava, a f je injektirana frekvencija u mrežu i K_f je amplituda promjene reaktivne snage zbog promjene frekvencije. Iz navedene formule se može primijetiti da kada je distribuirani izvori u sinkronizmu s distribucijskom mrežom, onda je promjena frekvencije reaktivne snage minimalna. Međutim kada distribuirani izvor radi u otočnom radu, promjena frekvencije je jednaka injektiranoj f_0, što dovodi do ovisnosti frekvencije otočnog rada o izlaznoj frekvenciji distribuiranog izvora i tereta na mreži. Zbog same tehnike navedene metode moguće ju je primijeniti jedino na sustavima koji isporučuju isključivo aktivne energije a to su FN sustavi.

Autori rada [40] također koriste isti pristup za otkrivanje otočnog rada, kao i autori u istraživanju [39], kod distribuiranog izvora sa izmjenjivačima, ali posvećujući veću pažnju na zonu ne detekcije kod preporučene metode. Područje koje navedena metode nije u mogućnosti pokriti jeste situacija kada je promjena aktivne i reaktivne snage jako mala, te se promjena primijenjena na $Q_{d/t}$ ne vidi dovoljno jako na parametru frekvencije. Odgovor na ovo su autori navedenog rada riješili uvođenjem dodatnog parametra B(k) koji mijenja amplitudu promjene reaktivne snage navedene u (24).

$$Q_{inv}\left(k\right) = A\left(k\right)^{B(k)} Q_{load}\left(k-1\right) \tag{2-10}$$

$$B\left(k\right) = \begin{cases} 1, & \omega_{max} > \omega\left(k-1\right) > \omega_{min} \\ -1, & \omega_{max} < \omega\left(k-1\right) ili\, \omega\left(k-1\right) < \omega_{min} \end{cases}$$

Rezultati su pokazali da preporučena metoda smanjuje zone ne detekcije, međutim ne eliminira je potpuno.

Nekoliko istraživanja se još posvetilo promjeni faznog pomaka napona, tj. pomicanje frekvencije od referentne, u svrhu otkrivanja otočnog rada za izmjenjivače, a to su [41] [42]. Pored toga što [41] nudi metodu promjene faznog pomaka napona, s tim da dodaje ubrzanje promjeni, te na taj način bilježi promjenu frekvencije, ref. [42] nudi metodu gdje se preko moduliranja prati signal harmoničnog izobličenja napona (THD_V) izmjenjivača. Izmjenjivač koji radi u premoduliranom operacijskom modu proizvodi THD_V i to 3-ći, 5-ti i 7-mi, koji se injektira u distribucijsku mrežu. Modulacijski indeks m_i izmjenjivača se mijenja periodično prema izrazu (25) u namjeri da injektira harmonike u distribucijskoj mreži.

$$m_i = \begin{cases} m_{op}\ 0 \le t \le 9T \\ m_{over}\ 9T \le t \le 10T \end{cases} \tag{2-11}$$

gdje je

- m_{op} operativni modulacijski indeks izmjenjivača tijekom normalnog radnog režima (sinkronog sa distribucijskom mrežom)
- m_{over} je modulacijski indeks u premodulacijskom regionu,
-T je vremenski period mrežnog napona.

Ono što autori napominju jeste da modulacijski indeks unosi nivo harmonika u distribucijsku mrežu, te time daje mogućnost kontrole nad harmonijskim poremećajima u kvaliteti električne energije i time može zadovoljiti traženi standard kvalitete. Kako se modulacijski indeks periodično uključuje u regionu između 9-og i 10-og perioda mrežnog napona, tako injektira THD u distribucijskoj mreži. Kada distribuirani izvor radi u sinkronizmu s distribucijskom mrežom, THD koji se javlja kao rezultat djelovanja premodulacijskog perioda je minimalan, te nema problema u kvaliteti napona. Međutim, kada je distribuirani izvor u otočnom radu, premodulacijsko djelovanje izmjenjivača će se detektirati povećanjem THD_V. Pošto se može uštedjeti na uzorkovanju pojedinih harmonika, onda se promatraju samo dva reda harmonika i to 5-ti i 7-mi. Testni rezultati pokazuju da metoda ima prednosti nad ostalim aktivnim i pasivnim metodama, a dodatna prednost jeste da se praćenje harmoničnog izobličenja napona može aktivirati samo u periodima kada se premodulacija uključi. Međutim, autori ne navode situacije kada je u distribucijskoj mreži već prisutno veće djelovanje naponskih harmonika, te je time preciznost metode narušena. Naravno, javlja se i situacija na mjestu kada je THD_V dovoljno veliki da ne prelazi graničnu vrijednost

propisanu standardom IEC 50160, ali kada se premodulacija uključi onda se granična vrijednost prijeđe, te time daje ponovno lažni signal da je u otočnom radu. Zona ne detekcije je također moguća, ako na mreži postoji prigušenje viših harmonika kao npr. konstantno uključene kondenzatorske baterije koje peglaju napon, te time neutraliziraju djelovanje premodulacije.

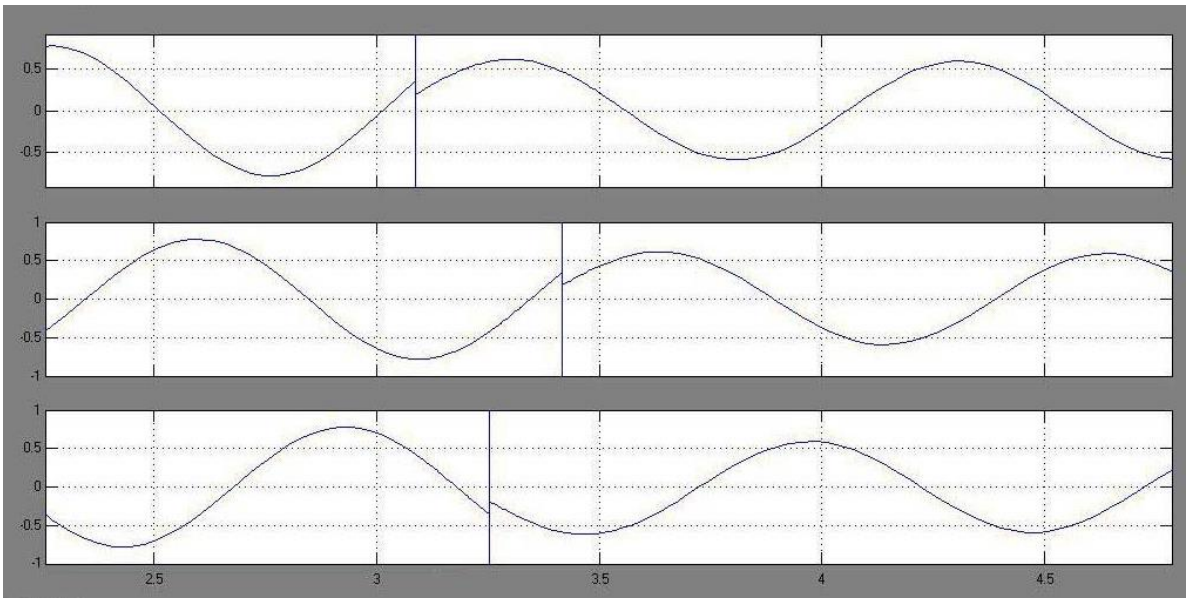
Posebna pažnja kod otkrivanja otočnog rada se daje distribuiranim izvorima sa sinkronim generatorima. Kako se može primijetiti u dosadašnjim analizama literature, uglavnom su metode zasnovane na praćenju ponašanja reaktivne snage, gdje se uz pomoć neke metode prepoznaje otočni rad. Jedna od takvih metoda je rad autora M. Bakhshi, Reza Noroozian i G.B. Gharehpertian [43], gdje su autori iskoristili reaktivnu snagu kod sinkronog generatora na način da prate promjenu napona u odnosu na napon. U stvari, predložena metoda praćenjem napona i reaktivne snage distribuiranog izvora računa indeks otkrivanja, te na osnovu njega utvrđuje stanje o otočnom radu distribuiranog izvora. Da bi se navedena metoda primijenila u elektroničkim uređajima koji se koriste na terenu, navedeni praćeni signali moraju biti prevedeni na diskretni tip. Za prebacivanje u diskretni tip, koristi se filter nultog reda. Nakon diskretizacijskog postupka i računanja indeksa otkrivanja, predložena metoda je implementirana i testirana pri različitim uvjetima otočnog i rada u sinkronizmu na dva odvojena sustava. Rezultati simulacija prikazuju efektivnost predložene metode, čak i kroz nulti postotak razlike reaktivne snage prije i za vrijeme otočnog rada, gdje ROCOV zaštitni relej za detekciju otočnog rada ne može otkriti ovu situaciju. Time predložena metoda ima manju zonu ne detekcije od ROCOV-a releja.

Pored reaktivne snage, mnogi autori koriste analitičke metode da bi se kroz transformaciju signala uspjela dobiti jasna situacija o stanju distribuiranog izvora unutar mreže. Istraživanje [44] pokazuje procjenu ne otkrivanja otočnog rada sinkronog generatora s pasivnim anti-otočnim uređajem, koje je bazirano na proračunu numeričkog indeksa koji daje nivo zaštite. Numerički indeks može se jasno izračunat koristeći jednostavne formule i/ili tablični prikaz parametara mreže. Jednostavni slučajevi mreže otkrivaju da nije praktično donijeti konačnu odluku o indeksu nivoa ne otkrivanja otočnog rada. Primjer tome jeste slučaj da se aktivna snaga generatora može mijenjati tako da ili povećava ili smanjuje spomenuti indeks, te je pri tome ovaj pristup veoma manjkav, ako u mreži ima potrošač aktivne energije sa veoma brzim uklopom i isklopom sa mreže. Vodeći se time, autori D. Salles, W. Freitas, J. C. M. Vieira i W. Xu su predložili formulu izračuna u kombinaciji sa tablicom parametara, tako da je metoda mnogo efikasnija u usporedbi s drugim metodama koji koriste EMT simulacije. Preporučena metoda je ocijenjena kroz testiranje osjetljivosti koji je pokazao slijedeće karakteristike metode:

- Povećavajući vrijeme otkrivanja sa 500 ms na 1500 ms, klasični frekventni releji mogu biti veoma efikasni u smanjenju indeksa ne detekcije. Kada se vrijeme otkrivanja povećava sa 1000 ms na više vrijednosti, ROCOF releji ne donose dodatnu prednost u odnosu na standardne frekventne releje sa gledišta indeksa ne detekcije.
- Distribuirani izvor sa manjom snagom će rezultirati manjim indeksom ne detekcije.
- Vrijeme zatezanja kod frekventnih releja može povećati indeks ne detekcije.

Pored navedenih karakteristika treba napomenuti da predložena metoda navedenih autora treba određeni vremenski period kako bi se utvrdili uzorci za proračun varijabli (stohastički), a taj period bi u nekim slučajevima mogao biti od 24 sata do godine dana.

Istraživanje autora A. Helmzadeh, J. Sadeh i O. A. Musavi u ref. [45] prikazuje jedan novi pristup otkrivanju otočnog rada sinkronih generatora, prateći negativnu komponentu napona pri pojavi otočnog rada. Zapažanje koje autori iskorištavaju pri detekciji otočnog rada od sinkronog jeste da pojava negativne komponente napona u sinkronim generatorima, može biti analizirana uzimajući u obzir profil napona faza tijekom prelaska u otočni rad. Promjena napona se dešava gotovo trenutno kada se pojavi otočni rad, ali za svaku fazu u drugačije vrijeme. Na slici 1. predstavljena je navedena pojava koju autori navode.



Slika 2.1. Anomalija koju autori ref.[41] iskorištavaju pri otkrivanju otočnog rada.

Negativna komponenta napona ima pozitivnu vrijednost tijekom pojave otočnog rada. Predloženim metodom se poredi negativna komponenta napona sa već određenim vrijednostima. Međutim, ako je negativna komponenta napona razmatrana sama, problemi vezani za naponske

releje uključujući utjecaj kondenzatora i paralelnih kapaciteta faznih vodiča na dalekovodima, mogu igrati važnu ulogu. Prijedlog autora za popravkom navedenog algoritma je da se koristi prigušeni uzorak negativne komponente napona kada se dogodi otočni rad. Ova vrijednost negativne komponente napona lagano opada kada je otočni rad. Koristeći tu vrijednost i navedeni uzorak, može se postići kvalitetan kriterij za prepoznavanje otočnog rada.

Nekoliko radova se fokusiralo na analitičke metode otkrivanja otočnog rada sinkronih distribuiranih izvora u mreži [46] [47] [48]. Autori ref. [42] koriste Tufts-Kumaresan procjenu signala da bi preko aktivne snage utvrdili promjenu frekvencije prije i poslije pojave otočnog rada. Metoda je pasivnog karaktera i predlaže da bilo koja vrijednost veća od 0,01 u razlici frekvencije, pokreće računanje izraza (2-12) i (2-13), te poredi dobivene rezultate.

$$\Delta f\left(t\right)=\frac{-\omega_n\Delta\delta_0}{2\pi\sqrt{1-\varsigma^2}}e^{-\varsigma\omega_n^t}\sin\left(\omega_d t\right) \tag{2-12}$$

$$\Delta f\left(t\right)=\frac{\Delta P}{D}\left(1-e^{-2\varsigma\omega_n^t}\right) \tag{2-13}$$

gdje je (2-12) situacija prije otočnog rada, a (2-13) izračunata situacija nakon otočnog rada. Jasno se vidi koliko aktivna snaga djeluje na promjenu frekvencije kada se distribuiranog izvora nađe u otočnom radu. Na osnovu ovih saznanja autori jasno mogu otkriti razliku između sinkronog rada i otočnog rada distribuiranog izvora u distribucijskoj mreži. Također, testovi pokazuju da predložena metoda u usporedbi sa ROCOF i ROCOFOP metodama, daje bolje rezultate kada je razlika aktivne snage manja od 10%.

U referatu [43] autori K. Sareen, B. R. Bhalja, R. P. Maheshwari su iskoristili Hilbertove transformacije, valovite transformacije i standardnu normalnu distribucijsku funkciju da bi pretvorili negativnu naponsku komponentu. Prema testovima autora na IEEE 34-sabirničkoj shemi, preporučena metoda omogućava otkrivanje otočnog rada pri različitim situacijama razlike u snazi uključujući potpunu ravnotežu snaga između distribuiranog izvora i potrošnje. Također se prihvatljivo ponaša pri prelaska iz jednog uklopnog stanja u drugo, pri tome ne stvarajući uvjete za otočni rad. Također, metoda ostaje neosjetna na promjenu odnosa induktivne i kapacitivne komponente distribuiranog izvora. Predložena metoda se temelji na odnosu dvije formule (2-14) i (2-15).

$$NV_2=f\left(V_2|\mu,\sigma\right)=\frac{1}{\sigma\sqrt{2\pi}}e^{-\frac{\left(V_2-\mu\right)^2}{2\sigma^2}} \tag{2-14}$$

$$NV_2^{`} = f\left(V_2^{`}|\mu,\sigma\right) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{\left(V_2^{`}-\mu\right)^2}{2\sigma^2}} \tag{2-15}$$

Ovdje su vrijednosti μ i σ uzete tako da budu 0 i 1 za standardnu normalnu funkciju distribucije. Sada kada se dodaju navedene vrijednosti, rezultat se računa kao:

$$ROCSNDF = \frac{NV_2^{`} - NV_2}{\Delta t} \tag{2-16}$$

gdje su NV_2 i $NV`_2$ vrijednosti standardne normalne distribucijske funkcije za negativnu komponente napona (NSV) pod sinkronim i otočnim radom, dok je Δt vremenski interval uzorkovanja.

Također, autori M. Bakhshi, R. Noroozian i G. B. Gharehpetian u svom istraživanju pod ref. [44] obrađuju srednju vrijednost frekvencije generatora uz pomoć izrazi (2-17) (2-18) i (2-19), da bi dobili indeks prepoznavanja otočnog rada distribuiranog izvora.

$$\Delta f_{mean-on} = \frac{1}{T}\int_0^{T_d} -\frac{\omega_n \Delta\delta_0}{2\pi\sqrt{1-\varsigma^2}} e^{-\varsigma\omega_n t} \sin\left(\omega_d t\right) dt \tag{2-17}$$

$$\Delta f_{mean-off} = \frac{1}{T}\int_0^{T_d} \frac{\Delta P}{D}\left(1-e^{-\varsigma\omega_n t}\right) dt \tag{2-18}$$

$$\left|\frac{\Delta f_{mean-off}}{\Delta f_{mean-on}}\right| > 1 \tag{2-19}$$

Iako je promjena frekvencije već navedena kao bit analize, u ovom su se istraživanju autori okrenuli drugačijoj usporedbi dobivenih rezultata. Pošto je metoda bazirana na integralnim operacijama koje zahtijevaju vrijeme proračuna željene veličine, time je vrijeme prepoznavanja otočnog rada duže, ali u usporedbi sa derivacijama iste, kao što je ROCOF i ROCOFOP, ova metoda ima manji zone ne detekcije. Predložena metoda, prema rezultatima koje su autori prezentirali u radu, je odličan dodatak za nad i pod frekvencijsku zaštitu (OFP/UFP), gdje može poslužiti za smanjenje zone ne detekcije čak do 3%. Pri testiranju se koristilo nekoliko scenarija u kojima su bili uključeni kvarovi na distribucijskoj mreži, uklopna stanja kondenzatora na mreži, promjene uklopnog stanja konzuma.

Dosadašnja analiza dostupne literature o otkrivanju i zaštiti od otočnog rada distribuiranog izvora u distribucijskoj mreži, pokazuje da problem još nije riješen, te da navedena rješenja imaju

specifične prednosti i nedostatke. Navedeni pregled prikazuje da nijedna navedena metoda simultano ne pruža sva tri uvjeta kompletne metode:

1. nepostojanje zone ne detekcije,
2. 100% precizna,
3. brža od klasičnih zaštita.

Međutim, nekoliko navedenih metoda daju mnogo veću efikasnost od drugih metoda, s tim da uvjeti pod kojima se te metode pokažu neefikasne su toliko rijetke i specifične da se može reći da se nikada neće desiti. Navedene metode ipak sa sobom nose određeni trošak koji se ne može zanemariti, ako se razmišlja o praktičnoj primjeni a to su uglavnom:

- troškovi ugradnje u postojeću opremu,
- veoma zahtjevno uzorkovanje signala potrebnih za analizu,
- veliki pred instalacijski posao koji zahtjeva pripremu metode i snimanje distribucijske mreže na točki zajedničkog spajanja,
- kompleksan matematski aparat koji traži ogroman trošak proračuna u realnom vremenu.

Uzimajući navedene zahtjeve u obzir, nameće se zaključak da treba tražiti nove algoritme koji bi na sličan ili efikasniji način rješavali isti problem, prepoznavanja otočnog rada distribuiranog izvora u distribucijskoj mreži.

2.2 Primjene metoda umjetne inteligencije u energetici

Radovi prikazani u prethodnom poglavlju obrađuju temu otočnog rada kroz postojeće metode. Prikazani znanstveni radovi jasan su pokazatelj smjera razvoja trajnih rješenja kojima je moguće riješiti određene probleme zaštite u elektroenergetici, ali se svi navedeni pristupi ne bi smjeli, bez recenzije i ekonomski opravdane primjene, prihvaćati kao opća rješenja za apsolutno sve slučajeve pojave otočnog rada.

Do sada metode umjetne inteligencije (eng. Artificial Intelligence - AI) nisu relativno mnogo korištene u te svrhe, tj. za prepoznavanje otočnog rada. Međutim, složenost problema zaštite od otočnog rada zahtijeva korištenje metoda koje nisu analitičke, te time ne koriste konvencionalne metode koje zahtijevaju ogroman matematski aparat, koji je skup za izračunavanje iz kuta vremena i količine ulaznih parametara, gledano iz perspektive korištenje u realnom vremenu. Metode umjetne inteligencije, također imaju veoma kompleksan matematski aparat koji ima tendenciju rasti kvantitativno od slučaja do slučaja. Bez obzira na to, one su vrlo brze za korištenje nakon

uspješnog treninga i uspješnog prepoznavanja pojave koja se obrađuje, te nakon primjene postaje brza i efikasna s dozvoljenom tolerancijom. Radovi prikazani u prethodnom pod poglavlju, uspješno rješavaju problem otkrivanja otočnog rada jedne ili više jedinica distribuiranog izvora mreži, te se metode korištene u navedenim radovima, prema mišljenju autora ove disertacije, mogu proširiti, doraditi i/ili potpuno zamijeniti sa metodama umjetne inteligencije za rješavanja navedenog problema. Korištenje metoda umjetne inteligencije u elektroenergetici za rješavanje cijelog niza problema, od optimizacije rasporeda proizvodnje i potrošnje, preko upravljanja kvalitetom i elementima distribucijskoj mreži preko SCADA sustava, pa sve do autonomnih upravljačko optimizacijskih aplikacija za sigurno i efikasno djelovanje PLC-ova na određenim postrojenjima, su samo neka od područja u kojima metode umjetne inteligencije nalaze primjenu. Ovo pod poglavlje predstavlja dosadašnje radove autora koji se upravo u takvim problemima unutar elektroenergetike i srodnih znanosti koristili metode umjetne inteligencije, bilo da su to neizrazita logika (eng. Fuzzy Logic-FL), neuronske mreže (eng. Neural Network -NN), ANFIS (eng. Adaptive Neuro-Fuzzy Inference System), duboko učenje (eng. Deep Learning -DL), neizrazita logika tip-2 (eng. Type-2 Fuzzy Logic-T2FL), metode potpornih vektora (eng. Support Vector Machine - SVM), svaka od njih su korištene za određenu problematiku nudeći rješenja koja bi mogla ili zadovoljavaju korisnika.

Autori referata [49] su kao središte istraživanja postavili kvalitetu opskrbe energijom krajnjih kupaca kroz veličinu indeksa prosječnog trajanja prekida napajanja kupa (eng. customer average interruption duration index – CAIDI), te obradili kroz vrste kvarova na distribucijskoj mreži, kao i njihovu lokaciju u cilju što bržeg otklanjanja. Ovaj referat predstavlja jednu od tehnika umjetne inteligencije, preciznije ANFIS, za brzu i točnu dijagnostiku kvarova u distributivnim sustavima. Funkcije dijagnostike kvarova uključuju ispravnu klasifikaciju vrste kvara, preciznu lokaciju kvara, točnu identifikaciju neispravnih zaštitnih uređaja i trenutni status rada zaštitnih uređaja u distribucijskom sustavu. Da bi se utvrdile vrste kvarova i mjesta kvarova, predložena inteligentna tehnika koristi trofazne struje pri trofaznim kvarovima za treniranje adaptivnih neuro-fuzzy Sugeno tipova sustava sa zaključivanje (ANFIS). Stanje zaštitnih uređaja prikazano je kao binarno (1) jedan ili (0) nula pomoću predviđanja ANFIS-a, koristeći geometrijske koordinate točaka kvara. Rezultati simulacije pokazuju da tehnika ima prosječnu maksimalnu postotnu pogrešku od 0,02% za predviđanje vrste kvarova i 2,8% za određivanje mjesta kvara. Dobivene su prosječne maksimalne pogreške od 0,053 i 0,182 za radno stanje glavnih i rezervnih uređaja zaštite. Predložena tehnika provjerena je simulacijama pomoću komercijalnog softvera PSS-ADEPT.

Rezultati su pokazali da Sugenov tip ANFIS pristupa, omogućuje brzu i preciznu dijagnostiku kvarova koja se može implementirati u distribucijskoj mreži.

Struktura sustava za dijagnostiku se sastoji od nekoliko slojeva ANFIS-a, gdje je svaki sustav treniran za uraditi svoj dio posla, klasifikacija kvara, određivanje lokacije, identifikacija zaštitnih uređaja zaduženih za tu vrstu kvara. Na kraju, cijeli predloženi sustav ima ukupno 22 ANFIS sustava, koji svaki radi kao zaseban dio, gdje su izlazi iz jednih ulazi u druge sustave. U referatu je prikazana primjena Sugeno-tipa ANFIS za brzu i točnu dijagnostiku kvarova u distribucijskoj mreži, analizirajući ulazne parametre u svrhu dijagnoze tri funkcije: klasifikaciju tipa pogreške, mjesto kvara i neispravnu identifikaciju uređaja za zaštitu. Ulazni parametri koji se koriste su trofazne efektivne vrijednosti struje nakon što se kvar desi. Zatim se dobivene mjesta kvara koriste za identificiranje ispravnih radnih stanja glavnih i pomoćnih uređaja za zaštitu. Ukupni rezultat pokazuje da predloženi ANFIS sustav može dati brzu i preciznu dijagnozu grešaka u IEEE 34 sabirničkoj distribucijskoj mreži-i u usporedbi sa rezultatima dobivenim simulacijama PSS-ADEPT softwera. Obzirom na vrijeme izračuna, predloženi pristup dijagnoze kvarova traje samo 9 sekundi za obavljanje svih dijagnostičkih funkcija.

Kako je u prethodnom radu uvedena napredna primjena tehnika umjetne inteligencije u zaštiti prijenosnih vodova u elektroenergetskim sustavima, tako se u slijedećem primjeru [50] koristi ista metoda ANFIS-a u prepoznavanju parametara distantne/daljinske zaštite. Adaptivni sustav neuro-neizrazitog zaključivanja je vrlo pogodan alat među metodama umjetne inteligencije dijelom zbog njegove hibridne prirode, jer je sastavljen od FL i ANN, što omogućava lako korištenje i treniranje. U predloženom istraživanju uvest će se i raspraviti primjena ANFIS-a za distantnu zaštitu dalekovoda, pod različitim uvjetima opterećenja. Na temelju višestruko klasificiranog ANFIS-a i obzirom na različita opterećenja za duge prijenosne vodove u EES, predložena tehnika bavi se otkrivanjem kvarova, klasifikacijom i položajem kvara na dugim dalekovodima. Referat prvo razmatra otkrivanje pojave kvara u vrlo kratkom vremenu, a potom djeluje na mjesto kvara s ciljem izoliranja neispravnog dijela dalekovoda. Drugo razmatranje, prepoznaje vrstu kvara na dalekovodu i zaključuje koja je od tri faze izložena kvaru. Konačno, pronalaženje kvara se lako postiže čak i ako je postupak ovdje potpuno različit od kvarova u kratkim i srednje naponskim vodova. Ulazni podaci za vježbanje detekcijskih jedinica ANFIS, najprije proizlaze iz vrijednosti mjerenja napona i struje, gdje se pomoću digitalne obrade signala putem diskretne Fourierove transformacije (DFT), ulazni parametri za ANFIS obrađuju prije nego posluže kao svježi podaci. Ta su mjerenja simulirana obzirom na različite uvjete opterećenja sa modela napravljenog u MATLAB/Simulink programskom paketu na 500 kV dalekovodu, dužine 150 km. Sakupljeni

podaci opisuju 880 situacija na dalekovodu u koje su ubrojeni svi mogući kvarovi te normali režimi rada sustava, što znači da je usvojeno 880 treniranja modela ANFIS, te prema njima kreiran sustav koji su autori koristili za prepoznavanje parametara distantne zaštite.

Rezultati dobiveni u ovoj shemi vrlo su obećavajući u pogledu daljnjeg korištenja ANFIS-a kao metode rješavanja problema zaštita u elektroenergetici. Svi podaci o ispitivanju za metodu ANFIS u stanju kvara i bez kvara daju ispravan izlaz u promatranim vremenskim razdobljima. Za klasifikaciju grešaka, svi podaci ispitivanja daju ispravan izlazni broj koji predstavlja vrstu kvara na dalekovodu, tako da se ona približi najbližem cijelom broju kojem je doznačen određeni kvar. Za zadatak lociranja mjesta kvara, maksimalna pogreška ANFIS metoda iznosi oko 3% za različite otpore na mjestu kvara, obzirom na različita vremena početka kvara i različite vrste kvarova. Prezentirani rezultati u referatu i podaci za treniranje samog metoda, dobiveni su simulacijom pomoću MATLAB/Simulink programskog alata. Na osnovu predstavljenih rezultata, autori razmatraju različite uvjete opterećenja za duge prijenosne vodove u elektroenergetskim sustavima kao predmet za daljnje istraživanje. Predložena napredna tehnika distantne zaštite temelji se na višestrukom klasifikacijskom ANFIS-u, tijekom svih zadataka zaštite kao u prethodno predstavljenom referatu gdje ima nekoliko slojeva ANFIS-a i to svaki sa svojom zadaćom, sa razlikom što je u ovom slučaju jedan ANFIS zadužen za nekoliko zadaća.

Autori referata [51] također istražuju zaštitu EES-a, ali sa nešto drugačije perspektive. U centru pažnje nije određena zaštita, nego princip djelovanja ekspertnog sustava (ES), u ovom slučaju agenta, na pametne elektroničke uređaje (IED) u cilju pravovremenog i kvalitetnog reagiranja na događaje u srednje naponskoj (SN) distribucijskoj mreži.

Ovaj rad predlaže novi model zaštite SN distribucijske mreže primjenom distribuirane umjetne inteligencije, u području u kojem tradicionalno dominiraju metode centralizirane kontrole. Predloženi skalabilni više-agentni sustav pomoći će korisnicima u distribuciji izbjeći korištenje troškovno neisplativih i vrlo složenih SCADA sustava kontrole. Ogromne baze podataka, skupi i snažni računalni sustavi bit će zamijenjeni malim i raznovrsnim agentskim cjelinama zbog dekompozicije problema, kada se bude nametalo lokalno upravljanje distribucijskoj mreži-om. Bit predložene metode je tehnologija koja se brzo razvija, PLC (Power Line Communications), što doprinosi neovisnosti sustava od dodatnih telekomunikacijskih mreža, a samim time i troškova korištenja, a posebno bi dodatno nametnulo nekoliko funkcionalnih i ograničavajućih faktora. Projektiranje sustava bi rezultiralo odgovarajućom razinom redundancije, budući da su agenti neovisni subjekti koji svoje zadatke obavljaju u ime ljudi ali je moguće da se udruže kao jedno

centralno tijelo. Štoviše, autori predlažu formuliranje poželjne hijerarhije za zajedničke agente da djeluju na kooperativan i direktno djelotvoran način. Ciljana suradnja će se postići, budući da agenti uspijevaju:

- dobiti zajednički cilj,
- suglasiti se da žele surađivati u postizanju zajedničkog cilja,
- dogovoriti zajednički recept za postizanje zajedničkog cilja,
- provoditi međuzavisne radnje u kontekstu zajedničkog cilja,
- imati dogovor za praćenje održivosti svojih obveza.

Svrha zajedničkog cilja je osigurati materijal za ujedinjavanje djelovanja pojedinaca u kohezivnu cjelinu. Što se tiče vremena i resursa koje sustav treba za cjelokupni postupak izvršenja, rezultati terenskih testova su prilično ohrabrujući. Potrebno je nekoliko sekundi dok sustav ne prepozna okolinu i riješi scenarije testiranja na određene radnje i pojave koji su mogući scenariji u distribucijskoj mreži. Što se tiče okvira razvoja agenta, autori predlažu programski paket JADE koji je otvorenog tipa, te je moguće ostalim znanstvenicima da učestvuju u kreiranju infrastrukture mreže agenata. Zapravo se sastoji od paketa Java klasa za kreiranje softverskih agenata koji su u stanju komunicirati i razmjenjivati informacije u stvarnom vremenu. Navedeni JADE paket pruža potrebne ontologije koje kohezivno opisuju odnose između agenata koji čine više-agentni sustav. Cjelokupni okvir zahtijeva instalaciju Java izvršnog okruženja (eng. Java Runtime Environment-JRE), te je stoga neovisan o platformi. Zbog orijentacije predložene arhitekture, nije bilo u namjeri autora da osmisle složeni multi-agentni sustav koji bi zamijenio nadzorne inženjere, već fleksibilnu primjenu koja bi mogla ubrzati postupke zaštite. Iako u referatu nije predložena nijedna metoda umjetne inteligencije kao baza na kojoj se istraživanje zasniva, autori su na zanimljiv i konstruktivan način predložili ideju razvoja sustava nadzora, upravljanja i zaštite distribucijskoj mreži na nivou SN. Ono što je ostalo otvoreno jeste konkretna rješenja za konkretne probleme, na koje korisnici takvih sustava nailaze. Prethodno opisani radovi bi mogli biti dio pojedinih agenata ili sami agenti, te tako doprinijeti konkretizaciji predložene ideje.

S ciljem da distribucijskoj mreži radi bez zastoja u odnosu na krajnjeg kupca, uzimajući u obzir sustav zaštita obuhvaćajući i zaštitu od otočnog rada, autori rada [52] su predložili poseban način sustava zaštita. Ponuđeni sustav bi bio u mogućnosti autonomno izvršavati radnje koje su mu zadane, bez obzira bio spojen na oblak ostalih komponenti istog sustava ili radio autonomno odnosno lokalno. Da bi mikro mreže, od kojih je distribucijskoj mreži sastavljena, radile ispravno, prekidač mora biti otvoren za vrijeme nekog poremećaja, a distribuiranog izvora energije moraju

biti u stanju nositi teret na otočnom dijelu mreže, ako je to politika upravljanja, ili se odvojiti od potrošača iz mikro mreže gledano iz perspektive distribuiranog izvora. Ovisno o tehnologiji prekidača, mogu se pojaviti trenutni prekidi tijekom prijenosa iz načina „spojenog na mrežu“ na otočni pogon i obratno. Za visoku pouzdanost mora se koristiti prekidač velike brzine, što nije tema koju su autori ovog referata obrađivali, ali su naveli da popratna oprema mora podržavati predloženi način upravljanja. Cilj autora ovog rada je osmisliti rješenje na temelju ANFIS-a koji rješava opće probleme FL i NN u sustavu zaštite. ANFIS koji donosi odluku kroz obuku za sve svoje elemente (tj. dio neizrazite interferencije, funkcija pripadnosti, broja neurona i broja pravila) urađena je metodama „pokušaja i pogreške“. Model ANFIS ne zahtijeva točan model postrojenja, nego samo ulaze i izlaze tog sustava.

Njegova relativna jednostavnost u obliku alata olakšava konstrukciju i primjenu. Visoka razina znanja o sustavu nije potrebna za izgradnju skupa pravila za FL kontrolor ili za identifikaciju koja je potrebna u NN kontroloru. Ova tehnika ima neke prednosti u odnosu na tradicionalne koje su obrađene u prethodnom pod poglavlju. Treba napomenuti nekoliko točaka koje autori ističu kao bitne:

a. Rezultati simulacije pokazuju da je prosječno trajanje predložene tehnike kraće od trajanja komercijalnih releja.
b. Uočena je visoka stabilnost predloženog algoritma za sve greške i radne uvjete.
c. Druga važna prednost algoritma leži u njegovoj jednostavnosti i računalnoj učinkovitosti, pogodnoj za komercijalnu primjenu.
d. Tradicionalna teorija može se smatrati posebnim slučajem teorije temeljene na Hilbertovom prostoru. Drugim riječima, teorija koja se temelji na Hilbertovom prostoru može se smatrati generalizacijom.
e. Rezultati simulacije analizirani su za različite uvjete kvara. Pokazano je da je predloženi procesor ANFIS-a vrlo učinkovit za pouzdan rada zaštitnog sustava.

Vrijeme odgode za otvaranje prekidača traje oko jedan ciklus nakon pojave kvara. Štoviše, predloženi algoritam ne treba prag djelovanja, nego on daje postotak udjela pojave u trenutnom stanju mreže. Ova metoda daje prilično dobru procjenu pouzdane, točne i brze razlučivosti za sve vrste kvarova. Jedna od glavnih prednosti ANFIS-ove sheme je u tome što je ona računski učinkovita, povećava dinamičke osobine i osigurava dobru stabilnost u slučaju kvara. To pokazuje izvrsnu reakciju predloženog sustava zaštite, jer ima sposobnost učenja pomoću svog dijela sa neuronskim mrežama. Sve navedeno su autori zaključili u istraživanju, te prezentirali u referatu.

Većina direktnih rješenja za specifične probleme u području zaštita su uglavnom bazirana na ANFIS metodi, što istraživača navodi na zaključak da je ANFIS veoma fleksibilna, brza, učinkovita metoda koja se može vrlo jednostavno iskoristiti u navedenom području elektro energetike. Ono što još pridonosi jeste da ANFIS nije ograničen kvantitativno promatrajući rješenje, nego se može generirati beskonačno mnogo sustava koji mogu raditi autonomno i/ili u simbiozi da ostalim sustavima koji obrađuju informacije.

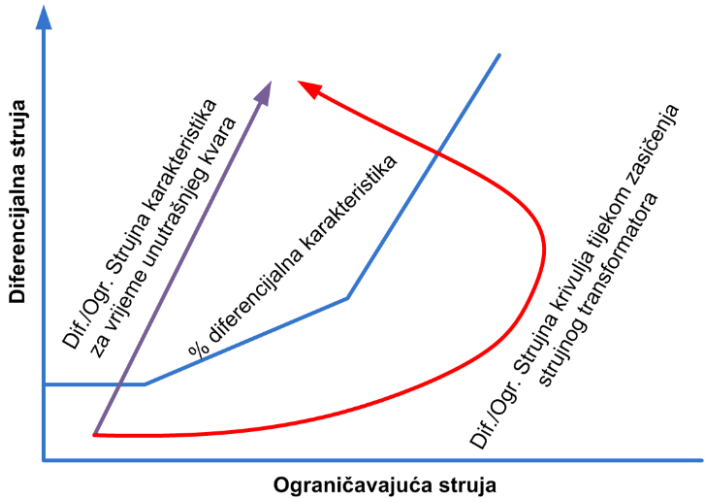
Još jedno istraživanje su uradili autori referata [53] koje koristi navedeni ANFIS, koji također ovog puta predstavlja relej distantne zaštite, međutim sa proširenim mogućnostima. Tehnike umjetne inteligencije uvedene su u zaštitu prijenosa električne energije, gdje pronalaze mjesto zamjenjujući standardne konvencionalne metode koje se koriste u elektroenergetskim sustavima. U ovom referatu je također primijenjena ANFIS metoda za distantnu zaštitu dalekovoda. Ako dođe do isključivanja dalekovoda, tijekom identifikacije voda pogođenog neželjenim kvarom, isporuka energije potrošaču se prekida. Stoga bi trebalo pružiti alternativno rješenje za rješavanje ovog problema s ciljem da se kvar zaobiđe, te izolira, a kupcu nastavi opskrba. Cilj ovog rada je uporaba impedancije dalekovoda kojim se prijenosi energija kako bi se odredilo zona zaštite distantnog releja. Releji distantne zaštite djeluju na dalekovod koji je u kvaru i to sada sa istreniranim Sugeno ANFIS-om. Simulacija pokazuje da se izvrsni rezultati testiranja mogu dodati ponuđenom alternativnom algoritmu koji ima dobre osobine za zaštitu prijenosnog voda.

Autori su kroz rad predložili ANFIS shemu koja određuje mjesto postavljanje releja za svaku štićenu zonu i njenu udaljenost, te u slučaju kvara djeluje kao distantna zaštita. Određivanje zone udaljenosti je jedan od problema sa kojim se navedena zaštita susreće pri parametriranju releja. Stoga se smatra da je potrebno odrediti točno postavljanje zone štićenja releja . Rezervna zaštita može biti zamijenjena korištenjem predložene tehnike, ako se uzmu u obzir rezultati testova, te usporedi s konvencionalnom tehnikom. Shema koju ANFIS usvoji kao radnu verziju može se koristiti u normalnim uvjetima i tijekom kvarova. Konačno, rezultati ispitivanja mogu pomoći jednoj od inteligentnih alternativnih tehnika koje imaju vrlo dobre osobine za poboljšanje zaštite dalekovoda.

Još jedno istraživanje se veže uz zaštite elektroenergetskih postrojenja koristeći [54] ANFIS i to ovog puta uzimajući u obzir sve vrste objekata koje treba štititi od poremećaja. Iako su uzorci koji se uzimaju pri analizi pojave struje i naponi, situacija gotovo nikada nije jednostavna po pitanju klasifikacije. Autori navode tri pokazatelja koja uzimaju u obzir pri analizi pojave: usporedba faza

s usmjerenim strujama, dinamička diferencijalna karakteristika s niskim / visokim strujnim režimom i algoritam za detekciju zasićenja temeljen na tehnici umjetne inteligencije.

Sveobuhvatna struktura ANFIS-a kreirana je s tri gore opisana svojstva, kako bi se razlikovala stvarna unutarnja greška u ciklusu veza slojeva i vanjske smetnje za slanje signala blokiranja, kako bi se izbjeglo loše reagiranje zaštite sabirnica. Inteligentni algoritam za zaštitu sabirnica praktično se testirao na tipičnom sabirničkom sustavu 220 kV u Egiptu, sa sekundarnim ispitivanjem na sustavu zaštite sabirnica koji postoji na trafo stanici. Tada se stvarni rezultati ispitivanja uspoređuju sa simuliranim sustavom zaštite spomenutog naprednog algoritma zaštite. Rezultati pokazuju valjanost i djelotvornost predloženog pametnog algoritma s vrlo brzim odzivom na signal kvara, čineći predloženi algoritam prikladnim za zaštitu u realnom vremenu. Pored operacija koje ANFIS obavlja u svrhu zaštita, autori su uključili slučaj da dođe do zasićenja strujnih mjernih transformatora, te time pogrešne informacije dolaze na ulaz ANFIS-a. Slika 2.2. Prikazuje trend u kojem se nalazi zasićenje SMT-a, te se to uračunava pri prikupljanju informacija.



Slika 2.2. Trajektorija struja razlike i suzdržanih struja tijekom zasićenja strujnih mjernih transformatora i unutarnjih kvarova [54].

Pojava zasićenja SMT dovodi do pogrešnih ulaznih podataka, gdje se može desiti da zaštita djeluje pri normalnom radu. To se ne smije dopustiti pa autori predlažu algoritam koji će posebno pratiti strujno zasićenje SMT-a. Kada detektor zasićenja (SAT) objavi, tj. SAT = 1, pod funkcija provjerava je li diferencijalna struja ispod prvog nagiba s malom brzinom promjene, a prati se i veća vrijednost promjene za zadržavanje, što dovodi do ograničenja diferencijalne putanje izvan diferencijskih karakteristika za određeno vremensko razdoblje. U slučaju zasićenja djelovanje zaštite je ograničeno i nepouzdano što ANFIS javlja korisniku.

Iz dosadašnjih prezentiranih referata se može zaključiti da su metode umjetne inteligencije veoma korisne u elektroenergetici i to ne samo u području zaštita, što se može vidjeti iz radova koji jako mnogo obrađuju temu predviđanja opterećenja, proizvodnje električne energije. Upravo prognoza tereta je tema referata autora Thai Nguyen i Yuan Liao u [55], gdje autori u svrhu adekvatnog djelovanja na distribucijskoj mreži i pravovremenog planiranja uklopnog stanja distribucijskoj mreži koriste metodi umjetne inteligencije za precizno predviđanje opterećenja mreže. Ovaj rad prikazuje precizno predviđanja opterećenja od jednog sata unaprijed, komunalnom poduzeću koje se nalazi u regiji Sjeverne Amerike, na temelju sustava adaptivnog neuro-neizrazitog zaključivanja (ANFIS). Unosi u ANFIS su temperatura sljedećeg sata, točka rosišta sljedećeg sata, dan u tjednu, sat u danu i opterećenje trenutnog sata. Izlaz is predložene metode je opterećenje cijelog sustava za sljedeći sat.

Prema testiranjima koja su autori proveli nad predstavljenim metodom, metoda temeljena na ANFIS-u može točno predvidjeti opterećenje sljedećeg sata s pogreškom od 2,5%. Sustav ima prednosti jednostavnog oponašanja znanja stručnjaka i automatsko ugađanje funkcija pripadnosti za optimalno mapiranje ulaza vrijednosti neizrazite logikete je time učenje ne nadzirano. Prikazane studije temeljene na podacima koje je dala komunalna tvrtka u usporedbi sa dobivenim testnim rezultatima izgleda vrlo obećavajuće.

Još jedno istraživanje u kojem se obrađuje tema predviđanja opterećenja su obradili autori Karthik Sivakoti i Mohammad Mozumdar u referatu [56] koristeći umjetne neuronske mreže (ANN). U ovom radu prikazan je hibridni algoritam koji je praktično pokazao da je učinkovitost predviđanja mnogo veća od klasičnih metoda. Korištenjem umjetnih neuronskih mreža za korištenje modela s povijesnim podacima i promjenama potražnje, korištena je metoda linearne regresije za primjenu osjetljivosti na temperaturu, i to: točka rosišta, vlažnost, brzina vjetra, sezonske varijacije i položaj pametnog brojila koje mjeri potrošnju električne energije. Zajedno s algoritmom za prilagodbu krivulje, predloženi hibridni algoritam praktično je implementiran uzimanjem podataka s pametnih brojila diljem Sjedinjenih Država, kako bi se utvrdila njihova učinkovitost provedbe. Predloženi algoritam opisan u ovom radu, rezultirao je velikom točnošću predviđanja od 99,2% - 99,45%, što obećava veliko smanjenje snage koja se troši na elektroenergetska poduzeća, zbog neusklađenosti unutar stope potražnje energije od potrošača i daleko je preciznija od predviđanja koja su zasnovana na klasičnim tradicionalnim metodama. Neuronske mreže implementirane su pomoću Levenberg-Marquardt (LM) algoritma (koristi se za rješavanje nelinearnih problema najmanjih kvadrata) koji je iterativni pristup za rješavanje jednadžbi kriterijem najmanjih kvadrata,

uključujući i probleme prognoziranja. LM algoritam može se dalje opisati kao metoda za obradu i rješavanje jednadžbe (2-20):

$$\left(J^t J + \lambda I\right)\sigma = J^t E \tag{2-20}$$

Gdje su:

J je Jacobian matrica koja sadrži prvu obradu greške neuronske mreže sa postojećim težinama i pomacima,

λ je uvijek pozitivno a ako je veoma malo cijeli izraz (2-20) prelazi u Newton-ovu metodu, inače se naziva kombinacijski koeficijent,

σ je gradijent koraka trenutne epohe treniranja težina ulaznih veličina,

E je komponenta Hessian matrice gdje učestvuje kao umnožak sa Jacobian matricom trenutne obrade greške.

Svaka epoha uključena u fazu I uključivala bi računanje *J* nakon čega slijedi gradijent pogreške, a zatim ažuriranje težina pomoću σ. Ukratko, svaka epoha se ponavlja kroz izraz (30).

Predloženi algoritam je dao srednju apsolutnu postotnu pogrešku (eng. Mean Absolute Percentage Error – MAPE) od 0,86% pri korištenju ANN, zajedno sa linearnom regresijom, te podešavajući krivulju.

Poslije predviđanja tereta mreže, distribucijskoj mreži koja ima tendenciju postati napredna mreža (eng. Smart Grid), upravljanje će prepustiti također metodama umjetne inteligencije koje na efikasan i pravovremeni način djeluju na distribucijskoj mreži u svrhu što kraćeg ostanka bez napajanja krajnjih kupaca, a istovremeno zadržavajući visok nivo sigurnosti osoblja distribucijskoj mreži. Istraživanje koje su sproveli autori referata [57] su isto bazirali na upravljanju toka snaga u SG, koristeći neizrazitu logiku (en. Fuzzy Logic (FL)). U radu je prikazan inteligentni distributivni sustav temeljen na neizrazitoj logici koji optimalno koristi raspoloživu energiju. Autori proučavaju elektroenergetski sustav s dva distribuirana izvora obnovljive energije poput vjetra i sunca, zajedno s konvencionalnim napajanjem distribucijskoj mreži-a. Kroz prikladni omjer raspodjele proizvodnje izvora energije, distribucijski sustav proizvodnje, u kombinaciji s baterijom, može korisniku pružiti pouzdanu i stalnu električnu energiju. Stoga kod distribucija el. energije opskrbu potrošača energijom, radi tako da se njihova potražnja optimalno opskrbljuje ovisno o dostupnoj energiji i statusu baterije. U ovom radu, novi sustav distribucije testiran je s teorijom neizrazite logike, kako bi se konstantno zadovoljavala potreba za opterećenjem, te kako bi se stanje punjenja

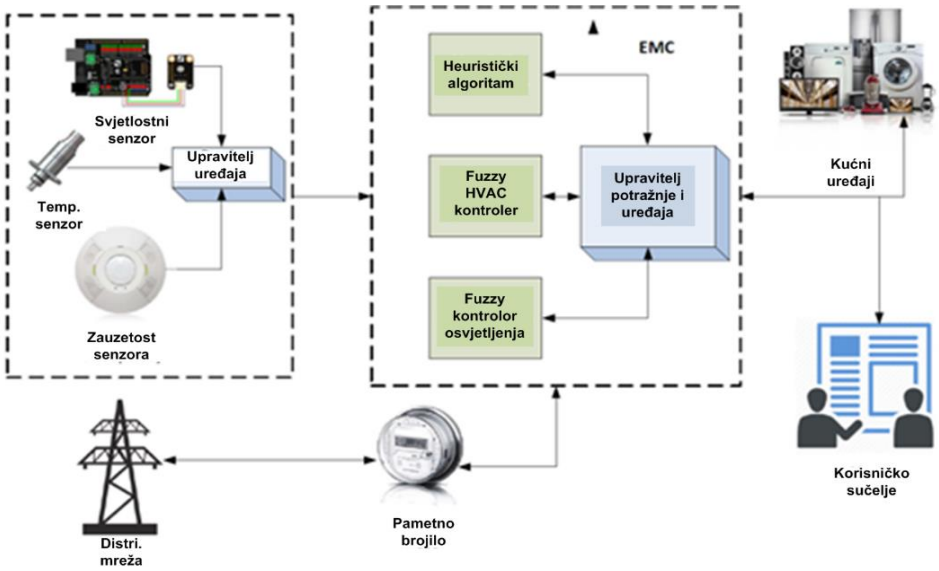
baterije održalo na sigurnoj razini. Također su prikazani rezultati simulacije, kako bi se ilustrirale potencijalne prednosti pametnog distributera maksimiziranjem upotrebe obnovljivih izvora energije i smanji se ovisnost o opskrbnoj mreži.

Rezultati simulacije pokazali su da je opterećenje zadovoljeno optimalnim iskorištavanjem obnovljivih izvora. Pametna odluka donesena je online sustavom temeljenim na informacijama o trenutačnoj potražnji i energetskom statusu. Ovaj rezultat također pokazuje kako novi sustav štiti bateriju, tako da doseže kritične gornje i donje razine, te time čuva bateriju da ne razvije tzv. efekt pamćenje kod baterija. Također je istaknuto da je cjelokupna potražnja potrošača zadovoljena minimalnim korištenjem energije iz opskrbne mreže. Mogući daljnji razvoj ovog rada uključuje optimalno podešavanje pravila Fuzzy Logic i parametara funkcija pripadnosti, kao i pronalaženje numeričkog načina za procjenu energetske učinkovitosti.

Predviđanje nije samo ograničeno na opterećenje mreže, nego se može metoda umjetne inteligencije vrlo jednostavno primijeniti na još nekoliko veličina koje bi bilo zgodno znati unaprijed. Jedna od njih je ukupna potrošnja korisnika mreže. Autori referata [58] unutar svog rada predlažu metodologiju predviđanja potrošnje energije u stambenim zgradama. Predložena metoda sastoji se od četiri različita sloja, a to su prikupljanje podataka, pred procesiranje, predviđanje i vrjednovanje osobina. Za eksperimentalnu analizu prikupili su stvarne podatke iz četiri višekatne stambene zgrade. Prikupljeni podaci koriste se kao ulazni sloj za akviziciju. U sloju prethodne obrade, nekoliko shema za čišćenje i pred obradu podataka se koristi za uklanjanje nepravilnosti iz podataka. U predviđenom sloju koristili su stroj za duboko ekstremno učenje (eng. Deep Extreme Learning Machine - DELM) za predviđanje potrošnje energije. Također je korišten ANFIS i umjetne neuronske mreže (ANN) u sloju predviđanja. U Deep Extreme Learning Machine-u se koristi različit broj skrivenih slojeva, različitih skrivenih neurona i različite vrste aktivacijskih funkcija, kako bi se postigla optimalna struktura Deep Extreme Learning Machine-a za predviđanje potrošnje energije. Slično tome, u ANN-u autori su koristili različitu kombinaciju skrivenih neurona s različitim tipovima aktivacijskih funkcija, kako bi dobili optimalnu strukturu ANN. Da bi dobili optimalnu strukturu ANFIS-a, autori su koristili različit broj i vrstu pripadnu funkcija. U sloju za ocjenjivanje osobina za komparativnu analizu triju algoritama predviđanja, korištene su srednje apsolutne pogreške (MAE), srednju kvadratnu pogrešku (RMSE) i srednju apsolutnu pogrešku (MAPE). Rezultati pokazuju da je učinkovitost Deep Extreme Learning Machine-a daleko bolja od ANN i ANFIS-a za jednotjedno i mjesečno satno predviđanje energije sa danim podacima.

Svrha korištenja različitih algoritama strojnog učenja na prikupljenim podacima bila je dobivanje boljih rezultata u smislu točnosti za praktične primjene. Za optimalnu strukturu Deep Extreme Learning Machine-a različitih parametara, napravljen je različit broj skrivenih slojeva, različit broj neurona u skrivenom sloju i različite aktivacijske funkcije podešene su kako bi se dobila optimizirana struktura DELM-a.

Još jedno veoma zanimljivo istraživanje je prezentirano u referatu [59], gdje autori obrađuju temu upravljanja kućnim trošilima uz pomoć neizrazite logike. Upravljanje energijom na strani potrošača složen je zadatak, zahtijeva učinkovito raspoređivanje uređaja s minimalnim kašnjenjem, kako bi se smanjio omjer vršnih i srednjih vrijednosti i troškovi potrošnje energije. U ovom radu uvedena je klasifikacija uređaja na temelju njihove potrošnje energije. Regulator upravljanja energijom razvijen je za upravljanje potražnjom. Korištena je neizrazita logika i tehnike heurističke optimizacije za troškove, potrošnju energije i smanjenje opterećenja. neizrazite logike se koristi za upravljanje prigušnicama i prekidačima s obzirom da ima mogućnost implementacije u obliku kontrolora u realnim aplikacijama. S druge strane, heuristički optimizacijski algoritmi, koriste se za raspoređivanje pomičnih uređaja. Autori su također predložili hibridni optimizacijski algoritam za raspoređivanje kućanskih aparata, nazvan hibridni optimizacijski algoritam oprašivanja. Rezultati simulacije pokazuju značajno smanjenje potrošnje energije, troškova i potražnja za vršnim opterećenjem. Predloženi sustav koji su autori projektirali je predstavljen na slici 3.



Slika 2.3. Arhitektura EMC sustava koji su autori referata [59] predložili, a koji se sastoji od 3 kontrolora i jednog centralnog regulatora.

Korištene su tri tehnike optimizacije za planiranje uzorka uređaja koji se mogu isključivati. Te tehnike optimizacije uključuju: optimizacijski algoritam hibridnog oprašivanja (HFBA), algoritam oprašivanja cvijeta (Flower Pollination Algorithm - FPA) i BAT algoritam. Ove tehnike smanjuju razliku vrhova i prosjeka (PAR), financijske troškove do značajne razine u usporedbi s nepredvidivom potrošnjom. Predložena tehnika optimizacije izvodi se sa dva parametra: PAR i udobnost korisnika. Prema ukupnim osobinama optimizacijskih tehnika, HFBA pokazuje nadmoć nad BAT i FP algoritmima u smislu unaprijed definiranih parametara . Slično tome, BAT algoritam pokazuje bolje osobine u usporedbi s FP algoritmom. Rangiranje ovih algoritama je u skladu s njihovim ponašanjem u predočenom studiju slučaja. Ponašanje ovih algoritama može se razlikovati u drugim scenarijima. Osim toga, korištena je neizrazita logika za smanjenje potrošnje energije, troškova HVAC-a i sustava rasvjete. Sve veća primjena solarna energija kao obnovljivog izvora od velike je važnosti za njen utjecaj u distribucijskoj mreži. Razna istraživanja su usmjerena na poboljšanje učinkovitosti foto naponskih sustava i dostupnost ove tehnologije, kako komercijalno tako i tehnološki. Uspjeh foto naponskih energetskih rješenja ovisi o tome jesu li uvjeti, u kojima uređaji energetske elektronike mogu izvući maksimalnu snagu iz foto naponskih sustava (FNS), povoljni i kako sa njima ako nisu. Zatim je potrebno dobivanje maksimalne snage iz FNG-a u realnom vremenu sa konstantnim uzorkovanjem i promjenom upravljanja. Prati se točka maksimalne snage (MPPT) za FNS izlaze pri svim uvjetima osunčanosti i temperature. Stoga pouzdanost MPPT regulatora postaje ključna kontrola u radu uređaja za uspješna rješenja foto naponskih sustava. Općenito, kontrola MPPT-a predstavlja izazov, jer se uvjet sunčeve svjetlosti i temperature, koji određuju količinu sunčeve energije i unutarnju temperaturu u FNS-u, može promijeniti u bilo kojem trenutku. Karakteristika FNS i njegove struje je vrlo nelinearna. Budući da foto naponskih niz ima vrlo nelinearne karakteristike, a njegove osobine se mijenjaju s radnim uvjetima kao što su izolacija ili temperatura okoline. Stoga je tehnički izazov razviti foto naponski sustav koji može prevladati stvarne nedostatke. Da bi se to prevazišlo, potrebno je što jeftinije, brže i točnije pronaći MPPT za određeni set nizova nekog foto naponskog rješenja.

Nekoliko istraživača su svoj rad razvijali oko metoda umjetne inteligencije, a u svrhu pronalaženja točke maksimalne snage za fotonaponske sustave na osnovu ulaznih podataka: osunčanosti i temperature zraka. Iako su tradicionalne metode koje se koriste u tu svrhu pokazale zadovoljavajući nivo performansi, Ui metode su kroz eksperimentalno istraživanje dale rezultate mnogo bolje do gotovo 10 % u nekim referatima. Jedan od takvih uradaka je referat [60], gdje autori predstavljaju inteligentni pristup za poboljšanje i optimizaciju učinkovitosti FN sustava. Proučena je topologija foto naponskih sustava s ugrađenim kontrolorom za praćenje MPPT-a. Da

bi se postigao ovaj cilj, poseban interes bio je usmjeren na ANFIS algoritam temeljen na Sugeno modelu zaključivanja. Ovaj rad predstavlja detaljnu studiju i projekt MPPT kontrolora za osiguranje visokih performansi FN sustava, koji se mogu odabrati za praktičnu primjenu. Postignut je simulacijski rad s MPPT regulatorom, DC/DC izmjenjivač koji napaja DC motornu pumpu. Dobiveni su značajni rezultati koji dokazuju valjanost predloženog cjelokupnog foto naponskog sustava pumpanja, sa predloženom metodom traženja MPP-a.

Slijedeća istraživanja koja se bave istom tematikom su obradili autori referata [61] [62] gdje su predstavili usporedbu ANFIS-a, kao metode traženja točke maksimalnog opterećenja, te nekih tradicionalnih metoda kao što je Pretraži i Nadgledaj (eng. Preturb&Observe-P&O). Prema autorima za praćenje MPPT-a s ANFIS-om, potrebni su ulazni i izlazni skupovi podataka. Ovi skupovi ulaznih i izlaznih podataka uzimaju se iz ograničenja u radu sustava. Postoje dva moguća načina prikupljanja podataka za obuku ANFIS-a. Jedan je prikupljanje podataka iz sustava u stvarnom vremenu, drugi je iz simulacije razvijanjem točnog dinamičkog modela za FN modul. Prikupljanje podataka iz sustava u stvarnom vremenu je vrlo teško zbog nestabilnog vremena i nemogućnosti kontrole vremenskih uvjeta. Stoga su podaci o obuci prikupljeni u ovom radu od simulacije, nakon razvoja dinamičkog foto naponskog modula. Predloženi ANFIS MPPT preuzima radnu temperaturu i zračenje, kao ulaz i prognozira maksimalne izlazne snage iz foto naponskog modula u tom trenutku. Pri istoj radnoj temperaturi i zračenju, stvarna izlazna snaga iz foto naponskog modula izračunava se očitavanjem radnog napona i struje. Uspoređene su ovisne snage i izračunate snage, te se daje pogreška proporcionalnom integralnom (PI) kontroloru, kako bi se generirali operativni signali. Signal rada koji generira Proporcionalno Integralni kontrolor daje se PWM izvoru. PWM signal se generira korištenjem visoke frekvencije u usporedbi s radnim signalom.

Frekvencija korištenog nosećeg signala je 25 kHz. Generirani PWM signali upravljaju radnim ciklusom DC-DC izmjenjivača, kako bi se podesila radna točka FN modula. Konvencionalne tehnike MPPT kontrole- P&O, su uspoređene s naprednom tehnikom umjetne inteligencije-a ANFIS sustavom. Obje su primijenjene na lancu pretvorbe energije isporučenom pomoću DC/DC izmjenjivača, koji ima ulogu podešavanja izlazne snage sa DC segmenta foto naponskog sustava. Može se shvatiti da MPPT ANFIS kontrolor, koji se u početku temelji na iskustvu operatera tijekom faze treninga, ima vrlo dobre osobine To poboljšava odzive foto naponskog sustava, što smanjuje vrijeme odziv pri traganju za maksimalnom snagom. To dokazuje učinkovitost upravljanja ANFIS-om za fotonaponske sustave u različitim uvjetima okoline. Analiza osjetljivosti istražuje snagu koja se isporučuje iz solarnog foto naponskog sustava na kontinuirano promjenjivo

opterećenje i nedostatak koji se mora dobiti iz mreže. Prekomjerna snaga koja se može prenijeti na mrežu koja bi mogla eliminirati nužnost sustava za pohranu energije, kao što su baterijski sustavi, za pohranjivanje viška proizvedene energije. Ova analiza predviđa isporuku el. energije tijekom cijelog dana i sve tako kroz godinu. Još slikovitiju usporedbu su napravili autori referata [63], gdje su na intuitivan način nakon urađenih simulacija i testova napravili tablicu u kojoj su prikazani svi u to vrijeme poznati algoritmi traženja točke maksimalne snage. Tablica 2 je preuzeta iz dotičnog referata, te prikazuje spomenutu usporedbu.

Tablica 2.2. Komparativne karakteristike raznih MPPT algoritama, uzete iz [63].

MPPT Algoritmi	**Složenost algoritma**	**Brzina konvergencije**	**Analogni ili digitalni**	**Ovisnost FN niza**	**Preciznost traženja**	**Hardware primjena**	**Aplikacija**
O.C. Voltage	malo	sporo	oboje	da	mala	laka	bez mreže
S.C. Current	malo	sporo	oboje	da	mala	laka	bez mreže
P&O	malo	sporo	oboje	ne	srednja	laka	oboje
INC	srednje	brzo	digitalno	ne	visoka	srednja	oboje
Fuzzy	srednje	brzo	digitalno	da	veoma visoka	laka	oboje
ANN	veliko	brzo	digitalno	da	veoma visoka	teška	s mrežom
PSO	veliko	brzo	digitalno	ne	veoma visoka	srednja	oboje
Slide Mode	srednje	brzo	digitalno	ne	srednja	teška	oboje

Istraživanje naglašava tehničke aspekte, prednosti, te analizira svojstva svake metode. Odabir određene MPPT tehnike je specifičan za primjenu i analizira trenutno dostupne tehnike za ovu problematiku. Na temelju ovog pregleda, može se zaključiti da izvan mrežne i online tehnike rade vrlo dobro, samo kada je sunčevo zračenje ujednačeno. No, ne uspijevaju pristupiti istinskom

MPP-u kada dođe nagla promjena atmosferskih prilika i djelomično zasjenjeni uvjeti. Ovaj nedostatak je nadvladan novim MPPT tehnikama koje se temelje na umjetnoj inteligenciji i koje pokazuju dobre osobine u praćenju MPP-a. Još se više istraživača odlučuje za pronalaženje jednostavnih, jeftinih, lako implementirajući i visoko učinkovitih algoritama.

Istraživanje koje su prezentirali autori u referatu [64], koristi algoritam upravljanja energijom za fotonaponske crpke i instalacije za kapljično navodnjavanje. Postrojenje se sastoji od foto naponskih panela, baterija, DC / AC izmjenjivača, releja i potopne pumpe. Uzimajući u obzir optimalne kriterije upravljanja, algoritam odlučuje o vremenima povezivanja različitih komponenti sustava, dok ispunjava potražnju za navodnjavanjem i smanjuje korištenje baterije. Prikazan je i ocijenjen algoritam neizrazitog upravljanja za optimalan rad fotonaponskog sustava za navodnjavanje sastavljen od foto naponskih panela, olovnih baterija i potopljene crpke. Algoritam donosi odluke o vremenu priključenja crpke i baterija na fotonaponske panele uzimajući u obzir snage FN sustava, dubinu pražnjenja akumulatora i količinu uskladištene vode. Kontrolni alat ima za cilj osigurati kontinuiranu opskrbu crpke i zaštitu baterija od dubokog pražnjenja i pretjeranog punjenja. Učinkovitost algoritma testirana je tijekom vegetativnog ciklusa rajčica (od ožujka do srpnja). Simulacija sustava pokazuje da algoritam jamči autonomiju sustava i sigurnost baterije. Predloženi algoritam je generaliziran, u smislu da se može koristiti za foto naponski sustav-navodnjavanje različitih veličina parcela, davanjem samo mjesečne potrebe za vodom. Kao opći zaključak, pokazali smo da su neizraziti algoritmi vrlo prikladni za sustave upravljanja energijom, te da jednostavni sustavi upravljanja energijom mogu poboljšati otočni rad foto naponskih sustava. Iz navedenog je jasno da neizrazita logika ima veoma široku primjenu ne samo u energetici nego u oblastima koja koriste energetiku, ali donose dodatne ovisnosti pri upravljanju i korištenju energetskih postrojenja. Na osnovu navedenih istraživanja se može reći da aplikacije koje umjetne inteligencije tehnike mogu zadovoljiti su gotovo neograničene, a među njih se ubraja elektroenergetika.

Još jedan od takvih referata je [65] gdje autori predstavljaju strategiju upravljanja energijom, koja se temelji na kontroli neizrazite logike za hibridni moderni tramvaj s pogonom na lančanu bateriju-ultra kondenzator. Neizraziti logički kontrolor za zonu kontaktne mreže i zonu bez katetera je projektiran tako da analizira strukturu i način rada hibridnog sustava, a zatim je predložena strategija upravljanja energijom koja se temelji na kontroli dvostruke neizrazite logike, kako bi se poboljšala potrošnja goriva. Hibridni moderni simulacijski model tramvaja razvijen je na temelju MATLAB / Simulink okruženja. Na osnovu dobivenih rezultata testiranja, može se reći da predloženi sustav upravljanja energijom može jamčiti pouzdan rad hibridnog sustava tramvaja

tijekom stvarnog ciklusa vožnje. Baterija i ultra kondenzator mogu dobro raditi zajedno kako bi zadovoljili potrebe snage DC sabirnice, ultra kondenzator osigurava vršnu snagu u zoni veze sa mrežom i time je pokrivena početna pogonska snaga. U zoni kontaktne mreže, ista osigurava vučnu snagu za tramvaje, tj. za daljnje napredovanje tramvaja i sakupljanje energije u sustavu baterija. Osim toga, i kada je vučna snaga veća, sustav čuvanja energije može dati izlaznu snagu, što smanjuje izlaznu snagu potrebnu za povlačenje iz kontaktne mreže.

Još jednu zanimljivu upotrebu neizrazite logike su predstavili autori referata [66], gdje su postavili u fokus istraživanja problem koji se odnosi na prijenosna računala i ručne uređaje sa ograničenom snagom baterije, životni vijek baterija značajno utječe na osobine ad hoc mreža, budući da čvorovi u ad hoc mrežama trebaju prenijeti svoje podatke preko drugih čvorova. U ovom radu FL kontrolori uzimaju u obzir broj skokova, zauzetost redova paketa i preostalu energiju duž staza prilikom odabira ruta. Predložena metoda neizrazitog usmjeravanja procjenjuje se i uspoređuje s klasičnim AODV usmjeravanjem u smislu omjera paketnog prijenosa, prosjeka odgode od kraja do kraja i prosjeka potrošnje energije po čvoru pomoću OMNeT ++ 4.0 simulatora. Ovaj rad predlaže proširenje AODV protokola usmjeravanja energije unutar prijenosnih računara, kako bi se povećao vijek trajanja ad hoc mreže miješanjem broja čvorova, popunjenosti paketa redova i preostale energije duž ruta putanja energije kroz računar. Izvedba predložene metode uspoređena je s radom konvencionalnog AODV-a kroz simulacijske pokuse. Rezultati pokazuju da je predloženi protokol usmjeravanja temeljen na neizrazitoj logici poboljšao funkcionalnost i izvedbu konvencionalnog AODV protokola za usmjeravanje. Samim time proširio područje djelovanja metoda umjetne inteligencije preko energetike na informatičku opremu, u dijelu za koji je zadužena elektroenergetika.

Strategija upravljanja energijom ključna je za koordinaciju rada različitih pod komponenti hibridnog automobila. Prema projektu strategije upravljanja energijom serijskog hibridnog vozila, model automobila je uspostavljen na temelju komponente pogonskog sklopa i parametara vozila. Prijedlog za bolje upravljanje zasnovano na neuronskim mrežama su autori referata [67] predložili i obradili u svom istraživanju. Autori u referatu predlažu koncept projekta upravljanja energijom i strategiju upravljanja hibridnim električnim automobilima temeljenim na neuronskoj mreži i globalnoj optimizaciji. Kontrolna strategija može učinkovito kombinirati prednosti globalnog algoritma optimizacije i algoritma neuronskih mreža. Može se izvesti minimalna potrošnja goriva modela motora. U sklopu istraživanja provedena je simulacija i analiza poznatih uvjeta cestovnog ciklusa. Simulacijska platforma ADVISOR2002 korištena je za sekundarni razvoj. Simulirana je uspoređena strategija kontrole, strategija nadzora napajanja i strategija kontrole termostata.

Strategija ima snažan adaptivni kapacitet koji može dodatno poboljšati potrošnju goriva hibridnog automobila. Dinamička optimizacija provodi se pomoću dinamike

Za rješavanje problema koristi se dinamički algoritam programiranja i slijedno kvadratno programiranje (eng. Sequential quadratic programming - SQP) algoritam. Konačno, algoritam samoorganizirajući mape (eng. self-organizing map –SOM) se dalje optimizira na temelju globalne optimizacije. Ukratko, ova studija pruža strategiju globalne optimizacije upravljanja energijom koja se temelji na neuronskoj mreži. Ova strategija može pružiti optimizirani model motora, kako bi se osigurala baza podataka za daljnju optimizaciju osobina motora u budućnosti. Simulacijska analiza modela istraživanja, analiza optimizirane strategije upravljanja energijom i opća globalna optimizacija upravljanja energijom korištenjem platforme Matlab, rezultirali su velikom učinkovitošću strategije upravljanja zasnovanoj na neuronskim mrežama.

Jedno istraživanje koje su sproveli autori referata [68] daje uvid u do tada sve pokrivene aplikacije koje su umjetne neuronske mreže pokrile na polju vjetro elektrana. U referatu su prikazane najmodernije umjetne neuronske mreže (ANN) koje se primjenjuju u sustavima baziranima na energiji vjetra. Složenost ovih sustava raste, a metode i algoritmi kojima se osigurava njihova učinkovitost postaju sve robusniji zbog opsega podataka i raznolikosti varijabli. U radu su objašnjeni glavni modeli bazirani na ANN koji se primjenjuju u sustavima energije vjetra i njihove karakteristike. Razvijena je opsežna kompilacija metoda, algoritama i modela. Te su metode grupirane u četiri glavne kategorije. Izdvojeni su neki zaključci o svakoj kategoriji:

- Predviđanje i prognoza: osim popisa glavnih referenci, provedena je i usporedba pogrešaka u različitim modelima predviđanja. Pokazalo se da su neuronske mreže učinkovitije za kratkoročno predviđanje brzine vjetra, a hibridna metoda temeljena na ANN-u daje bolje rezultate za kratkoročna predviđanja od drugih klasičnih tehnika.
- Optimizacija projekta: raspravljeni su modeli bazirani na ANN za projektiranje. Ti se modeli ne fokusiraju samo na turbine na vjetar, nego i na karakteristike vjetro elektrana. U ovom području, najčešće korištene metode su ANFIS i neuronske mreže s povratnim širenjem (eng. Back propagation), budući da je potrebna visoka točnost a vrijeme računanja nije determinantni faktor.
- Detekcija kvarova i dijagnostika: U referatu se raspravlja o glavnim tehnikama za detekciju kvarova i dijagnostici vjetro agregata na temelju ANN. Većina metoda koje se temelje na ANN-u stvorene su za otkrivanje kvarova u prijenosnicima i ležajevima. Detekcija kvara ne zahtijeva brz proces računanja i stoga je glavni faktor točnost metode. U ovom području,

neuronske mreže za povratno širenje se uobičajeno koriste, jer obično daju točnije rezultate od ostalih metoda. Ponavljajuće (eng. Recurrent) ANN se koriste zato što dopuštaju da se nedavni neuspjesi uključe u strukturu putem procesa povratnih informacija. ANN u nenadziranom učenju (samoorganizirana karta i teorija adaptivne rezonancije) također se koriste, jer mogu otkriti anomalije bez korištenja povijesnih podataka o neuspjehu.

- Optimizacija upravljanja: U ovom referatu raspravljalo se o najvažnijim i najnovijim metodama temeljenim na ANN kontrolorima. Kontrolori zahtijevaju niske računske troškove, jer su potrebni hitni odgovori na iznenadne promjene stanja sustava. U tu svrhu, najčešće se primjenjuju ANFIS-i i radijalne bazične funkcije neuronskih mreža.

Ovi rezultati opisuju evoluciju tijekom posljednjih 10 godina, trenutno stanje i buduće trendove primjene ANN u vjetro elektranama. Autori su raspravljali o nizu izazova i tehnoloških nedostataka u vezi s tim primjenama. Naposljetku, cjelokupna tablica aplikacija koje obnašaju umjetne inteligencije metode raspravljane u ovom referatu od strane autora, je dana u tablici 3. Rezultati ovog rada mogu istraživači iskoristiti za otkrivanje mogućnosti novih istraživačkih linija otkrivanjem područja na kojima su potrebna poboljšanja. Neke od njih su predložene u nizu izazova. Ovi rezultati omogućuju projektantima komponenti vjetro agregata odabrati najprikladniju strukturu za svaki slučaj prema odgovoru različitih tipova ANN na određene zahtjeve. Pokazalo se da su ANN korisne za različite primjene i mogu se kombinirati s drugim alatima kako bi se povećao njihov doprinos hibridnim sustavima. Općenito, ovaj se rad može koristiti kao referentni vodič za one koji žele naučiti o korištenju naprednih tehnika u rastućem sektoru energije vjetra.

Tablica 2.3. Klasifikacijska struktura aplikacija umjetnih neuronskih mreža u vjetro elektranama [68].

Umjetne neuronske mreže i	**Predviđanje i prognoza**	brzina vjetra
		snaga vjetra
		drugi parametri
	Optimizacija projekta	turbina
		farma vjetro elektrana
	Prepoznavanje kvara i dijagnoza	mjenjač i ležajevi
		generator, primarna elektronika i elektronika
		rotor, noževi i hidraulika
		smanjivanje lažnih aktivacija alarma

	Optimalna kontrola	traženje točke maksimalne snage
		kut nagiba
		brzina vjetra
		reaktivna snaga
		izmjenjivač

U referatu [69], autori se osvrću na utvrđivanje stanja pametne mreže (eng. Smart Grid – SG) uz pomoć umjetne inteligencije metoda. Ovaj rad predstavlja novu metodu za procjenu stanja pametnih mreža (npr. naponi, gubitci aktivne i jalove snage) pomoću umjetnih neuronskih mreža (ANN). Predložena metoda koja se naziva SE-NN (procjena stanja pomoću neuronske mreže) može ocijeniti stanje u bilo kojoj točki pametnih mrežnih sustava, obzirom na promjenjivu prirodu opterećenja unutar mreže. Kako bi se pokazala učinkovitost predložene metode, primijenjena je na IEEE 33-bus distribucijskom sustavu s različitim rezolucijama podataka. Točnost predložene metode potvrđuje se uspoređivanjem rezultata s metodom točnog protoka snage. Predložena SE-NN metoda je vrlo brz alat za procjenu napona i ponovnog / aktivnog gubitka snage s visokom točnošću u usporedbi s tradicionalnim metodama. Predložena metoda koristi naprednu neuronsku mrežu za određivanje procjene stanja pametnih mreža. Postojeće metode protoka snage imaju vrlo dugo vrijeme izvođenja, dok predložena metoda procjenjuje stanje u bilo kojoj točki na brz i precizan način. Eksperimenti su provedeni na dva različita skupa treninga (200 i 1440 rezoluciji podataka). Predložena metoda uspoređena je s QBBFS metodom za validaciju. SE-NN ima sposobnost da brzo procijeni stanje pametne mreže s visokom stopom točnosti. Predložena metoda može biti koristan alat za operatore sustava za praćenje rada pametnih mreža u realnom vremenu. Autori još navode da ova metoda vrlo jednostavno se može aplicirati na simulaciju velikih distribucijskih sustava s obnovljivim izvorima energije, kao što su foto naponski i vjetro energetski sustavi.

Još je jedan referat [70] koji se osvrće na problematiku prikupljanja podataka iz SG, s naglaskom na stanje tijekova snaga. Praćenje sastavnica elektroenergetskog sustava jedan je od načina na koji se može ocijeniti status sustava, a u ovom konkretnom slučaju to je SG. Analize provedene na izlazu sustava praćenja, mogu pružiti važne informacije o stanju sustava i kretanjima njegovog stanja. Informacije iz sustava praćenja omogućene su putem senzorskog mjerenja. Razvoj sustava praćenja širokog je područja, stoga je važno znati da je on ključan za svjesnost situacije u pametnoj mreži. Ulaz iz takvog nadzornog sustava omogućuje sustavima kontrole širokog područja poduzimanje prediktivnih kontrolnih djelovanja, kako bi se sustav održao stabilnim tijekom

poremećaja. U ovom istraživanju korištena je višeslojna integrirana stanična neuronska mreža (CNN) za predviđanje procjene stanja različitih parametara u pametnoj mreži. Ovi različiti parametri se identificiraju ili predviđaju pomoću svakog sloja CNN-a. Predviđanje raznih parametara elektroenergetskog sustava odrađuje sustav praćenja širokog područja za pametnu mrežu. Predložen je upravljački sloj temeljen na dinamičkom stohastičkom optimalnom protoku snage (DSOPF), koji pruža pomoćne signale prediktivnog upravljanja sustavom.

Primjena informatičke i komunikacijske inteligencije učinkovito poboljšava kvalitetu praćenja i kontrole pametnih mreža. Međutim, ovisnost o informacijskoj tehnologiji također povećava osjetljivost na zlonamjerne napade. Autori referata [71] su u svojem istraživanju obradili nekoliko oblasti iz sigurnosti pametnih mreža kao što su: lažno utiskivanje podataka (FDI) koje napada integritet podataka, pojavljuju se kao ozbiljna prijetnja sustavu nadzora i prikupljanja podataka. U svom radu autori koriste tehnike dubokog učenja (eng. Deep Learning- DL), kako bi prepoznali značajke ponašanja FDI napada s povijesnim mjernim podacima i koristili zarobljene značajke za otkrivanje FDI napada u realnom vremenu. Na taj način naš predloženi mehanizam otkrivanja učinkovito promatra pretpostavke o mogućim scenarijima napada i postiže visoku točnost. Nadalje, autori su predložili optimizacijski model za opisivanje ponašanja jedne vrste FDI napada koji ugrožava ograničen broj državnih mjerenja elektroenergetskog sustava za krađu električne energije. Izvedbu predložene strategije ilustrirali su simulacijom pomoću IEEE 118-bus testnog sustava i IEEE 300-bus sustava. Autori su svoju metodu testirali kroz 4 studije slučaja:

i) Procijeniti učinkovitost predloženog mehanizma u stvarnom vremenu za otkrivanje FDI napada.
ii) Razmatranje scenarija u kojem postoje povremene greške u radu koje potencijalno rezultiraju odstupanjem mjerenja.
iii) Procjena skalabilnosti predložene sheme otkrivanja pomoću IEEE 300-bus sustava testiranja snage.
iv) Proučavanje stvarnih FDI napada uz pretpostavku da je krajnji cilj krađa električne energije.

U prva dva slučaja razmatran je utjecaj broja ugroženih mjerenja, razinu buke okoliša i prag detekcije za procjenitelja stanja vektora (eng. State vector estimator – SVE) na izvedbu sheme otkrivanja. Da bismo istražili skalabilnost sheme, autori u trećem slučaju koriste IEEE 300-bus sustav. Nadalje, prema modeliranju napada iz izravnih stranih plasiranja podataka u stvarnom svijetu, revidiraju svoj model napada FDI razmatrajući praktičnije ograničenje napada. U

simulacijama procjenjuju učinkovitost svoje metode otkrivanja usporedbom s onima utemeljene na ANN i metodi potpornih vektora (eng. Support Vector Machine-SVM). Rezultati simulacije pokazuju da je predložena shema autora otkrivanja otporna na različite brojeve mjera zlonamjernog napada, različite pragove detekcije metode potpornih vektora i neke razine buke okoline. Rezultati simulacije također pokazuju da predložena metoda detekcije može postići visoku točnost detekcije u prisutnosti povremenih grešaka u radu.

Originalno istraživanje su proveli autori referata [72], gdje obrađuju temu emisije plina CO_2, ali iz perspektive G20 zemalja i njihovih odnosa. Razumijevanje odnosa između emisija CO_2, potrošnje energije i gospodarskog rasta, pomaže zemljama da razviju energetske izvore i formuliraju energetske politike, kako bi poboljšale održivi razvoj. Cilj autora ovog istraživanja je bio razviti novi učinkovit model za analizu odnosa između tri gore spomenuta pokazatelja u zemljama skupine G20, pomoću modela ANFIS-a. Razdoblje od 1962. do 2016. godine je korišteno kao vremenski period uzorkovanja s modelima predviđanja koristeći stvarne podatke za predviđanje emisije CO_2 na temelju dva važna pokazatelja unosa, potrošnje energije i gospodarskog rasta. Ovo istraživanje je koristilo ANFIS kako bi se poopćile veze ulaznih i izlaznih pokazatelja, te kako bi se napravila predviđanja emisije CO_2. Eksperimentalni nalazi na skupu podataka o svjetskim razvojnim pokazateljima (WDI) iz stvarnog svijeta pokazali su da predloženi model učinkovito predviđa emisije CO_2 temeljene na potrošnji energije i gospodarskom rastu. Smjer međusobnih odnosa vrlo je važan iz perspektive ekonomske i energetske politike za ovaj međunarodni forum, jer su zemlje G20 prvenstveno usmjerene na upravljanje globalne ekonomije.

Eksperimentalni rezultati ovog istraživanja pokazali su da je predloženi model sposoban predvidjeti emisije CO_2 na temelju potrošnje energije i gospodarskog rasta. Modeli predviđanja su uspostavljeni u MATLAB-u i rezultati su postignuti. Kako bi formulirali modele predviđanja, ova studija je najprije koristila neizrazita pravila pomoću ANFIS-a iz WDI izvora online baze podataka. Sljedeća faza nakon formuliranja modela predviđanja je generaliziranje međusobnih odnosa ulaznih i izlaznih pokazatelja, kako bi se napravilo točno predviđanje emisija CO_2. Da bi se procijenio predloženi model i ispitala kompetentnost modela predviđanja ANFIS-a, MAE mjera se koristi za predviđanje emisije CO_2 kao outputa. Rezultat sustava neizrazitih pravila pokazao je da su povećanjem gospodarskog rasta i potrošnje energije u nekim zemljama emisije CO_2 porasle. Na primjer, u slučaju Argentine, povećanjem gospodarskog rasta s 8000 američkih dolara (USD) po glavi stanovnika na 12.000 američkih dolara, emisije CO_2 povećale su se s 2,5 tona po glavi stanovnika na 6 tona po stanovniku, a potrošnja energije povećala se s 1400 MWh na 1800 MWh po stanovniku. Rezultati MEA pokazali su da je prosječna veličina pogrešaka u skupu predviđanja

u zemljama skupine G20 bila između 0.0119% i 0.0732%. Međutim, rezultati MEA i sustava neizrazitih pravila pokazali su da se ANFIS može učinkovito koristiti za modeliranje i predviđanje emisije CO_2. Autori istraživanja vjeruju da se ovaj model može koristiti za pronalaženje mnogih drugih pokazatelja u ekološkim i energetskim područjima. Zaključeno je da je model ANFIS inteligentan u računanju i prikladan za predviđanje emisija CO_2 na temelju različitih pokazatelja. Ovaj se referat može učinkovito proširiti kako bi se razmotrio za druge pokazatelje koji utječu na emisije CO_2. U ovoj studiji, za predviđanje emisije CO_2, korištena su dva važna pokazatelja: potrošnju energije i gospodarski rast. Međutim, u budućim studijama, drugi pokazatelji trebaju biti korišteni, a neki od njih su: potrošnja električne energije, obnovljivi izvori energije, stanovništvo, financijska ulaganja, turizam, međunarodni turizam, energetski intenzitet, emisije CO2 u kućanstvima, izdaci za zdravstvo, gospodarska aktivnost, cestovni promet, prihodi, potrošnja nafte, ugljen potrošnja, otvorenost trgovine, strukturne promjene, mješavina goriva, izvoz i institucionalna kvaliteta, tehnička učinkovitost, industrijska struktura, prometna infrastruktura, korištenje interneta, potrošnja fosilnih goriva, vanjska trgovina, informacijska komunikacijska tehnologija, međunarodna trgovina, vanjskotrgovinski odnos, potrošnja goriva, ekološki varijable, oporezivanje ugljika, omjer zaposlenosti, urbanizacija, potrošnja hidroelektrične energije, okolišna regulativa, nuklearna energija, urbanizacija, izravna strana ulaganja, financijska nestabilnost, internacionalizacija, financijski razvoj, potrošnja otpada i gorivo, tehnološke inovacije, globalizacija, bogatstvo, stanovništvo, tehnologija, gustoća stanovništva, i intenzitet ugljika. Štoviše, pristup razvijen u ovom radu mogao bi se koristiti za pronalaženje rješenja za različite probleme predviđanja u domenama obnovljivih i neobnovljivih izvora energije. Nalazi ovog istraživanja dobiveni su korištenjem klasičnog modela ANFIS, a za modele predviđanja uspostavljena su off-line podešenja uređaja prema navedenoj metodi. Nadalje, kompetentnost predloženog modela klasičnim ANFIS modelom ograničena je određivanjem broja slučajeva za učenje ANFIS-a. Stoga postoji potreba za razvojem odgovarajućih pristupa inkrementalnom učenju, na način koji uzima u obzir nove podatke koji dolaze. Kao rezultat, možemo reći da će u budućnosti istraživači morati biti više uključeni u predlaganje metoda za ANFIS modele s inkrementalnim učenjem, na način koji će minimizirati vrijeme računanja u velikim skupovima podataka.

Razmatranje sigurnosti u razvoju bilo kojeg protokola namijenjenog bežičnim mrežama senzora (eng. Wireless Sensor Networks –WSN) je od vitalnog značaja. Autori referata [73] pokazuju kako zlonamjerni čvorovi mogu loše utjecati na usluge koje pružaju WSN-ovi i odvoditi mrežnu energiju od krajnjih korisnika. Uključivanje proaktivnih sigurnosnih rješenja osigurat će sigurno

usmjeravanje i ispravnu, uspješnu isporuku podataka uz produljenje životnog vijeka mreže. Navedeno istraživanje predstavilo je protokol za sigurnu neizrazitu energiju (eng. Secure-Fuzzy Energy Aware Routing - S-FEAR) za WSN-ove. S-FEAR poboljšava izvorni FEAR protokol primjenom sigurnosnih mehanizama za izgradnju energetski učinkovitog protokola za sigurno usmjeravanje, koji štiti mrežu od različitih vanjskih napada. Glavni cilj autora istraživanja je izgraditi sigurnu topologiju među mrežnim čvorovima, koja će se koristiti za siguran prijenos podataka. Predložen je siguran model za osiguranje protokola FEAR. Ovaj je model analiziran analitički i empirijski. Autentifikacija i integritet podataka, razmatrani su u ovoj studiji i postignuti primjenom CBC-MAC ili ECDSA na temelju simetričnih i asimetričnih pristupa.

Simulator komunikacijske mreže Qualnet 5.0, korišten je za procjenu utjecaja napadača na topologiju mreže i proces usmjeravanja u FEAR, S-FEAR (MAC) i S-FEAR (DS) protokolima. Osim toga, procijenjeni su troškovi napada na FEAR i S-FEAR protokol korištenjem različitih simulacijskih pokusa. Nakon primjene sigurnosnih shema, rezultati pokazuju da CBC-MAC košta 0,00064% mrežne energije, a ECDSA košta oko 0,0091%. Iako je taj trošak potreban za postizanje potrebnih sigurnosnih zahtjeva, rezultati također pokazuju da neki napadi koštaju mrežu oko 4,7 puta više od troškova postizanja tih zahtjeva. Štoviše, rezultati pokazuju da razmatranje samo ograničenja resursa čvorova senzora nije dovoljno za razvoj učinkovitog protokola usmjeravanja. Zaštita mreže od različitih usmjerenih napada je važna, jer napadači mogu iscrpiti mrežnu energiju tijekom vremena. Zahtjevom provjere autentičnosti i integriteta podataka tijekom izgradnje, isključuju se svi napadači iz konstruirane topologije mreže. Stoga se ova topologija može koristiti za siguran prijenos podataka, što će jamčiti uspjeh usluga koje se odvijaju preko WSN-ova. Autori navode da S-FEAR može uključivati inteligentniju uslugu koja razmatra vrstu aplikacije, osjetljivost podataka, preostalu mrežnu energiju i vrstu sigurnosnih tehnika u smislu složenosti, sigurnosne snage i latencije prije nego što se odluči u stvarnom vremenu koju sigurnosnu tehniku primijeniti. Osim toga, S-FEAR se također može uhvatiti u koštac s internim napadačima. To zahtijeva dodatnu uslugu otkrivanja upada koja bi mogla koštati mrežu nekih svojih resursa; to je problem koji vrijedi istražiti u budućim studijama. Osim toga, drugi postojeći energetski učinkoviti protokoli za WSN mogu se analizirati iz sigurnosne perspektive. Osim toga, mogu se predložiti i procijeniti novi protokoli koji rade u kombinaciji sa umjetne inteligencije metodama, kao što je na ovom istraživanju to bila neizrazita logika, kako bi se razmotrile njihove sigurnosne značajke tijekom rane faze projektiranja, kao i njihov utjecaj na WSN-ove.

Autori referata [74] su na opširan i širok način obradili temu upravljanja energijom iz perspektive korisnika energetskog sustava. Osim novosti semantičkog pristupa, rješenje predstavlja i promjenu

koraka poticanjem korištenja metoda umjetne inteligencije od strane upravitelja postrojenja (eng. Facility Manager –FM), poštivanjem uloge upravitelja postrojenja u procesu odlučivanja i korištenjem dostupnog korisničkog sučelja, a rješenje je uspješno implementirano u javnom sektoru zgrada u Nizozemskoj, što predstavlja ozbiljan pomak u odnosu na dosadašnja istraživanja gdje se završavalo sa testiranjem modela. U ovom referatu raspravljalo se o stanju tehnike i prethodnim istraživanjima unutar svakog konceptualnog sloja upravljačkog sustava energije zgrade (eng. Building Energy Management Systems – BEMS). Zatim je uveden novi BEMS, nakon čega su raspravljene komponente i metodologija svakog od njegovih slojeva sa mogućnošću integracije neizrazite logike. Najprije je uveden semantički srednji sloj kao ključna novost, a objašnjene su njegove prednosti inter operacije uređaja i sustava u zgradi na način koji se može proširiti, ponoviti i priuštiti. Metodologija uspostave antologije domene usklađena s međunarodnim standardima, predstavljena je korištenjem OntoCAD-a za popunu proširene verzije IFC modela podataka. Drugo, rješenje koje uključuje umjetne inteligencije metode je objašnjeno kao kombinacija inteligentnih tehnika generiranja pravila i neizrazitog rasuđivača (FL). Prikazana je kombinirana upotreba pravila generiranih putem rudarenja podataka i simulacijske optimizacije putem integracije SWRL ontologije. Konačno, istraženo je korisničko sučelje, objašnjene su njegove interakcije s pozadinskim praćenjem osobina i zonskih osobina i optimiziranim prijedloženim pravilima. Također se raspravljalo o softverskim odlukama WebGL-a i HTML5 na strani klijenta, kako bi se omogućilo postavljanje platformi bez potrebe za dodatnim korisničkim preuzimanjima, a da se pritom još uvijek pružaju 3-D sučelja i mnoge koristi razvojnih programera za daljnje sazrijevanje rješenja. Kroz jednostavnu grafičku sliku semafora, FM mogu odrediti zone koje zahtijevaju pažnju, a pop up prozori upozoravaju FM kada se napravi novi prijedlog za uštedu energije. Ova vrsta značajke bila bi idealna za mobilnu integraciju, tako da se FM može upozoriti na terenu. Rješenje je ispitano u simuliranim i realnim zgradama, uz ohrabrujuće rezultate u oba slučaja. Oba slučaja pokazala su značajne uštede energije tijekom jednog dana i nekoliko zimskih mjeseci, pri čemu je stvarna zgrada u prosjeku imala oko 25% uštede energije. Iako su ovi rezultati vrlo pozitivni i služe kao dokaz koncepta, sada je potreban daljnji rad kako bi se prikazala replikacija rješenja u drugim zgradama. Ostale značajke koje su od interesa za razvoj uključuju korištenje čarobnjaka za pomoć FM-u u zadacima i pružanje višejezične podrške za omogućavanje primjene u svim zemljama, kao što je vođenje FM angažmana s alatom kroz atraktivno i intuitivno sučelje što je ključni doprinos referata. Dok su pojedine komponente korištene u predloženom sustavu pružale dovoljan učinak, ključni tekući posao uključuje daljnju optimizaciju svakog od njih. Primjerice, provedeni ANN model mogao bi se zamijeniti s naprednijim modelom dubokog učenja, a njegovi hiper parametri mogli bi se dodatno optimizirati putem gustog pretraživanja

mreže ili slično. Obzirom na uspješnu primjenu rješenja i identificirane ključne novosti, ovaj rad demonstrira potencijal pristupa temeljenog na oblaku za obnovu BEMS rješenja pomoću semantičkog middlewarea kao komponente integracije sustava, uz proces pregovaranja između čovjeka i računala, naprednih metoda umjetne inteligencije i privlačno korisničko sučelje. Predstavljeni BEMS mogu stoga poslužiti kao referentna točka za slična rješenja u smislu potencijala za uštedu energije, smanjenja ulaganja unaprijed kroz integraciju sustava, kao i ublažavanje logistike i odgovornosti u vezi s kontrolom sustava zgrada.

Rješavanje problema ocjenjivanja i rangiranja potencijalnih dobavljača postalo ključni strateški cilj za poslovne tvrtke. Razvojem inteligentnih i automatiziranih informacijskih sustava u eri informacija, raste potreba za učinkovitijim metodama donošenja odluka. Metoda VIKOR razvijena je kako bi se riješili problemi donošenja odluka s višestrukim kriterijima (eng. Multiple Criteria Decision Making -MCDM) s proturječnim i neusporedivim kriterijima, uz pretpostavku da je kompromis prihvatljiv za rješavanje sukoba. S druge strane, objektivne težine koje se temelje na Shannonovom konceptu entropije, mogu se upotrijebiti za reguliranje subjektivnih težina koje donose donositelji odluka ili čak uzimanje u obzir mišljenja krajnjih korisnika. U referatu [75] autori tretiraju odabir dobavljača kao problem grupnog odlučivanja s višestrukim kriterijima (eng. Group Multiple Criteria Decision Making - GMCDM) i dobivamo mišljenja donositelja odluka u obliku lingvističkih pojmova. Zatim se ti lingvistički pojmovi pretvaraju u trapezoidne neizrazite brojeve, koristeći funkcije pripadnosti uz pomoć FL. Metoda VIKOR proširena je mehanizmom izdvajanja i primjene objektivnih težina temeljenih na Shannonskom konceptu entropije. Konačni rezultat dobiven je sljedećim koracima koji se temelje na faktorima R, S i Q. Predložen je numerički primjer za ilustraciju primjena predložene metode. VIKOR je koristan alat u donošenju višekriterijskih odluka, a dobiveno kompromisno rješenje bi moglo biti prihvaćeno od donositelja odluka, jer osigurava maksimalnu skupinu korisnosti većine, te minimalno pojedinačno pomanjkanje. U spomenutom referatu autori su predložili proširenje VIKOR-a koji podržava subjektivne i objektivne težine sa FL, pri čemu se subjektivne težine dobivaju izravno od donositelja odluka, dok se objektivne težine određuju na temelju Shannonove entropije.

Iako nije polje elektroenergetike, zanimljivo istraživanje su imali autori referata [76] gdje se obrađuje tema iz industrije obrade metala. Proizvodnja željeza i čelika ključna je industrija za većinu industrijskih djelatnosti, a samim time se u njoj troši ogromna količina električne energije. Utjecaj učinkovite kontrole procesa na smanjenje troškova i energije, učinio je proces kontrole jednim od glavnih problema ove industrije. Proizvodnja željeza i čelika trebala bi se uglavnom oslanjati na nove integrirane proizvodne procese kako bi se poboljšala produktivnost, smanjila

potrošnja energije i održala konkurentnost na tržištu. U većini čeličnih tvrtki, tehnike planiranja proizvodnje i raspoređivanja su u osnovi ručne tehnike s malo kompjutorizirane podrške odlučivanju. Te se ručne tehnike uglavnom temelje na znanju i iskustvima onih stručnjaka koji su godinama radili u tvornici. Štoviše, proizvodnja čelika je vise stupanjski proces, logički i geografski raspodijeljen, koji uključuje različite proizvodne procese. Također, u klasifikaciji čelika, operator mora odrediti količinu aditivnih materijala u procesu proizvodnje čelika. Zbog navedenih razloga potreban je sustav za automatizaciju čelika kako bi se predstavila distribucija i integracija u ovoj industriji. Ekspertni sustav neizrazitog više-agenta, tj. FL, može omogućiti takve aktivnosti.

Ovo istraživanje predlaže višestruki ekspertni sustav koji uključuje tri različite vrste agenata:

- Agent inicijatora: Pruža početne funkcije pripadnosti i centre skupova za agenta.

- Agent skupa: stvara početne centre klastera za obuku ANFIS-ovih agenata.

- ANFIS agenti: Korištenjem ANFIS-a možemo selektirati ne „*ako-onda*“ pravila dobivena od ljudskog stručnjaka za opisivanje ulazno-izlaznog ponašanja složenog sustava. Međutim, ako ljudska ekspertiza nije dostupna, još uvijek se mogu postaviti razumne funkcije pripadnosti i započeti proces učenja, kako bismo generirali postavljena neizrazita pravila za približavanje željenog skupa podataka. Rezultati pokazuju da predloženi sustav može identificirati količine aditiva za različite klase čelika. Rezultati također pokazuju da Multi-agent ekspertni sustavi mogu učinkovito se primjenjivati u proizvodnji čelika.

Kvadrotori su nelinearni sustavi koje mogu kontrolirati ljudski stručnjaci. Budući da su matematički modeli kvadrotora prilično složeni, stručno znanje može biti jedan od načina da se dođe do rješenja za kontroliranje kvadrotora. Međutim, ljudski stručnjaci povremeno prave greške, pa neka lingvistička pravila korištena u kontroloru mogu biti lažna ili suvišna. Dakle, neizrazita logika tipa 2(T2FL) optimizirana od strane ANFIS-a, koja se može nositi s nesigurnostima, može se primijeniti za kontrolu kvadrotora [77]. ANFIS može optimizirati broj jezičnih pravila, i domena funkcija pripadnosti može se automatski prilagoditi. Osim toga, ANFIS bi također trebao biti u stanju identificirati loša pravila, tako da digitalni sustav (mikro-kontrolor) mogu smanjiti računske resurse potrebne za primjenu T2FL-a. Projektirani kontrolor može postići izvrsne eksperimentalne rezultate kada je smanjen ANFIS sustav. Dodatnoj složenosti u kontroloru neizrazite logike dodan je šumski signal u petlji za kontrolu položaja za kvadrotor. Osim toga, ilustrirana je usporedba između neizrazitog logičkog kontrolora tipa 2, podešenog od strane

stručnjaka i Fuzzy Logic tipa 2 optimiziranog pomoću ANFIS-a. Eksperimentalni rezultati potvrdili su dobar odgovor dostignut kada se koristi fuzzy logika tipa 2, optimizirana od strane ANFIS-a. Kada je neizraziti kontrolor tipa 2 podešen od strane stručnjaka, tranzicija može biti glatka za buku srednje razine, jer se broj pravila može prilagoditi u određenim zonama, ali ne mogu tolerirati visoku razinu buke i odgovor kada je dodan parametar koji tretira signal kao da nema buke, slično kao kontrolor podešen od strane ANFIS-a. Računalni resursi potrebni u kontroloru podešenom od strane ANFIS-a su najniži. Stoga je kontrolor koji je ugašen od strane ANFIS-a dobra alternativa, jer može tolerirati visoke razine buke.

2.3 Primjene metoda umjetne inteligencije u otkrivanju otočnog rada

Ovo poglavlje objedinjuje sve osnovne principe otkrivanja otočnog rada distribuiranih izvora koji su pogodni za analizu i primjenu, kako na testnom modelu, tako i u praksi kroz određene uvjete pripreme. Također navodi prednosti i mane pojedine tehnike otkrivanja, ali otvara prostor za petu skupinu metoda. Do sada su bile prisutne 4 skupine prepoznavanja otočnog rada distribuiranog izvora: aktivne, pasivne, hibridne i komunikacijske metode. Svaka od ponuđenih skupina ima svoje prednosti i mane, a to će biti detaljno prezentirano u poglavlju 4. Ona skupina koja se korištenjem umjetne inteligencije metoda nameće, te donosi prednosti bez mana svih ostalih postojećih skupina, jeste otkrivanje otočnog rada korištenjem umjetne inteligencije metoda, čime se ova disertacija bavi. U slijedećem pod poglavlju će biti prikazan pregled literature koja se bavi isključivo prepoznavanjem otočnog rada distribuiranog izvora korištenjem umjetne inteligencije metoda, s namjerom da se stekne uvid koliko je polje pokriveno sa konkretnim uradcima, te koliko ti uradci pokrivaju standarde propisane za otočnu zaštitu, te kako se pojedine metode snalaze u spomenuta tri parametra: zone ne detekcije, vrijeme detekcije i točnost.

Autori u referatu [78] istražuju mogućnost razvoja učinkovite univerzalne metode detekcije otočnog rada, koja se može primijeniti i na izmjenjivaču i na sinkronom distribuiranog izvora. Predložena metoda se oslanja na skupinu značajki, iz izmjerenih podataka simuliranih za obje vrste distribuiranih izvora, od kojih su odabrane najbolje značajke za otkrivanje otočnog rada. Tehnika klasifikacije slučajnim šumama (eng. Random Forest - RF) koristi se za otkrivanje otočnih i ne otočnih situacija s ciljem minimiziranja zone ne detekcije, kao i izbjegavanja neželjenog isklopa distribuiranog izvora tijekom ne-otočnih uvjeta. Slučajevi otočnih i ne-otočnih slučajeva generirani su za IEEE 34-bus sustav i korišteni su za treniranje i testiranje predložene tehnike. U radu je korištena višestruka unakrsna validacija kako bi se ispitala točnost predloženog algoritma za otkrivanje. Rezultati pokazuju da predložena metodologija ima nultu zonu ne otkrivanja, visoku

točnost i brz odziv kada se primjenjuje na obje vrste distribuiranih izvora, neovisno o veličini otočnog rada. Među ispitivanim pristupima klasifikacije, RF tehnika se pokazala kao najučinkovitiji pristup za predloženu metodu otkrivanja otočnog rada. Dvadeset jedna značajka koristi se u svrhu otkrivanja i identificiranja stanja rada distribuiranog izvora, dok se postižu male zone koje se ne mogu detektirati i izbjegavanje neugodnog okidanja zbog drugih događaja koji nisu otočni rad. Te značajke su izvađene iz valnog oblika napona i frekvencije na točki zajedničkog spajanja-u ciljanog distribuiranog izvora. Tada se pomoću ovih značajki klasifikator metode slučajnih šuma obučio i testirao za mjerenje njegove učinkovitosti i točnosti za otkrivanje otočnog rada. Nadalje, testirani su jednostruki i višestruki distribuirani izvori, kako bi se testirao klasifikator pod različitim uvjetima. Za obje vrste distribuiranog izvora utvrđeno je da je RF najbolji klasifikator za otkrivanje uvjeta otočnog rada zbog dva glavna razloga. Prvo, ona je nadmašila sve ostale klasifikatore s prosječnom točnošću od 99% i nula zone ne detekcije za obje vrste distribuiranih izvora. Drugo, izuzetno je brzo otkrivanje otočnog rada, što je vrlo važan čimbenik u odabiru tehnike otkrivanja otočnog rada.

U referatu [79] autori predlažu novu metodu pasivne detekcije otočnog rada na temelju ANN, korištenjem zona bez detekcije, obzirom na različite distribucijske sustave i radne uvjete distribuiranih izvora. Rezultati su pokazali da predložena metoda predstavlja odgovarajuću izvedbu zbog intrinzičnih karakteristika ANN (za identifikaciju uzoraka, tj. sposobnost ANN da joj je motivacija samo ponašanje pojave koju modelira). Važna karakteristika predloženog algoritma je da ovisi samo o uzorcima napona izmjerenim na sabirnicama distribuiranog izvora. Osim toga, autori dalje predlažu postupak odabira podataka kako bi proces edukacije ANN bio učinkovitiji. U istraživanju je primijećeno da učinkovitost metode jasno ovisi o neravnoteži aktivne snage otočnog sustava. Za procjenu predloženih različitih ANN-a korišteni su vremena sa i bez detekcije. Općenito, uočeno je da što je manja neravnoteža snage, to je otkrivanje otočnog rada duže traje. Od testiranih ANN-a, najbolje rezultate postigla je ANN sa 128 mjerenih uzoraka. Ova ANN je dala 99,88% uspješnih rezultata za vrijeme detekcije od 2 sekunde, 94,71% uspjeha za 1 sekundu i 92,91% za 0,5 sekunde, čak i obzirom na najteže radni uvjeti za otkrivanje otočnih situacija, tj. niska neravnoteža radne snage. Međutim, postoje neke situacije u kojima su izvedbe obje ANN (ANN64 i ANN128) bile vrlo slične. U takvim slučajevima, korištenje ANN64 može biti korisno ako je problem u računanju. Konačno, robusnost metode može se provjeriti primjenom na nekoliko ne-otočnih poremećaja, gdje su brzine rada bile značajno niske. To se događa zbog parametra osjetljivosti koji je uveden u metodu, gdje se događaj otočnog rada otkriva u 6 ciklusa otočnih uzoraka, unutar 12 uzastopnih ciklusa.

Istraživanje autora referata [80] predstavlja pregled različitih naprednih tehnika obrade signala i računalnih tehnika umjetne inteligencije za otkrivanje poremećaja, koji prethodi otočnom radu u distributivnoj mreži, koji ima distribuiranu proizvodnju. Različite tehnike pasivnog praćenja navedene pojave, kao što su tehnike pod/nad naponske i pod/nad frekvencijske zaštite, detekcija pomaka vektora faznih napona, mjerenje harmonika, nesimetrije napona itd., detaljno se razmatraju kao kriterij za detekciju otočnih pogona distribuiranog izvora. Nadalje, napredne tehnike obrade signala i tehnike metoda umjetne inteligencije razmatraju se radi otkrivanja cilja i uspoređuju se s klasičnim pasivnim tehnikama. Istaknuto je da obrada signala i tehnike zasnovane na metodama umjetne inteligencije, omogućuju brže otkrivanje s minimalnom zonom ne detekcije. Primjećuje se da su te tehnike robusnije i fleksibilnije u rješavanju složenih nelinearnih sustava. Naposljetku, prikazana je usporedba između različitih metoda otkrivanja otočnog rada, kako bi se znale relativne prednosti i mane u tablici 4.

Tablica 2.4. Usporedba vremena otkrivanja otočnog rada umjetne inteligencije metoda [80]

Tehnika otkrivanja otočnog rada	**Vrijeme otkrivanja otočnog rada [s]**
Kontinuirane valne transformacije (CWT)	0.800
Diskretne valne transformacije (DWT)	0.050
Neizrazita logika (FL)	0.070
Umjetne neuronske mreže (ANN)	0.075
ANFIS	0.062
Metoda potpornih vektora (SVM)	0.040
Stablo odlučivanja (DT)	0.041

Kako se može vidjeti iz prezentiranih rezultata, tehnike zasnovane na metodama umjetne inteligencije i maju znatno kraće vrijeme detekcije od klasičnih metoda čije vrijeme uglavnom se kreće oko 100 milisekundi.

U referatu [81] i [82] je prikazana metoda otkrivanja novih slučajeva otočnog rada distribuiranog izvora, uz pomoć neizrazite logike. Algoritam prati promjene predloženih triju parametara i detektira operacije otočnog rada korištenjem FL pravila. Gubitak mrežnog napajanja temelji se na više kriterijskom algoritmu za distribuirane izvore, koji su međusobno povezani distribucijskom

mrežom. Predložena metoda s radijalnom distribucijskom mrežom, s distribuiranim izvorima rotirajućeg tipa, te različite vrste opterećenja, verificirana je i ocijenjena unutar referata. Da bi se pokazao učinak algoritma gubitka mrežnog napajanja, potreban je niz studija. Simulacijska ispitivanja provedena su pomoću programa EMTP-ATP. Simulirana je specifična vrsta otočnih uvjeta - uz zanemarivanje promjena opterećenja distribuiranog izvora, nakon prelaska u otočni rad. Rezultati ispitivanja pokazuju da su predloženi kriteriji i algoritam sposobni ispravno detektirati otočne i ne-otočne uvjete, uz dobru selektivnost. Autori provode daljnja istraživanja o otkrivanju otočnog rada. Oni namjeravaju usvojiti samo podešavanje neizrazite postavke, faktora težine praga okidanja, kako bi poboljšali FL rad u ovu svrhu.

Autori referata [83] predlažu inteligentnu metodu detekcije otočnog rada distribuiranog izvora na temelju ANN i PSO algoritma. Parametri optimalne ANN mreže kao što su težine i prenaponi izvedeni su pomoću PSO algoritma. Učinkovitost MLP-PSO, RBF-PSO, RBF i PNN uspoređena je u cilju otkrivanja otočnog rada u kojem se nalazi distribuirani izvor. Glavni cilj predložene metode je smanjenje zone ne detekcije-je što je moguće manje. U metodi se koristi frekvencija za ROCOF (eng. Rate of Change od Frequency- ROCOF) i snaga za ROCOAP (eng. Rate of Change of Active Power - ROCOAP) signala na točku zajedničkog spajanja (eng. Point of Common Coupling -PCC) za pet ciklusa, kao ulaznih podataka u ANN-a. Predložena metoda vrednuje se brojnim testnim slučajevima. Potvrđeno je da je točnost MLP-PSO za otkrivanje otočnog rada viša od ostalih metoda. Točnost MLP-PSO s dva neurona u skrivenom sloju je gotovo 100%. Simulirani rezultati potvrđuju ovu činjenicu da MLP-PSO smanjuje zone ne detekcije i povećava točnost ANN u slučaju otkrivanja otočnog rada distribuiranog izvora. Osim toga, kako bi se postigla maksimalna točnost u slučaju bilo kakve promjene u strukturi mreže, ANN se neprestano uči. Zapravo, proces učenja ANN od strane PSO-a provodi se kao realno vrijeme za prilagodbu sljedećim promjenama u strukturi mreže.

3. OTOČNI RAD DISTRIBUIRANIH IZVORA ENERGIJE

Svrha ovog poglavlja jeste sažeto i jasno prikazati pojavu otočnog rada distribuirane proizvodnje u distribucijskoj mreži, s naglaskom na analizu parametara mreže u trenutku i nakon samog otočnog rada. Obuhvatiti sve pojave i analizirati ih pomoću neke metode ili programskog alata u jednoj doktorskoj disertaciji je nemoguće. U ovom radu je naglasak postavljen na frekvenciju (*f*), napone (*U*) i struje (*I*).

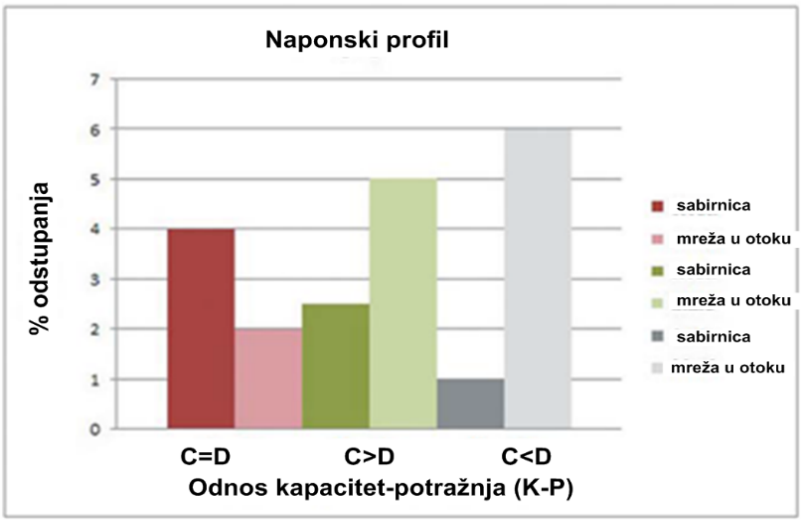
Da bi se bolje razumjela pojava otočnog rada distribuiranog izvora, potrebno je otočni rad promatrati kroz nekoliko aspekata vezanih za napajanje električnom energijom, kao što su pouzdanost, kvaliteta i zaštita. Jedna od glavnih prednosti distribuiranih izvora jeste mogućnost visokog udjela distribuiranih sustava u otočnom načinu rada. Otočni rada je situacija u kojoj distribucijska mreža postaje električno izolirana od ostatka elektroenergetskog sustava, zbog neke vrste poremećaja kao što je isklop zbog kvara izvoda koji napaja distribuirani izvor. U ovom slučaju, mreža ostaje pod naponom od strane distribuiranog izvora, što uzrokuje povećanje pouzdanosti distribucijskog sustava [84]. Izolirani rad distribuiranog izvora kontroverzna je tema razmatra između distribucije i kupaca električne energije. To neslaganje proizlazi iz nedostatka propisa između oba tijela. Doista, kupci električne energije vjeruju da je njihova potreba za električnom energijom prioritetnija od pravila distribucije kojima se ODS mora povinovati i obratno. ODS smatra da je njihova djelatnost iznad pojedinačnih želja kupaca. Naravno, postoji visok rizik od kvara na opremi, kao i sigurnosni problemi koji utječu na sigurnost operatora ODS-a i operatora na distribuiranim izvorima koji rade u otočnom pogonu. [85]. ODS-a se obično protivi svakom postojanju otočnom pogona distribuiranog izvora, ako uzrokuju prekid veze s glavnim opskrbljivačem distribuiranog izvora, to jest mrežom. Međutim, za kupce koji su vlasnici distribuiranog izvora stanje otočnog rada može predstavljati kontinuiranu nastavak proizvodnje pod nekim uvjetima smanjenja snage, većim padovima napona, varijacija frekvencije i ograničenih snaga proizvodnje. Što znači manje ekonomske gubitke u usporedbi s onima koji proizlaze iz povećanih padova napona ili nestanak napajanja [86] [87]. Autori referata [88] prikazali su učinke otočnog rada distribuiranih izvora na distribucijske mreže, procjenjujući trenutne promjene opterećenja koje se odnose na snage distribuiranih izvora i potražnju za opterećenjem, dok je na snazi otočni rad distribuiranog izvora.

Analiza otočnog rada je urađena za dva scenarija:

1) **Planirani otočni rad** - Namjerni otočni rad je planirano stanje u kojem se dio sustava napaja putem jednog ili više lokalnih izvora koji su električno odvojeni od mreže [89].

Procjena stanja mreže izvršena je u nekoliko koraka. U prvoj fazi, namjerno je napravljen pokušaj otočnog rada, s naglaskom na promjene uzrokovane strujama opterećenja i naponskim profilima.

2) **Neplanirani otočni rad** - Nenamjerni otočni pogon pojavljuje se otvaranjem prekidača koji se nalazi prema izvornoj distribucijskoj mreži. On ostavlja dio sustava prema napojenim distribuiranih izvora povezanim u taj otočni dio mreže. Otvaranje prekidača obično je rezultat djelovanja sklopnih aparata glavnog dovodnog uređaja zbog pojave kvara [90]. Kao posljedica toga, jedan od najznačajnijih nedostataka rada u otočnom pogonu odnosi se na varijaciju frekvencije. Slika 3.1 prikazuje varijacije napona u odnosu na vrijeme nakon što je uklonjen kvar na distribucijskoj mreži, uzrokujući otočni rad mreže na koje je priključen samo distribuirani izvor. Tijekom analize ovog slučaja opterećenje iznosi mnogo manje nego što je snaga distribuiranog izvora. Nakon kvara u mreži, sustav zaštite odmah djeluje, što rezultira povećanjem razine frekvencije zbog otočnog rada.



Slika 3.1. Profil napona prije i poslije nastupa otočnog rada [88].

Da bi se imao bolji uvid u utjecaj otočnog rada na prilike tokova snaga u distribucijskoj mreži samog otočnog rada, potrebno je prikazati struje u tri scenarija:

a) Snaga distribuiranog izvora jednaka teretu mreže u otočnom radu,
b) Snaga distribuiranog izvora veća od tereta mreže u otočnom radu,
c) Snaga distribuiranog izvora manja od tereta mreže u otočnom radu.

U otočnom pogonu, energija koja snabdjeva opterećenja mora biti veća od vlastitih potrošnje u otočnom radu. Inače, veća je vjerojatnost da će niska proizvodnja distribuiranog izvora uzrokovati preopterećenje u dijelu mreže koje utječe na način rada iste, a koje je izolirano od glavnog dovoda.

Uspoređujući vrijednosti toka snage opterećenja, dok je bio otočni rad , kao i za vrijeme kada to nije bio, odvijalo se s razinama snage koje su bile gotovo jednake traženom opterećenju. Neki se problemi javljaju za one snage manje od npr. 130 kW, pod pretpostavkom da je snaga izvora 100 kW, što onda podrazumijeva preopterećenje samog distribuiranog izvora. Drugi problem je kada je snaga distribuiranog izvora veći od snage opterećenja.

U drugom slučaju razina potrošnje je npr. 540 kW (P_{DG}=100 kW), a formira se otočni pogon na čvoru koji odvaja dio mreže koji je spojen sa distribuiranim izvorom. Vrijednosti struja opterećenja koje prolaze kroz različite grane tijekom rada u izoliranom režimu gotovo da su jednake situaciji kada je potrošnja jednaka snazi distribuiranog izvora. Primijećeno je da, ako je opterećenje manje od snage distribuiranog izvora energije, struje opterećenja su vrlo slične nominalnim kada je snaga glavnog čvora blizu maksimalnog opterećenja. Inače bi došlo do preopterećenja distribuiranog izvora.

U trećem ispitnom slučaju, distribuirani izvori je smješten u čvoru gdje je opterećenje manje od njegove snage. Osim toga, ima najveću razinu opterećenja mreže 90 kW, što je manje od ukupne snage distribuiranog izvora. Za snage proizvodnje niže od snage opterećenja, struje opterećenja nisu dobro usklađene. S druge strane, smanjile su se njihove vrijednosti u odnosu na nominalne, koje napajaju samo glavne potrošače. Te su se razlike mogle pojaviti zbog npr. velikog broja čvorova koji su spojeni na tom području, kao i zbog velikih udaljenosti između opterećenja od izvora napajanja.

Profili napona analizirani su u svakom pojedinom čvoru koji pripada zoni u kojoj nastaje otočni pogon i uspoređuje se s nominalnim vrijednostima. Najkritičniji slučajevi pojavili su se kada snage opterećenja prelaze i/ili su gotovo iste kao snaga distribuiranog izvora. Tako su vrijednosti napona dosegle maksimum od 6% i 5% odstupanja (u apsolutnoj vrijednosti uzimajući kao referentni napon od 1 p.u.), u slučaju a), odnosno c). Uključivanjem distribuiranog izvora sa snagom iznad vrijednosti snage opterećenja, naponske veličine se približavaju ka 1 p.u., dostižući maksimalne razlike do 2%, kao i poboljšanje maksimalnog odstupanja od 4% pojavljuje se kada je glavni izvod uključen.

Distribuirani izvori i mogućnost otočnog rada zajedno su nepoželjan i nefunkcionalan način rada kada su razine snaga izvora i snage opterećenja relativno blizu jedno drugome zbog mogućeg djelovanja APU-a na kvarove na vodu. Potrebno je uzeti u obzir da ni pod kakvim okolnostima razina opterećenja ne bi trebala biti veća od snaga distribuiranog izvora, ako se želi raditi u otočnom rada. Tako se izbjegava pogoršanje naponskih prilika i neučinkovitost distribuiranih izvora. Također, ne preporučuje se slučaj kada je opterećenje mnogo manje od snaga distribuiranog izvora, kako bi se izbjegla bilo kakva vrsta problema s preopterećenjima ili oštećenja mreže zbog loše kvalitete električne energije. Kada se radi na nenamjernom otočnom pogonu, jedan od najznačajnijih nedostataka odnosi se na varijacije frekvencije, upravo kada je potražnja opterećenja mnogo niža od snaga distribuiranog izvora. Pod tim uvjetima, frekvencija naglo raste. Namjerna operacija otočnog pogona mogla bi biti potpora mreži dok se ne eliminiraju prolazni kvarovi ili održavanje jedne ili više zona mreže, jer pridonosi izbjegavanju prekida opskrbe el. energije, bez pritiska na osoblje ODS-a.

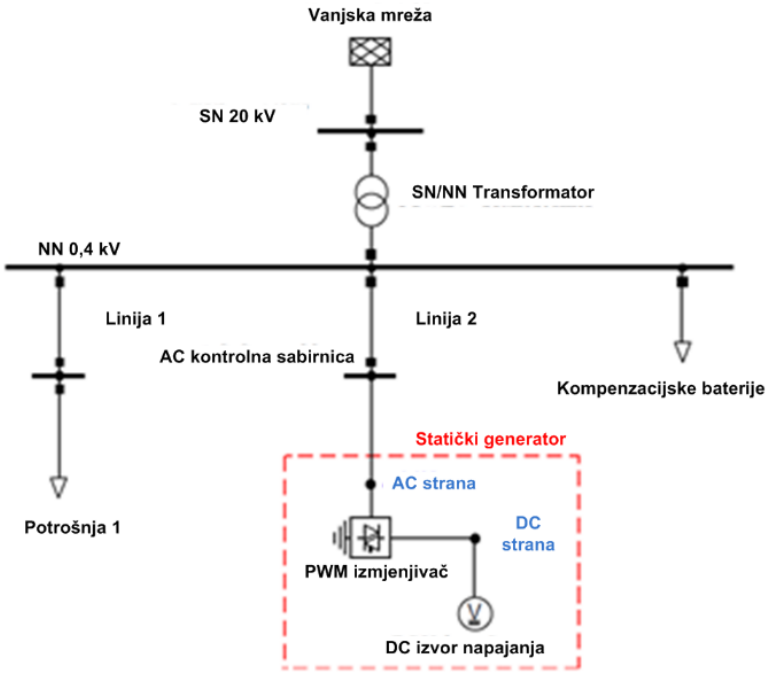
U mnogim zemljama nedavno su odobrena različita mrežna pravila s definiranim uvjetima povezivanja za pasivne i/ili aktivne mreže i njihovih krajnjih korisnika. Na europskoj razini, tehničke specifikacije CENELEC TS 50549-1 i CENELEC TS 50549-2 [91][92] sadrže preporuke za priključenje proizvodnih postrojenja, s strujom iznad 16 A, na distribucijske mreže na niskim naponima (NN) i srednjem naponu (SN). Nadalje, mikro-postrojenja s nazivnom strujom ispod 16 A spojena na NN mreže regulirana su europskim standardom CENELEC EN 50438 [93]. U Italiji, su standardi CEI 0-16 [94] i CEI 0-21 [95] koji uvode tehničke zahtjeve i pravila za priključenje pasivnih i aktivnih mreža i korisnika na SN i NN mreže, uključujući u posljednjoj verziji istodobnu prisutnost i distribuiranih izvora i sustava za skladištenje energije. Operater distribucijskog sustava (ODS) trebao bi uključiti oba od njih u svoje propise i radne uvjeta mreže.

Ovi dokumenti definiraju pravila kojima se osigurava integracija obnovljivih izvora energije u postojeće električne mreže s najvišom razinom kompatibilnosti. Lokalni izvori i baterijski spremnici spojeni na NN i SN mreže, moraju podržavati stabilnost mreže. Preporučuje se regulacija injektirane aktivne snage (P/f regulacija) koja doprinosi stabilnosti frekvencije mreže, dok je regulacija jalove snage (nazvana Q/V regulacija) usmjerena na kontrolu naponskih razina u distribucijskoj mreži [96]. Čak i ako bi Q/V regulacija mogla imati slab utjecaj na kontrolu lokalnog napona u NN sustavima (gdje bi P/V regulacija mogla biti prikladnija, ovisno o R/X omjeru u mreži [97]), ova funkcija se obavlja sa sadašnjim mrežnim pravilima i na NN u distributivnoj mreži i pruža značajnu potporu za SN mrežu. Nadalje, regulacija aktivne i reaktivne

snage distribuiranog izvora povezanih na distribucijskim sustavima NN i SN, može se iskoristiti za rješavanje problema naponskih nesimetrija [98].

Nadalje, trenutno primijenjeni standardi definiraju šire frekvencijske i naponske raspone za sustave zaštite na mjestima sučelja IPS (Interface Protection System), kako bi se izbjeglo nepravovremeno isključenje proizvodnih postrojenja i, posljedično, spriječile neravnoteže na mreži. Osim toga, autori referata [99] razmatraju i druge tipove funkcija koje utječu na stabilnost, kao što je podrška za brzi napon (Fast Voltage Support -FVS) i podizanje umjetne (sintetičke) inercije (SI), iako još nisu dani u mrežnim pravilima, predloženi su tehničkim dokumentima i literaturom. U stacionarnim uvjetima prednosti ovih poboljšanja su dobro poznate. Nasuprot tome, rad pokazuje da, u slučaju kvarova ili isklopa prekidača (zbog održavanja mreže, rekonfiguracija, pogrešnih isklopa prekidača, itd.), funkcije stabilizacije koje pružaju distribuirani izvori mogu dovesti sve ili dio NN sustava u stanje da mogu samostalno raditi odvojeni od SN mreže. Konkretno, u nekoliko scenarija mreže (uzimajući u obzir različite razine neravnoteže između opterećenja i proizvodnje u NN dijelu), funkcije stabilizacije imaju ulogu u održavanju promjena napona (*V*) i frekvencije (*f*) nakon otočnog pogona u dopuštenim granicama. Time se sprječava ispravno isključenje potrebnih zaštita od ostalih glavnih elemenata mreže, što bi dovelo do nekontroliranog djelovanja u otočnom dijelu mreže u kratkom trajanju. Autori su svoju teorije praktično pokazali putem dinamičke simulacije u programu DIgSILENT PowerFactory^{R}. Već definirane stabilizacijske funkcije i podešenja na mjestima sučelja, postavljaju se prema postojećem talijanskom mrežnom kodu [95], u skladu s CENELEC-ovim smjernicama.

Za testiranje modela autori su koristili shemu prikazanu na slici 5. Ekvivalentna NN mreža prikazana na slici 3.2, posljedično nudi rezultate koji su reprezentativni po različitim domenama. Distribuirani izvor je modeliran kao izvor istosmjernog napona povezanog sa izmjeničnom sabirnicom putem pulsnog širinskog izmjenjivača (end. PWM Converter). Cijeli sustav sastoji se od SN glavne mreže, i SN/NN distribucijskog izvora, transformatora Dyn11 sa zvjezdištem uzemljenim na NN strani snage S_n=400 kVA.



Slika 3.2. Shematski prikaz NN mreže korištene za analize autora referata [99].

Statički generator (eng. Static Generator) predstavlja distribuirani izvor spojen na NN mrežu. PWM elektronički izmjenjivač, modeliran kao strujno kontrolirani uređaj, ima snagu od 100 kVA. Ima aktivnu i reaktivnu komponentu snage koji su kontrolirani ovisno o analizi slučaja koji se razmatra i doprinosa funkcija stabilizatora koje se koriste. U detalje samog modela generatora nije potrebno ulaziti za potrebe ove disertacije.

Analizirana su dva tipa mrežnih događaja za procjenu doprinosa statičkih generatora stabilnosti napona i frekvencije u distribucijskoj mreži. Prvi tip događaja bavi se nenamjernom formiranju otočnog rada u NN mreži zbog isključenja niskonaponske strane transformatora, kako bi se naglasile promjene parametara mreže i njihove posljedice na rad zaštite od gubitka glavnog napajanja.

Drugi događaj analizira učinke stabilizacijskih funkcija primijenjenih na distribuiranom izvoru, u smislu varijacija napona tijekom trofaznog kratkog spoja na SN strani distribucijskog transformatora. Doprinosi *P/f i Q/V* regulacije su primjetni u oba slučaja, dok su emulacija inercije i FVS uvedene zasebno u prvom i drugom slučaju (obzirom na njihove učinke kao posljedicu frekvencijskih i naponskih promjena). U oba slučaja usvojeni su dopušteni pragovi prorade za frekvencijski relej.

Stanje otočnog rada nastaje otvaranjem prekidača na primaru transformatora u nekom trenutku. Kao posljedica toga, NN dio mreže ostaje pod naponom zbog statičkog generatora. Nakon isklopa kondenzatorske baterije (KB) iz mreže, ispitane su različite vrijednosti aktivne snage generatora kako bi se utvrdili različiti doprinosi, što je prikazano u tablici 5:

(i) proizvodnja aktivne energije niža od potrošnje opterećenja (80%),

(ii) proizvodnja električne energije jednaka razini tereta (u ovoj konfiguraciji očekuju se najniže promjene frekvencije [100]),

(iii) proizvodnja aktivne energije veća od razine tereta (120%). Zadana vrijednost reaktivne snage distribuiranog izvora jednaka je nuli u stacionarnim uvjetima prema [95].

Za svaki slučaj uzete su u obzir tri konfiguracije:

(a) nepostojanje propisa o snazi (što znači da distribuirani izvor radi s fiksnim zadanim aktivnim i reaktivnim snagama),

(b) aktiviranje P/f i Q/V regulacije,

(c) aktiviranje umjetne (sintetičke) inercije uz *P/f i Q/V* regulaciju.

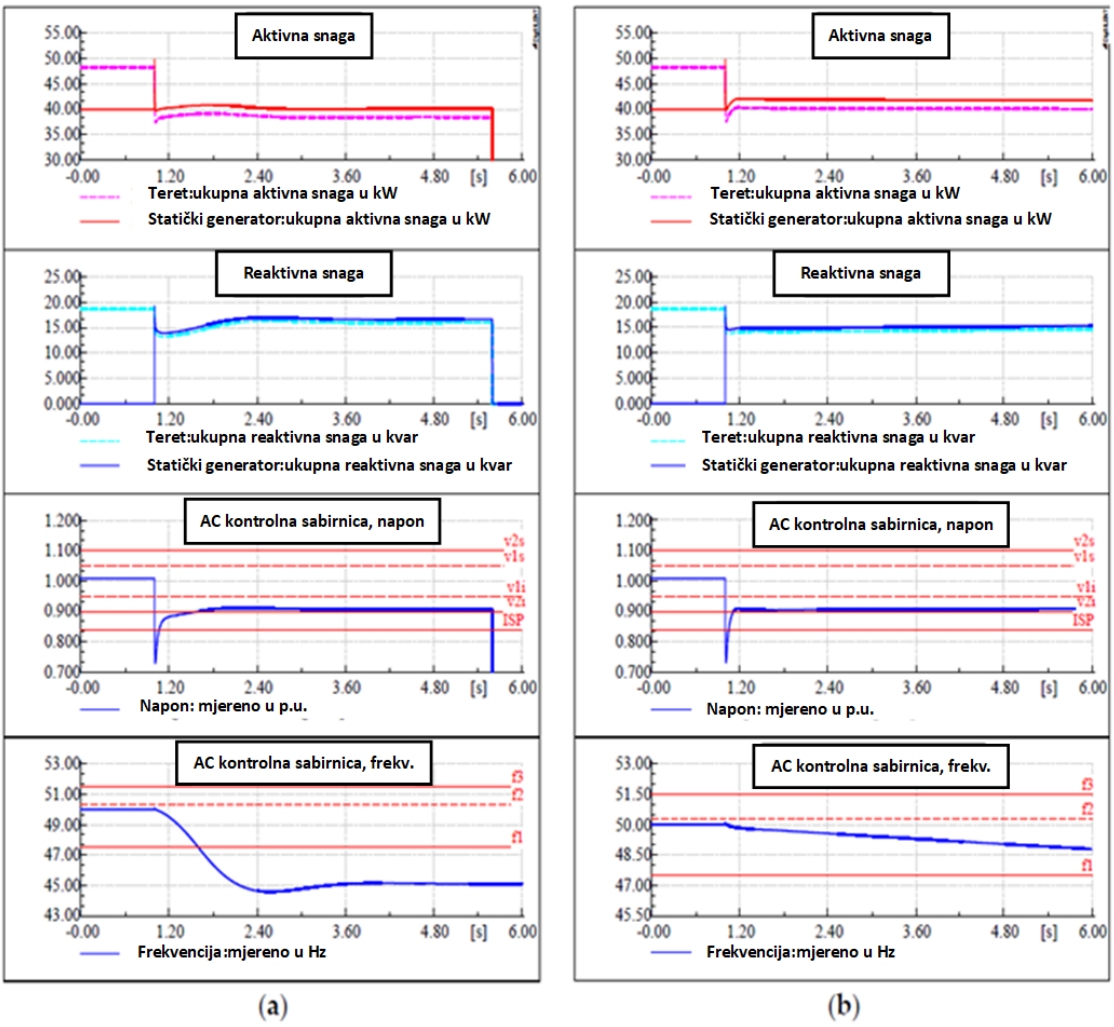
Za svaku konfiguraciju, Tablica 3.1 prikazuje rezultate simulacije navodeći da li zaštitni sustav (IPS) ispravno eliminira neželjenu otočnu pojavu (DA) ili ne (NE). U simulacijama, IPS se smatra nedjelotvornim, ako ne prepozna otočni rad (a time i bez naponsko stanje) odvajanjem distribuiranog izvora u manje od (5) pet sekundi od pojave otočnog rada.

Tablica 3.1. Parametri otočnog rada i njihov utjecaj na ispravan rad sustava zaštite (IPS) (DA znači da IPS ispravno radi, NE znači IPS ne prepoznaje uvjete otočnog rada) [99].

Generator P postavke	**Slučaj**	***P/f i Q/V***	**Sintetička inercija**	**IPS korektivna akcija (bez kondenzatorske baterije)**	**IPS korektivna akcija (s kondenzatorskom baterijom)**
40 kW (80% Ptereta)	i.a	OFF	OFF	DA	NE
	i.b	ON	OFF	DA	DA
	i.c	ON	ON	NE	NE
50 kW	ii.a	OFF	OFF	DA	NE

(100% Ptereta)	ii.b	ON	OFF	NE	NE
	ii.c	ON	ON	NE	NE
60 kW (120% Ptereta)	iii.a	OFF	OFF	DA	DA
	iii.b	ON	OFF	NE	NE
	iii.c	ON	ON	NE	NE

Analiza rezultata jasno pokazuje da radom s *P/f i Q/V* regulacijom, koje su projektirane za priključak na mrežu, značajno pridonose održavanju nekontroliranih uvjeta otočnog rada u odvojenom dijelu mreže. Detaljno, obzirom na konfiguracije ii.a, ii.b i ii.c, u kojima ravnoteža aktivne snage između proizvodnje i opterećenja postoji u vrijeme formiranja otočnog rada ($P_{setpoint} = P_{load}$), bez propisa na mjestu IPS-a ispravno reagira, kao posljedica brzog povećanja frekvencije zbog, djelomično, neravnoteže jalove snage $Q_{load} - Q_{setpoint}$. Važno je napomenuti da je aktiviranje funkcija stabilizacije koja se trenutno zahtijeva u talijanskim standardima (*P/f i Q/V*) dovoljna za sprečavanje prorade glavne zaštite, čime se omogućuje otočni rad. Drugim načinom uzimajući u obzir konfiguracije i.a, i.b i ic (gdje je $P/f_{setpoint} < P/f_{load}$), višak aktivne snage dobiven emulacijom inercije dovoljan je da uzrokuje stabilnu pojavu otočnog rada u kratkom trajanju (slučaj i.c). Slika 6a koja se odnosi na scenarij i.b, pokazuje stanje u slučaju manjka aktivne snage u NN mreži u otočnom radu, gdje sintetička inercija nije aktivirana na distribuiranom izvoru. Prikazani su vremenski dijagrami aktivne snage, reaktivne snage, napona i frekvencije tijekom prijelaznog stanja. Obične linije predstavljaju vrijednosti na izmjenjivaču, dok točkaste crte predstavljaju opterećenje. Simboli v_{1s}, v_{2s}, v_{1i} i v_{2i} odnose se na *Q/V* pragove aktivacije, dok se f_1, f_2 i f_3 odnose na IPS pragove zaštite, 51,5, 50,3 i 47,5 Hz. Jasno je vidljivo da, nakon otvaranja prekidača, napon naglo opada, ali se brzo obnavlja i održava unutar prihvatljivih razina *Q/V* regulacijom (o čemu svjedoči obična plava crta u drugom dijagramu s vrha), dok se frekvencija smanjuje ispod praga od 47,5 Hz, a IPS zaštita, ispravno intervenira kroz pod frekventni relej, četiri sekunde kasnije od pod frekvencijskog praga.



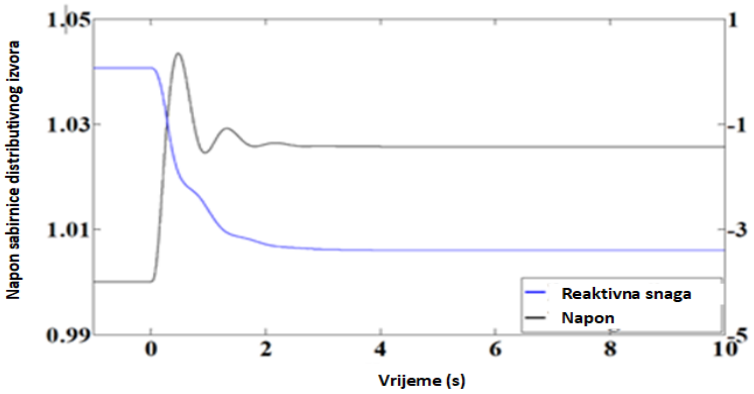
Slika 3.3. Električni parametri sa $P/f_{\text{setpoint}} < P/f_{\text{load}}$ u konfiguraciji i.b (a) i i.c (b), *P/f* i *Q/V* su uvijek aktivni, sa sintetičkom inercijom isključenom (lijevo) i uključenom (desno)[99].

Slika 3.3b prikazuje ponašanje aktivne i jalove snage, napona i frekvencije u slučaju aktiviranja emulacije sintetske inercije (slučaj i.c). Nakon formiranja otočnog rada i promjene napona, napon se brzo vraća i održava u prihvatljivom području (0,85-1,15 p.u.) *Q/V* regulacijom, slično prethodnom slučaju i.b prikazanom na slici 6a. U ovom slučaju, međutim, aktivna snaga koja se utiskuje regulacijom sintetičke inercije ima značajan učinak izglađivanja pada frekvencije. Kao posljedica toga, pod frekvencijski relej IPS-a, ne može detektirati događaj u otočnom režimu rada distribuiranog izvora, omogućujući stabilan rad mrežnog dijela koji je od spojen od glavne mreže za ne-zanemarivo trajanje (dulje od pet sekundi). U drugom i trećem scenariju ($P/f_{\text{setpoint}} = P/f_{\text{loadpoint}}$ i $P/f_{\text{setpoint}} > P/f_{\text{load}}$, respektivno), rezultati su slični, tj. dovoljna je aktivacija *P/f* i *Q/V* regulacije (slučaj ii.b i iii.b) da spriječi djelovanje zaštite, čak i ako emulacija sintetičke inercije nije aktivirana. Otočni dio mreže je u stanju postići stabilno radno stanje jer je generirana aktivna snaga smanjena prema unaprijed postavljenom statizmu *P/f* krivulje. Vrijedno je procijeniti ulogu

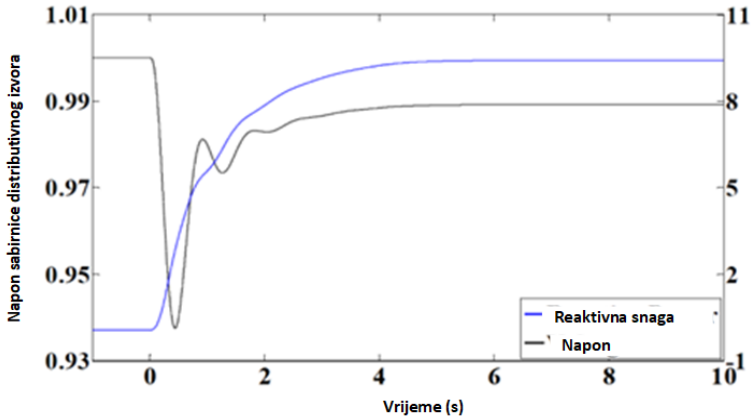
uređaja za kompenzaciju reaktivne snage spojenih na NN mrežu (npr. kondenzatorske baterije instalirane kod krajnjeg korisnika, kako bi se smanjio novčani iznos uslijed prevelikog troška reaktivne energije). Zbog toga se spaja kondenzatorska baterija s nazivnom snagom od 20 kvar (kao što je prikazano na slici 5), kako bi se u potpunosti kompenzirala reaktivna snaga opterećenja (slučaj "sa kondenzatorskom baterijom" u tablici 5). Čak i ako su propisi o potrošnji reaktivne energije van snage, prisutnost kompenzacije pridonosi stabilnom otočnom radu distribuiranog izvora u slučaju $P_{setpoint} < P_{load}$ i $P_{setpoint} = P_{load}$ (scenariji i.a i ii.a). U prvom slučaju kondenzatorska baterija uključuje dopušteni pad napona koji podrazumijeva ravnotežu aktivne snage i stabilnost frekvencije (podsjećajući da P_{load} ovisi o naponskoj razini u poveznom čvoru). U scenariju ii.a kondenzatorska baterija jako smanjuje neravnotežu jalove snage koja ograničava promjenu napona uzrokovanu otočnim radom.

Općenito govoreći, kompenzacijski uređaji mijenjaju raspon aktivne snage distribuiranog izvora koji uključuje nenamjerne uvjete otočnog rada. Konkretno, stabilni otočni rad može se postići mrežom, čak i ako se na distribuiranom izvoru ne koriste stabilizacijske funkcije. Do sada su distribuirani izvori tradicionalno bili spojeni na distribucijske mreže niskog napona, bez potrebe za bilo kakvim stabilizacijskim funkcijama koje bi podržale nepredviđene okolnosti mreže. U slučaju slabe penetracije lokalnih distribuiranog izvora, pasivna zaštita od gubitka glavnih elemenata mogla je učinkovito identificirati potencijalno opasne uvjete i sigurno isključiti distribuirane izvore. Samo savršena kompenzacija reaktivnog opterećenja dovela bi do potencijalne opasnosti od nenamjernog ulaska u otočni rad. Nakon toga, budući da je distribuirana proizvodnja povećala svoj udio u distribucijskim sustavima, i aktivni krajnji korisnici moraju sudjelovati u stabilnosti mreže. Konkretno, napredne funkcije su nametnute lokalnim distribuiranim izvorima sa statičkim izmjenjivačima, koje se lako mogu integrirati prikladnim modificiranjem funkcija i regulacija izmjenjivača. Na taj način mali izvori doprinose minimiziranju frekvencijskih poremećaja moduliranjem aktivne snage, imaju ulogu u održavanju napona na sabirnicama razmjenom reaktivne snage i izbjegavaju neželjene prekide koji djeluju na točki zajedničkog spajanja [99]. Distribuirani izvori se u osnovi mogu svrstati u tri glavne vrste na temelju njihove povezanosti s prijenosnom mrežom. Oni su ili izravno spojeni na mrežu poput generatora s plinskim turbinama (bio plinske elektrane), ili su spojeni preko elemenata energetske elektronike poput foto naponskih sustava, ili kombinacija oba kao što je generatori na vjetro agregatima s indukcijskog generatora (DFIG). Neki od distribuiranih izvora mogu se izvesti sa kontrolom aktivne snage ili frekvencije i/ili faktora snage/reaktivne snage ili napona. Na slikama 3.4 i 3.5 prikazana je jalova snaga od 4,9 MVA distribuiranog izvora, spojena na krutu mrežu kada

se promijeni mrežni napon [101]. Kruta prijenosna mreža modelirana je pomoću dvadeset 255 MVA sinkronih generatora koji rade paralelno.



Slika 3.4. Reaktivna snaga distribuiranog izvora za podizanje napona na sabirnici distribuiranog izvora [101].



Slika 3.5. Reaktivna snaga distribuiranog izvora za smanjenje napona na sabirnicama distribuiranog izvora [101].

Povećanje napona sabirnica dovodi do nad uzbude distribuiranog izvora i može dovesti do gubitka sinkronizma [102]. S druge strane, niski napon sabirnica može uzrokovati preopterećenje i pretjerano zagrijavanje distribuiranog izvora. Prema autorima referata [103], rad malih generatora u VAr modu kontrole faktora snage je opravdan. Međutim, kada je distribucijski sustav ili njegov dio u otočnom radu, napon može prijeći granice propisane normama kvalitete električne energije. U tom slučaju, mali generatori moraju održavati napon otočnog sustava za distribuciju radeći u modu regulacije napona U=const. Upravljačke jedinice međusobno povezane energetske elektronike rade tako da proizvode snagu na unaprijed postavljenoj vrijednosti kada su spojene na mrežu [104], [105]. Izmjenjivači djeluju kao izmjenjivači napona koji se kontroliraju strujom

(VSI) kada su spojeni na mrežu [106]. Međutim, oni također moraju kontrolirati napon kada je sustav distribucije u otočnom pogonu [107]. Stoga, izmjenjivači djeluju kao VSI kontrolirani napon dok je izvor u otočnom radu. Osim kontrole napona, distribuirani izvor također treba kontrolirati frekvenciju otočnog distribucijskog sustava. Za izravno spojene konvencionalne distribuirane jedinice, kao što je plinska elektrana, izlazna snaga distribuiranog izvora, a time i frekvencija otočnog distribucijskog sustava, može se kontrolirati s pomičnim regulatorom, i izokronim regulatorom (izokronalna regulacija frekvencije će se vratiti na početnu zadanu vrijednost frekvencije nakon što generator prihvati ili odbaci opterećenje) ili izokronim regulatorom s povratnom vezom [108]. Sustav testiranja prikazan u [108] je otočni rad distribuiranog izvora s nedostatkom snage 5 MW i rezervnom marginom generatora od 6 MW za testiranje regulatora.

Odabir strategije upravljanja temelji se na dostupnim tehnologijama distribuiranog izvora i mogu biti se koristiti različite strategije za različite tehnologije distribuiranog izvora. Izbor između upravljačkih strategija može se jednostavno napraviti ispravnim određivanjem stanja distribucijskog sustava izborom odgovarajuće tehnike detekcije stanja istog. Sam otočni rad distribucijskog sustava je jedan mali EES. Uz ispravno upravljanje naponom i frekvencijom, može raditi bez potpore glavne mreže. Iako je pouzdanost opskrbe električnom energijom poboljšana dopuštajući rad u otočnom pogonu, pouzdanost cjelokupnog sustava u otočnom pogonu je manja u usporedbi s radom povezanim na mrežu [109]. Stoga je poželjno ponovno povezati distribucijski sustav s prijenosnim sustavom kada se prijenosni sustav vrati u normalne radne uvjete.

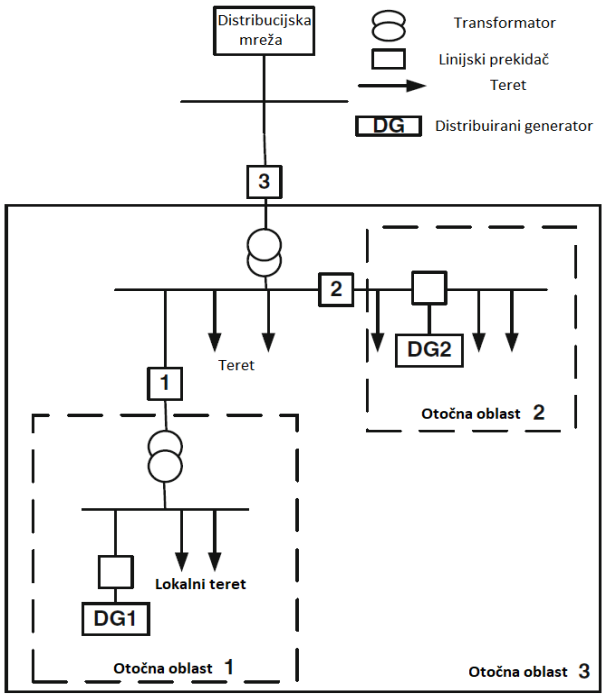
Ponovno povezivanje distribucijskog sustava s prijenosnom mrežom, slično je sinkronizaciji distribuiranog izvora s distribucijskim sustavom ili elektranom na prijenosni sustav. Razlika između napona, frekvencija i faza distribucijskog sustava i prijenosnog sustava trebala bi biti unutar određenih granica prije ponovnog spajanja, tako da ne utječu na rad mreže. Kada se te granice dosegnu onda se kreće sa ponovnom sinkronizacijom dviju mreža. Uz odgovarajuće upravljanje, može se kontrolirati frekvencija, faza i iznos napona, i distribucijski sustav se može sinkronizirati s prijenosnim sustavom. To je moguće ako je sinkronizacijski prekidač blizu distribuiranog izvora. Međutim, u praksi je uglavnom situacija da je sinkronizacijski prekidač daleko od distribuiranog izvora i može postojati više distribuiranih izvora jedinica u otočnom distribucijskom sustavu. Dakle, distribuirani izvor može kontrolirati promjenu napona, frekvencije i faze s upotrebom komunikacijskih rješenja i protokola. Značajan prodor distribuirane proizvodnje otvorio je mogućnost rada distribucijskih sustava u otočnom radu radi povećanja pouzdanosti napajanja. Međutim, još uvijek postoje različita pitanja vezana uz takav rad. Detekcija

stanja (mreža spojena ili je u otočnom radu), kontrola napona i frekvencije, dopušteno pod frekventnog rasterećenje, podešene nad strujne trenutne zaštite i vrste uzemljenja zvjezdišta mreže i distribuiranog izvora samo su neki od primjera problema kod otočnog rada.

U ovom su poglavlju razmatrana su pitanja otočnog rada i utjecaja na distribucijski sustav te se raspravljalo o mogućim dostupnim rješenjima iz literature. Postoje različite tehnike za otkrivanje otočnog rada i hibridne tehnike se ističu kao najperspektivnije, međutim imaju i svojih mana i prednosti. Nadalje, distribuiranim izvorom se može optimalno upravljati prebacivanjem iz jedne strategije upravljanja u drugu kada se distribucijski sustav radi sinkrono i kada nastaje otočni rad ili obrnuto. Neka opterećenja mogu se smanjiti, ako je potražnja u otočnom radu veća od ukupne proizvodnje izvora u otočnog rada kako bi se održavao otočni pogon. Za odbacivanje opterećenja u distribucijskim sustavima potrebne su brze tehnike rasterećenja. Nadalje, adaptivna zaštita može se koristiti za prevladavanje problema s promjenom snage pri kvarovima. Također, distribucijski sustav treba biti uzemljen kako bi se izbjegao bilo kakav problem s prenaponima koji mogu nastati zbog nesimetričnih kvarova tijekom otočnog pogona distribucijskog sustava. Zaključno, otočni rad distribuiranog izvora je realno rješenje za poboljšanje napajanja električnom energijom, ako se problemi ispravno rješavaju. Međutim kada se politika ODS-a veže za regulativu koja ne dopušta otočni rad u normalnim pogonskim uvjetima rada distribucijskog sustava, onda se otočni rad mora izbjegavati. Da bi se spriječio, potrebno ga je pravovremeno i precizno prepoznati.

4. METODE DETEKCIJE

Klasična struktura distribucijskog sustava je pasivne prirode, tj. uvijek je smatrala da je tok energije od više do nižeg naponskog nivoa. Aktivna distribucijska mreža uključuje postojanje distribuiranih izvora energije (eng. Distributed Energy Resources - DER), koji su lokalno integrirani u niskonaponski distribucijski sustav koji mijenja topologiju i rad mreže, što klasičnu analizu čini teže primjenjivom. Aktivna distribucijska mreža razlikuje se od pasivne u smislu dvosmjernosti toka snage, proizvodnje zasnovanim na izmjenjivačima energetske elektronike, visoke različitosti razine kvarova, itd. Udio distribuiranog izvora kao i postavljanje istog u mreži ima značajan utjecaj na zaštitu, rad, pouzdanost i upravljanje elektroenergetskog sustava [110]. Tim se pitanjima treba kritički baviti prije nego što dopusti sudjelovanje distribuiranih izvora u reguliranju postojećih tokova snaga, uz neke dodatne prednosti kao što su aktivna rezerva, mogućnost smanjenja /prekida opterećenja, opterećenja generalno, itd. Jedna od glavnih prepreka u prelasku postojeće strukture mreže na strukturu pametnih mreža, u smislu osjetljivosti i stabilnosti, je problem pojave otočnog rada u distributivnoj mreži. Otočni rad distribuiranih izvora se definira kao situacija u kojoj se dio sustava opskrbe napaja iz jednog ili više distribuiranih izvora, dok se taj određeni dio sustava električno odvaja od ostatka elektroenergetskog sustava, kao što je prikazano na slici 4.1 [111].



Slika 4.1. Koncept pojave otočnog rada distribuiranog izvora [111].

Otočne oblasti 1, 2 i 3 formirane su otvaranjem prekidača 1, 2, odnosno 3. U radu se daje pregled metoda detekcije otočnog rada (MDOR) (eng. Islanding Detection Method – IDM) dostupnih u literaturi kako bi se s vremenom primijenile te strategije otkrivanja otočnog rada. Metode su široko klasificirane u klasične i moderne metode. Bit će navedena sustavna analiza tih tehnika, kako bi se prikazale prednosti i mane pojedinačnih MDOR-ova.

Pojava otočnog rada se može podijeliti na nenamjerno i namjerno iniciranje. Nenamjerno iniciranje je scenarij u kojem se otočni rad pojavljuje bez prethodnog znanja opskrbljivača ili neovisnih proizvođača električne energije. Prekid mreže u nenamjernom otočnom radu događa se u sljedećim uvjetima [112]:

1) kvar koji je otkriven zaštitama u mreži, ali ne i zaštitnim uređajima ugrađenim u distribuirani izvor,
2) pogreška opreme koja uzrokuje slučajno isključenje u mreži,
3) ljudska pogreška ili zloupotreba,
4) čin prirode.

Navedene neželjene posljedice nenamjernog otočnog rada su jasne, te ih nije potrebno posebno objašnjavati, što zahtjeva efikasnu identifikaciju integracije distribuiranih izvora u postojeću topologiju elektroenergetskih sustava [113]. Oko pojave namjernog otočnog rada nisu potrebna dodatna razmatranja, jer je već obrađen u prethodnom poglavlju, a tema ove disertacije ne obuhvaća pojavu namjernog otočnog rada distribuiranih izvora.

Nažalost, ne postoji specifičan sustav ocjenjivanja testa za otočni rad mreža. Različite zemlje su uvele vlastite testne sustave kako bi proučavale pouzdanost i izvedivost otočnog djelovanja, a neke su potpuno različite jedna od druge. Neke od njih temelje se samo na jednoj vrsti distribuiranog izvora, a neke na hibridnoj proizvodnji. IEEE 1547-2003, IEEE 929-2000, korejski, VDE 0126–1-1 i UL 1741 su neki od međunarodnih standarda koje nezavisni proizvođači el. energije i distribucijska poduzeća moraju poštivati za učinkovit otočni rad [114]. Slika 4.2 prikazuje generički sustav za istraživanje otočnog rada sukladno UL 1741 i IEEE 929 kao i IEEE 1547. Opterećenje unutar potencijalnog otočnog rada (lokalno opterećenje) je zamišljeno kao paralelni RLC krug, jer ove vrste opterećenja predstavljaju najveću poteškoću kod detekcije otočnog rada. Konkretno, RLC opterećenja koja imaju visok faktor kvalitete su najproblematičniji element u otkrivanju, jer oni imaju niske induktivnosti i/ili visoku kapacitivnost i/ili veliku otpornost. Rezonantna frekvencija se smatra frekvencijom istoj kao frekvenciji glavne mreže. Matematički

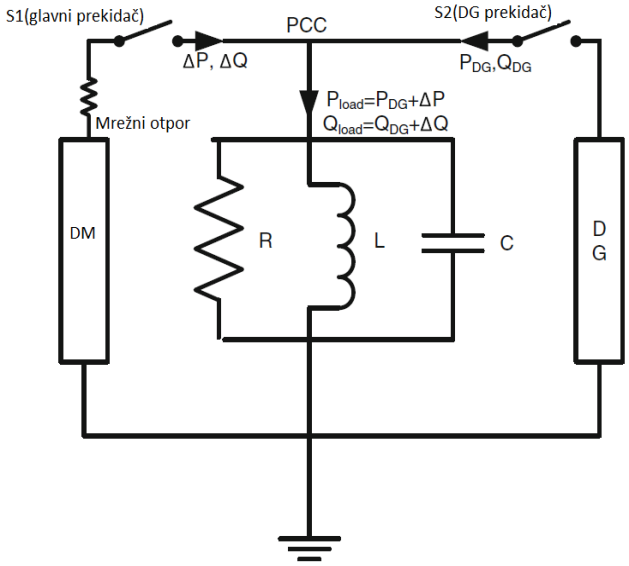
se parametri opterećenja mogu navesti kao u (4-1) - (4-4) [111]. Najgori scenarij nenamjernog otočnog događaja je kada nema neusklađenosti snage između distribuiranog izvora i opterećenja.

$$R = V^2 / P_{TERET} \tag{4-1}$$

$$L = V^2 / (2\pi * f * Q_f * P_{TERET} \tag{4-2}$$

$$C = Q_f * P_{TERET} / (2?* f * V^2) \tag{4-3}$$

$$f = \frac{1}{2\pi * \sqrt{\frac{L}{C}}} \tag{4-4}$$



Slika 4.2. Generički sustav za ispitivanje otočnog pogona mikro mreže po navedenim standardima [111].

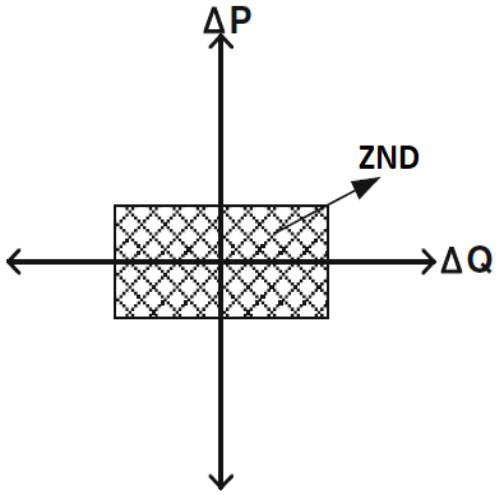
Postoji niz kriterija koji utječu na osobine metoda za otkrivanje otočnog rada. Međutim, trenutno ne postoji tehnika ili tehnike koje ispunjavaju sve kriterije i mogu se primijeniti za otkrivanje svih scenarija otočnog rada. Ti kriteriji po kojima se metode ocjenjuju uključuju zone ne detekcije, troškove primjene, pouzdanost/preciznost, vrijeme djelovanja, učinak na kvalitetu električne energije, itd. Zona ne detekcije je operativna regija u kojoj se ne mogu odrediti udaljenosti kod otočnog rada. Učinkovitost metoda detekcije otočnog rada se povećava sa smanjenjem zone ne detekcije. U normalnim radnim uvjetima napon i frekvencija na mjestu zajedničkog spajanja regulirani su uvjetima mreže, ali kod otočnih uvjeta to ovisi o razlici između aktivne i reaktivne snage između distribuiranog izvora i potrošnje. Granice ovih neusklađenosti snage, gdje metoda

detekcije otočnog rada ne uspijeva otkriti otočni rad je zone ne detekcije [115], dan u izrazima (4-5) i (4-6) [111].

$$\left(\frac{V}{V_{max}}\right)^2 - 1 \leq \frac{\Delta P}{P_{DG}} \leq \left(\frac{V}{V_{min}}\right)^2 - 1 \tag{4-5}$$

$$Q_f\left(1-\left(\frac{f}{f_{min}}\right)^2\right) \leq \frac{\Delta Q}{P_{DG}} \leq Q_f\left(1-\left(\frac{f}{f_{max}}\right)^2\right) \tag{4-6}$$

Iz gornjih jednadžbi dobiva se zone ne detekcije kako je prikazano na slici 4.3 [110]. zone ne detekcije za različite otočne standarde izračunava se i prikazana je u tablici 4.1, gdje se uzima u obzir nazivna frekvencija od 50 Hz. Ako je aktivna i jalova snaga unutar zadanog raspona, tada će napon i frekvencija ostati unutar nazivnog raspona, što će onemogućiti identifikaciju.



Slika 4.3. Shematski dijagram za prikaz zone ne detekcije u parametrima razlike aktivne i reaktivne snage distribuiranog izvora i konzuma [111].

Tablica 4.1. Neusklađenost izlazne snage distribuiranog izvora i potrošnje za različite otočne standarde.

Otočni standard	**Maksimalno dopušteno vrijeme detekcije (sec)**	**V_{max} (%)**	**V_{min} (%)**	**f_{max} (Hz)**	**f_{min} (Hz)**	**Q_f**	**PMS(%)**			
							$(\Delta P/P_{DI})_{min}$	**$(\Delta P/P_{DI})_{max}$**	**$(\Delta Q/P_{DI})_{min}$**	**$(\Delta P/P_{DI})_{max}$**
IEEE 1547-2003	2	110	88	60,5	59,3	1	-17	29	28	31,7
IEEE 929-2000	2	110	88	60,5	59,3	2,5	-17	29	72	79,2
Korejski stan.	0,5	110	88	60,5	59,3	1	-17	29	28	31,7
VDE 0126-1-1	0,2	110	88	50,5	47,5	2	-17	29	-27	49
UL 1741	2	110	88	60,5	59,3	2,5	-17	29	72	79,2

Vrijeme uključivanja je vrijeme proteklo od otvaranja prekidača na točki zajedničkog spajanja, do signala koji se šalje na prekidač za odvajanje distribuiranog izvora. Poželjno je što manje vrijeme isključivanja, tako da se distributivni izvor može brzo odvojiti i spriječiti bilo kakva oštećenja, te minimizirati ista u slučaju pojave otočnog rada.

Iako je mala zone ne detekcije jako poželjna kod metoda otkrivanja otočnog rada, trebala bi postojati određena dopuštena granica kako bi se uklonile smetnje ili lažna okidanja, odnosno povećala preciznost metode. Pojavljuje se uglavnom zbog prenapona mreže uzrokovanog prebacivanjem opterećenja ili drugim poremećajima koji nastaju u mreži [116]. Postotak neželjenog okidanja može se definirati kao postotak trenutaka neželjenog okidanja u ukupnim

vremenima detekcije i izražava se u (4-7) [111]. Omjer bi trebao biti što je moguće manji, kako bi se izbjeglo nepotrebno isključenje glavnog prekidača.

$$P_{nul} = \left[I_{nul} \left(I_{nul} + I_{isl} \right) \right] * 100 \tag{4-7}$$

Metode detekcije utiskivanjem poremećaja kao što su harmonici, struje, itd., ne proizvode nikakav značajan učinak kada su distribuirani izvori spojeni na glavnu mrežu, ali značajno smanjuju kvalitetu energije u otočnom stanju. Stoga se preferiraju metode s nultim ili minimalnim djelovanjem na mrežu.

Danas se većina mreža sastoji ne samo od jednog distribuiranog izvora, nego nekoliko vrsta distribuiranih izvora povezanih na istoj točki zajedničkog spajanja paralelno. Mjerni parametri metoda detekcije mogu poništiti jedan drugoga zbog karakterističnih promjena bilo kojeg distribuiranog izvora koja djeluje na osjetljivost metoda. Zbog toga, metode bi trebale imati primjenjivost u sustavima sa više različitih distribuiranih izvora. Štoviše, s više integracija distribuiranih izvora u budućnosti, metode detekcije bi trebale otkriti otočni rad kada se on pojavi. Ovakva pametna mreža će koristiti istu osnovnu električnu infrastrukturu koju poznajemo danas, ali će se također oslanjati na naprednu tehnologiju praćenja, kontrole i komunikacija koja se trenutno tek počinje primjenjivati. Rezultat će biti mreža koja je u velikoj mjeri automatizirana, primjenjujući veću inteligenciju za rad, praćenje i čak popravke nakon kvara. Ova pametna mreža bit će fleksibilnija, pouzdanija i sposobnija u primjeni digitalne ekonomije. Tablica 4.2 ističe glavne razlike između današnje mreže i pametne mreže.

Područje topologije u tablici ukazuje na ono što je možda temeljniji pomak koji će zahtijevati potpunu pametnu mrežu. Današnji elektroenergetski sustavi su projektirani da podrže velike proizvodne pogone koji služe udaljenim potrošačima korištenjem prijenosnog i distribucijskog sustava, koji je u biti jednosmjeran. No, mreža budućnosti će nužno biti dvosmjerni sustav u kojemu energija i snaga proizvedena od mnoštva malih, distribuiranih izvora, pored velikih postrojenja, teče preko jednog dijela mreže na drugi dio mreže, a ne prema postojećoj hijerarhijskoj strukturi.

Tablica 4.2. Razlika između današnjih mreža i naprednih mreža koje dolaze[117].

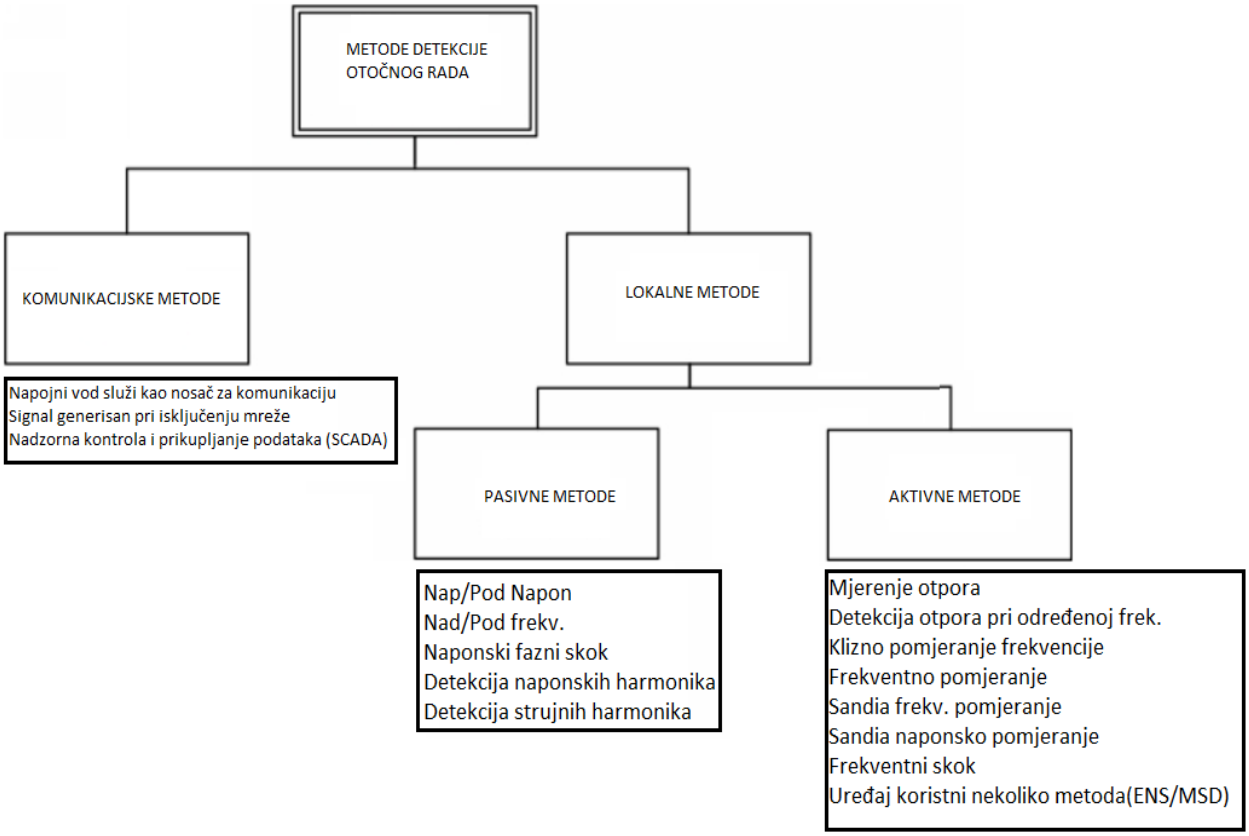
Područje	Današnja mreža	Pametna mreža
Komunikacija	Nikakva ili jednosmjerna	Dvosmjerna
Mjerenje	Elektromehanička	Digitalna koja može u realnom vremenu izmjeriti i dati tarifu
Operativnost	Ručna provjera opreme, vremenski zasnovano održavanje	Daljinski nadzor, predviđanje, održavanje vođeno događajima
Proizvodnja energije	Centralizirano	Centralizirano i distribuirano
Kontrola toka snage	Ograničeno	Opsežno i automatizirano
Popravljanje nakon poremećaju	Ručno	Samo popravljiva
Sustavna topologija	Radijalno, tok snage od izvora ka potrošaču je jednosmjeran	Zamkasta, mnogostruki tokovi snaga
Pouzdanost	Teži ka kvarovima i kaskadnim isključenjima, uglavnom reaktivna kontrola	Automatizirano, proaktivna zaštita, sprječava ispade prije nego se dese

Neke od metoda uključuju napredni i komplicirani hardver za uspješan rad. Efikasne osobine se dobivaju visokim cijenama ulaganja, smanjujući njegovu praktičnu primjenu. Potreban je kompromis između izvedbe i troškova za njihovu primjenu u stvarnom vremenu.

Različiti istraživači predlažu mnoštvo metoda za detekciju otočnog rada distribuiranog izvora. Jako mnogo metoda se rađa iz kombinacija postojećih metoda, dodajući određenje izmjene ili dopune, stvarajući nove hibride metode sa prednostima svojih roditelja i bez njihovih mana. Međutim, metode se mogu svrstati u tri glavne kategorije koje ih najbolje razlikuju po načinu detekcije otočnog rada distribuiranog izvora:

- pasivne metode,
- aktivne metode,
- komunikacijske metode.

Također slikoviti prikaz klasifikacije metoda je prikazan na slici 4.3.



Slika 4.4. Prikaz klasifikacije osnovnih metoda detekcije otočnog rada distribuiranog izvora.

Sveobuhvatno izvješće o metodama i njihovoj klasifikaciji ostvareno je u ovom poglavlju. U nastavku je dan kratak opis kategorija metoda i njihovih karakteristika.

4.1. Pasivne metode

Pasivne metode zasnivaju se na praćenju mrežnih varijabli namjenskim algoritmom koji se nalazi u kod distribuiranog izvora ili izvan njega u nekom uređaju. Većina pasivnih metoda traži veće promjene u frekvenciji, naponu ili faznom kutu, ali također može u nekim koristiti se i harmonicima ili ukupnom harmoničnom izobličenju (THD). Ako algoritam za praćenje detektira velike ili iznenadne promjene tih varijabli na mjestu spajanja s mrežom, izmjenjivač će se isključiti. Najčešće su pasivne metode:

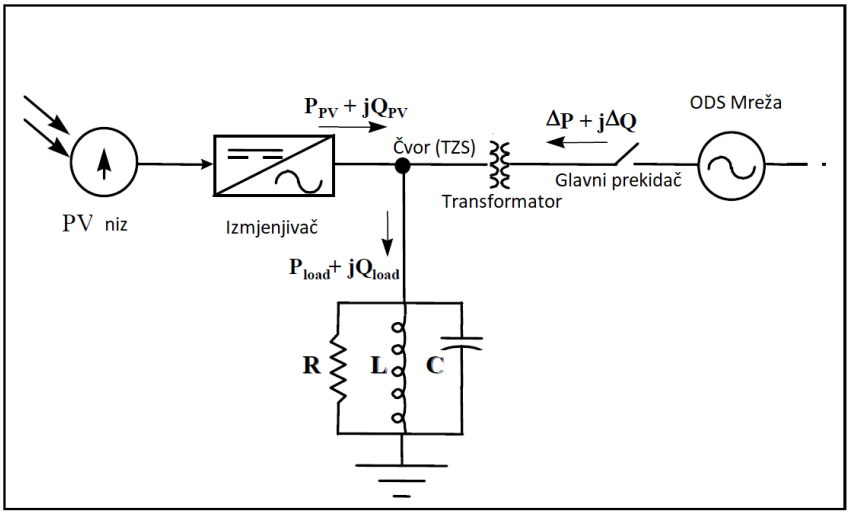
- nad / pod naponom - nadzire prelazi li napon mreže izvan granica utvrđenih odgovarajućim standardima,
- nad / pod frekvencijom - nadzire prelazi li mrežna frekvencija iz granica određenih odgovarajućim standardima,
- brzina promjene frekvencije (ROCOF) i napona (ROCOV),

- monitoring faza - prati brze skokove mrežnog napona faza,
- napon viših harmonika - nadzire selektivno (3-ći, 5-ti, itd.) ili ukupno harmonično izobličenje (THD) mrežnog napona [4], [5].

Pasivne metode su prilično učinkovite u većini situacija koje se javljaju u mreži; međutim, njihova zona ne-detekcije ne obuhvaća situacije u kojima se snaga opterećenja podudara s snagom koju proizvodi distribuirani izvor. U tom slučaju, varijacije napona, frekvencije ili faznog kuta su niže od specificiranih u standardu, jer mreža ostaje uravnotežena, iako je veza s glavnom mrežom izgubljena. Stoga, distribuirani izvor se neće isključiti, iako je nastao otočni rad. Može se koristiti kombinacija pasivnih metoda i korištenje višekriterijskog odlučivanja. U [6] algoritam za otkrivanje otočnog rada koristi pasivne metode, uključujući praćenje frekvencije i napona te najraširenije metode kao što je brzina promjene frekvencije (ROCOF), pomak napona vektora (VPN) i napon disbalansa. Međutim, pasivne metode se općenito smatraju nedovoljnom anti-otočnom zaštitom [118]. Također prema autorima u radu [118] imamo navedene metode sa svojim prednostima i manama i karakteristikama koje su jedinstvene za njih.

4.1.1. Pod/nad napon i pod/nad frekvencija.

Svi mrežni foto naponski izmjenjivači moraju imati nad/pod frekventnu zaštitu (NFZ /PFZ) i metode zaštite od nad/pod napona (NNZ/PNZ), koje uzrokuju da foto naponski izmjenjivač prestane napajati električnu mrežu ako frekvencija ili amplituda napona na točki zajedničkog spajanja između kupca i distribucijske mreže, se nađe izvan propisanih granica. Ove metode zaštite štite potrošačku opremu, ali također služe kao metode za otkrivanje otočnog rada. Razmotri li se konfiguracija prikazanu na Slici 4.5, u kojoj su označeni tokovi snaga i čvor. Čvor je točka zajedničkog spajanja između distribucijske mreže i foto naponskog izmjenjivača. Kada se preklopnik zatvori i priključi se distribucijska mreža, aktivna i reaktivna snaga $P_{FN} + jQ_{FN}$ teku od izmjenjivača u čvor, a snaga $P_{teret} + jQ_{teret}$ teče od točke zajedničkog spajanja do tereta. Zbrajanjem tokova snage u čvoru, dobijemo informaciju jesu li aktivna i reaktivna snaga koje ulaze u čvor iste ili ne. Ako izmjenjivač radi s jediničnim faktorom snage (tj. Izlazna struja izmjenjivača je u fazi s naponom na čvoru), tada $Q_{FN} = 0$ i $\Delta Q = Q_{teret}$.



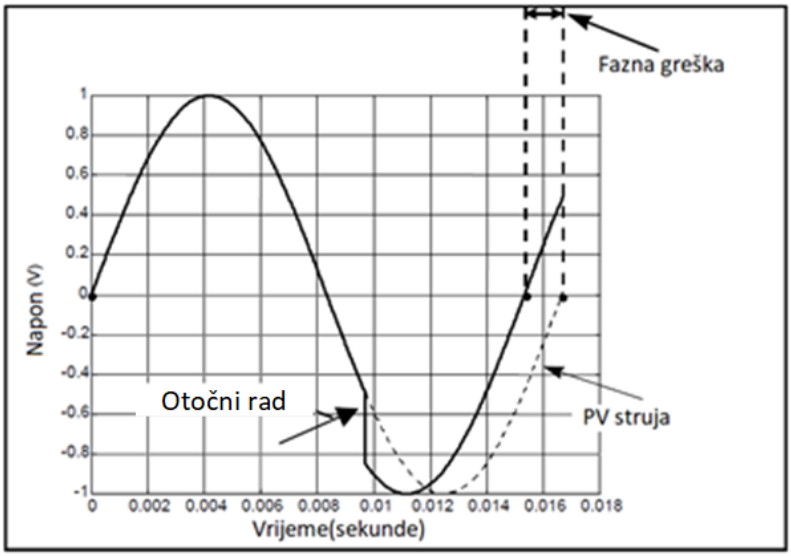
Slika 4.5. Foto naponski sustav i distribucijska mreža te konfiguracija komponenti pri vezivanju na točku zajedničkog spajanja [118].

Ponašanje sustava u trenutku prekida veze će ovisiti o razlici snaga ΔP i ΔQ u trenutku prije nego se prekidač otvori i formira otočni rad. Ako je ΔP≠ 0, amplituda će se promijeniti, a NNZ/ PNZ može otkriti promjenu i spriječiti otočni rad. Ako je ΔQ = 0, napon tereta će pokazati nagli pomak u fazi, a zatim će upravljački sustav izmjenjivača prouzročiti promjenu frekvencije izlazne struje izmjenjivača, a time i frekvencije napona u čvoru, za ΔQ = 0 (tj. dostignuta je rezonantna frekvencija opterećenja.) Ova promjena frekvencije može se otkriti od strane NFZ /PFZ. Treba imati na umu da brza promjena snage mijenja frekvenciju, ali sporije promjene snage mogu ograničiti promjenu frekvencije i može doći će do faznog pomaka napona pri faktoru snage cos φ =1. U ovom trenutku ponavlja se da se svi foto naponski izmjenjivači mogu štititi različitim stupnjevima NNZ/PNZ i NFZ/PFZ zaštite u pametnim digitalnim zaštitama korištenima u distribucijskoj mreži. Stoga, ako se stvarna snaga opterećenja i proizvodnja foto naponskog sustava ne podudaraju, ili rezonantna frekvencija opterećenja ne leži u blizini frekvencije distribucijske mreže, otočni rad se neće pojaviti. Ovo pokriva veliku većinu praktičnih slučajeva.

NNZ /PNZ i NFZ /PFZ potrebna je iz više razloga osim detekcije otočnog rada. Također, nekoliko drugih metoda sprječavanja otočnog rada djeluje tako da proizvedu povećanu frekvenciju ili amplitudu napona, te se oslanjaju na NNZ /PNZ i NFZ /PFZ kako bi zapravo isključili izmjenjivač. Ovo je jeftina opcija za otkrivanje otočnog rada. Primarna slabost NNZ /PNZ i NFZ /PFZ, u smislu detekcije otočnog rada, je njihova relativno velika zone ne detekcije. Dodatno tome, vrijeme djelovanja za ovu zaštitnu može biti predvidivo ili nepredvidivo.

4.1.2. Otkrivanje naponskog faznog skoka

Detekcija faznog skoka (DFS) uključuje praćenje fazne razlike između napona sabirnice izmjenjivača i njegove izlazne struje pri naglom "skoku" [119,120]. Pod normalnim radnim uvjetima i za izmjenjivače strujnog izvora, valni oblik izlazne struje izmjenjivača bit će sinkroniziran s naponom distribucijskog mrežnog sustava, detektiranjem prolaz kroz nulu (ili padajuće nule) na čvoru na slici 4.4. To se općenito postiže analognom ili digitalnom zatvorenom petljom [121]. Za izmjenjivače strujnog izvora, kada je mreža distribucije isključena, napon u točki zajedničkog spajanja više nije čvrsto fiksiran iz izvora napajanja, no kako je izlazna struja izmjenjivača $I_{FN\text{-}inv}$ fiksna, budući da još uvijek slijedi prethodni valni oblik koji daje zatvorena petlja u izmjenjivaču. To se događa zato što se sinkronizacija između $I_{FN\text{-}inv}$ i napona u točki zajedničkog spajanja događa samo na presjecima nula napona. Između prijelaza nula, izmjenjivač u osnovi radi u otvorenom načinu rada. Stoga, iznenada, izlazna struja FN izmjenjivača $I_{PV\text{-}inv}$ postaje referentna faza. Budući da se frekvencija još nije promijenila, fazni kut opterećenja mora biti isti kao i prije nego što je mreža isključena, te stoga napon u točki zajedničkog spajanja mora preći na novi fazni pomak kao što je prikazano na slici 4.6. Na sljedećem prelasku nule, rezultirajuća fazna pogreška između "novog" napona i izlazne struje izmjenjivača može se koristiti za otkrivanje otočnog rada. Ako je ova fazna pogreška veća od neke zadane vrijednosti, regulator može deaktivirati ili isključiti izmjenjivač, smatrajući da je distribuirani izvor u otočnom radu.



Slika 4.6. Shematski prikaz operacije metode faznog skoka [118].

Glavna prednost metode faznog skoka je njegova jednostavnost provedbe. Budući da izmjenjivač u svakom slučaju zahtijeva zatvorenu petlju za sinkronizaciju programa, sve što je potrebno za

primjenu navedene metode je dodavanje mogućnosti deaktiviranja izmjenjivača, ako fazna pogreška otkrivena između $I_{FN\text{-}inv}$ i napona u točki zajedničkog spajanja prelazi neki prag. Također, kao pasivna metoda, ne utječe na kvalitetu izlazne snage izmjenjivača i ne utječe na prijelazna stanja sustava. Konačno, kao i većina pasivnih metoda detekcije otočnog rada, učinkovitost metode se ne smanjuje kada su spaja više izmjenjivača na isti dio mreže u otočnom radu.

Navedena metoda nažalost ima poteškoća u provedbi, jer je teško odabrati pragove koji osiguravaju pouzdano otkrivanje otočnog rada, ali ne rezultiraju čestim neželjenim lažnim odvajanjem distribuiranog izvora od mreže. Uklop određenih opterećenja, posebno motora, često uzrokuje prijelazne fazne skokove značajnijeg iznosa, što će uzrokovati smetnje foto naponskih izmjenjivača, ako su nivoi postavljeni prenisko. Nivoi se mogu mijenjati za određeno mjesto ugradnje, ali takvi parametri specifični za pojedinu lokaciju povećavaju troškove instaliranja foto naponskih sustava kao i zahtjev za promjenama kada se ugrade nove komponente u distribucijskoj mreži.

4.1.3. Otkrivanje naponskih harmonika i detekcija harmonika

U ovoj metodi izmjenjivač foto naponskog sustava nadzire ukupno harmonično izobličenje (THD) napona u točki zajedničkog spajanja i isključuje se, ako taj THD premaši neki prag. Pod normalnim radom referentni izvor, koji je "kruti" izvor napona, uzrokuje sinusoidan napon niskog izobličenja (THD $\approx$ 0) preko sabirnica opterećenja, uzrokujući (linearno) opterećenje i neiskrivljene sinusoidne struje. Sumirajući u točki zajedničkog spajanja, kada se priključi izmjenjivač koji proizvodi više harmonijske struje, on utiskuje harmonike u mrežu niske impedancije. Budući da su te harmonijske struje male i da je impedancija referentnog izvora općenito niska, te harmonijske struje međusobno djeluju s vrlo malom korisnom impedancijom, da bi proizvele vrlo malu distorziju u naponu točke zajedničkog spajanja. Inače, kada je izmjenjivač priključen na pomoćnu mrežu, THD napona je ispod točke detekcije. Kada se otočni rad pojavi, postoje dva mehanizma koji mogu uzrokovati povećanje harmonika. Jedan od njih je sam izmjenjivač. Foto naponski izmjenjivač će proizvesti neke strujne harmonike u svojoj AC izlaznoj struji, kao i svi izmjenjivači struje. Tipičan zahtjev za mrežni izmjenjivač je da proizvede ne više od 5% THD svoje pune nazivne struje [122,123]. Kada se distribucijska mreža isključi, harmonične struje koje proizvodi izmjenjivač ulaze u opterećenje, što u pravilu ima mnogo veću impedanciju od napojene mreže. Harmonijske struje koje međusobno djeluju s većom impedancijom opterećenja proizvest će veće harmonike u naponu. Ovi harmonici napona, ili promjena razine harmonika napona, mogu se detektirati od strane zaštite unutar izmjenjivača, koja onda može pretpostaviti da je foto naponski

izmjenjivač u kvaru i je prekinuti njegov rad. Drugi mehanizam koji može uzrokovati povećanje harmonika je naponski odziv transformatora. Ovaj drugi mehanizam trenutno nije testiran za korištenje današnjih standardnih testiranja. Kada se koriste izmjenjivači strujnih izvora i kada se prekidač koji isključuje izvor napona napajanja od otočnog rada nalazi na primarnoj strani transformatora, kao što je prikazano na slici 4.5, sekundar transformatora će biti pobuđen izlaznom strujom foto naponskog izmjenjivača. Međutim, zbog magnetske histereze i drugih nelinearnosti transformatora, naponski odziv je jako izobličen i povećat će THD u točki zajedničkog spajanja. Također mogu postojati nelinearnosti u lokalnom opterećenju, kao što su ispravljači, koji bi slično proizveli izobličenja THD-a. Ove nelinearnosti obično stvaraju značajne treće harmonike. Stoga, kada se ova metoda koristi u praksi, često se prati trećeg harmonika.

U teoriji, metoda praćenja harmonijskog izobličenja napona je obećavajuća za otkrivanje otočnog rada pri širokim rasponima [8], a njegova se učinkovitost ne bi trebala značajno mijenjati u slučaju više izmjenjivača.

Otkrivanje harmonika pati od istih ozbiljnih poteškoća pri primjeni kao traženje izobličenja sinusoide napona, jer nije uvijek moguće odabrati dobar prag izlaza koji osigurava pouzdanu zaštitu od otočnog rada, ali ne dovodi do neželjenog isključivanja izmjenjivača. Jasno je da se mora odabrati prag koji je:

a) veći od THD-a koji se može očekivati u naponu mreže;

b) niže od THD-a koji će se proizvesti tijekom otočnog rada bilo kojim od dva gore opisana mehanizma.

Pretpostavimo da FN izmjenjivač proizvodi 5% THD u svojoj izlaznoj struji, maksimalno dopuštena granica. Za otporno opterećenje koje napaja ova struja, u nedostatku izvora napajanja, THD u točki zajedničkog spajanja će također biti 5%. Međutim, za RLC opterećenja moguće je da THD bude manji od 5%, jer paralelni RLC krug može pokazivati karakteristike niskog otpora nad kojim je THD. Stoga je jasno da će prag THD-a morati biti određen ispod 5%. U stvarnosti, iskrivljenje napona referentnog izvora napajanja za koje smo pretpostavili da je ≈ 0 može se očekivati da će biti 1-2 % u normalnim uvjetima (zbog interakcije harmoničnih struja koje izlaze i opterećuju se s impedancijom izvora napajanja), ali postoje mnogi uvjeti, kao što je prisutnost energetskih elektroničkih izmjenjivača koji proizvode strujne harmonike na frekvencijama na kojima distribucijski sustav ima rezonanciju, što može uzrokovati značajno povećanje te vrijednosti [125]. Također, prijelazne naponske smetnje, posebno one velike kao što su one koje

prate uklapanje kondenzatorskih baterija [126], mogu biti interpretirane kod foto naponskih izmjenjivačkih sustava kao trenutno povećanje THD-a, ovisno o korištenoj mjernoj tehnici. Jasno je da u nekim slučajevima nije moguće odabrati prag koji zadovoljava kriterije a) i b). Taj je problem moguće riješiti korištenjem digitalne obrade signala i prepoznavanja harmonijskog potpisa, ali te tehnike nisu bile ekonomično implementirane u male fotonaponske izmjenjivače. Iz tih razloga, tehnika harmonijskog praćenja nije komercijalno korištena.

4.2. Aktivne metode

Aktivne metode pojavile su se kao nužnost minimiziranja zone ne detekcije otkrivanja otočnih metoda u uvjetima kada je proizvodnja energije jednaka opterećenju. Uobičajeno, aktivne metode utiskuju malu smetnju u mrežu distribucije i na temelju odgovora mreže odlučuje je li nastao otočni rad. Smetnje u smislu pomaka od normalnih vrijednosti na veličinu mrežnog napona, frekvencije ili faznog kuta mogu biti dodane od strane distribuiranog izvora, u slučaju situacije povezane s mrežom, te smetnje trebaju biti ispravljene pomoću mreže, kroz kontrolu napona i frekvencije. Međutim, ako amplituda napona, frekvencija ili fazni kut prate pomak koji je nastao zbog distribuiranog izvora, najvjerojatnije je da je mreža prekinuta, te je stoga formiran otočni rad. Najčešće aktivne metode koriste pozitivne povratne informacije unutar upravljanja distribuiranog izvora, kontrolor pokušava promijeniti mrežne varijable kao što su frekvencija, faza ili iznos napona kako bi izvršili:

- Skok frekvencije ili skok faze - distribuirani izvor namjerno mijenja frekvenciju ili fazu injektirane struje kako bi promijenila frekvenciju ili fazu napona. Ako frekvencija mreže slijedi struju izmjenjivača, nastao je otočni rad i izmjenjivač bi trebao isključiti [127], [128].

- Preskok frekvencije - sličan gore navedenoj metodologiji.

- Sandia Frequency Shift - sličan skoku frekvencije, ali razvijen u Sandia Nacionalnom laboratoriju [129].

- Povratna informacija o naponu, Sandia Voltage Shift (metoda razvijena od strane Sandia instituta u Albuquerque, New Mexico) - pokušava promijeniti veličinu napona na mjestu u točki zajedničkog spajanja. Ako mreža prati promjene koje stvara distribuirani izvor, napon u mreži će se pomjeriti iz radnog režima i stoga će se izmjenjivač isključiti [130].

- Utiskivanju harmonika preko distribuiranog izvora – ubacivanje ne-karakterističnih harmonika preko distribuiranog izvora a odgovor mreže se registrira [131]. Metoda se također naziva

detekcija impedancije na određenoj frekvenciji. U [132] utiskivanje ne-karakteristične harmonične struje koristi se za dobivanje impedancije mreže na toj određenoj frekvenciji. Vrijednost inter-harmonika mora se odabrati blizu temeljne frekvencije mreže, kako bi se pretpostavilo da se utvrđena vrijednost impedancije mreže može aproksimirati za temeljnu frekvencije.

Aktivne metode koju zahtjeva njemačke norme [133] su one koje detektiraju otpor mreže. U [134] strujni se konus periodično utiskuje određeni otpor na mjestu zajedničkog povezivanja pomoću mrežnog izmjenjivača snage. Na temelju odgovora napona na ovu smetnju, vrijednost impedancije mreže se određuje Fourier-ovom transformacijom. Također se razmatra utjecaj nelinearnog opterećenja spojenog blizu točke zajedničkog spajanja i kao posljedica toga, potrebna je dodatna metoda obrade signala kako bi se dobili točni rezultati. U [135] signal faznog kuta koji se koristi za generiranje reference za regulator struje koji je malo izmijenjen, kako bi se mogla procijeniti impedancija mreže na temelju odziva mreže na generiranu struju. Signal visoke frekvencije (600 Hz) utiskuje se na prijelazu nula, za određivanje vrijednosti impedancije mreže. Oscilacije aktivne i jalove snage koriste se u [136] za određivanje vrijednosti impedancije mreže. Iako aktivne metode daju bolju identifikaciju otočnog rada, one također iskrivljuju isporučenu snagu, kako bi otkrili uvjete otočnog rada. Poremećaji u električnoj mreži nisu pogodni kada je značajan broj distribuiranih izvora spojen na isti izvor napajanja. Utisnuti među harmonici generirani od strane distribuiranog izvora su jedinstveni u distribucijskoj mreži, ova posebna metoda bi omogućila spajanje više od jedne proizvodne jedinice na istoj mreži, jer sinkronizacija u odnosu na ostale distribuirane izvore je moguće s harmonijskim utiskivanjem. Međutim, samo konačni broj izmjenjivača može se priključiti na istu sabirnicu i taj broj izravno ovisi o standardnim zahtjevima u vezi vremena isključenja i broja mogućih smetnji potrebnih za dobivanje točne identifikacije impedancije. Velika razina udjela izmjenjivača korištenjem aktivnih metoda ne samo da smanjuje kvalitetu energije u mreži, već i povećava zonu ne detekcije svih aktivnih metoda kako je opisano.

4.2.1. Mjerenje impedancije

Kada se foto naponski izmjenjivač koristi kao trenutni izvor na napojnoj mreži, on radi prema slijedećem obrascu:

$$I_{PV-inv} = i_{PV-inv}\sin\left(\omega_{PV}t + \Phi_{PV}\right) \tag{4-8}$$

Postoje tri izlazna parametra koja mogu varirati: amplituda $I_{FN\text{-}inv}$, frekvencija ω_{FN} i faza Φ_{FN}. U metodi promjene impedancije, jedan od ovih parametara kontinuirano varira između nekih vrijednosti [124], obično amplituda. Kada se poveže s mrežom, veličina naponskih "poremećaja"

koje nastaju iz "poremećaja" struje, a koja je ujedno i "poremećaj" snage, ovisi o nominalnim vrijednostima otpora i snage distribucijske mreže. Odnos je:

$$\Delta V = \frac{\Delta P}{2}\sqrt{\frac{R}{P}} \tag{4-9}$$

Ako je distribucijska mreža isključena, ova promjena će izazvati detektabilnu promjenu u naponu u točki zajedničkog spajanja, koja se može koristiti za sprječavanje otočnog rada. U stvari, izmjenjivač mjeri $dV_a/di_{FN\text{-}inv}$, i zbog toga se ova metoda često naziva metodom mjerenja impedancije [137]. Kako se izmjenjivač može koristiti tako da napon otočnog rada padne do granice prorade NNZ/PNZ zaštita spojenih na mrežu, minimalni pomak struje potreban za detekciju otočnog rada jednak je punoj veličini prozora djelovanja NNZ/PNZ. Na primjer, ako je NNZ/PNZ spojen na mrežu na +/- 10% od nazivnog napona, potrebna je 20% promjena krivulje da bi zaštita djelovala zbog pojave otočnog rada distribuiranog izvora.

Primarna prednost metode mjerenja impedancije je da teoretski ima izuzetno malu zone ne detekcije za jedan izmjenjivač, s bilo kojim lokalnim opterećenjem s impedancijom većom od impedancije mreže. Ako je izlazna snaga opterećenja i izmjenjivača uravnotežena nakon isključenja napojne mreže, varijacija izlaznog napona izmjenjivača će poremetiti ovu ravnotežu i uzrokovati da se aktivira pod-naponska zaštita.

Nažalost, u praksi metoda ima mnogo slabosti. Ono što se ističe jest da se učinkovitost metode impedancije smanjuje u slučaju više izmjenjivača. To se događa čak i ako svi izmjenjivači u otočnom radu koriste promjenu impedancije, osim ako je promjena nekako sinkronizirana. Razlog tome je što se sve više izmjenjivača dodaje na otočni rad, smanjuje se količina promjena koju svaki izmjenjivač uvede u ukupni $i_{FN\text{-}inv}$ generiran od strane svih FN izmjenjivača, i na kraju promjena postaje toliko mala da promjena u naponu u točki zajedničkog spajanja postaje nemjerljiva. Osim gubitka učinkovitosti u slučaju više izmjenjivača, navedena metoda koja se koristi za mjerenje impedancije mreže može stvoriti mnoštvo drugih problema, osobito na mrežama visoke impedancije ili kada je varijacija izlaza sinkronizirana. Ti problemi uključuju treperenje napona, nestabilnost mreže i lažno okidanje. Metoda koja osigurava da višestruki izmjenjivači ne mijenjaju izlazne snage, u isto vrijeme će smanjiti intenzitet treperenja, ali može i dalje doprinijeti nestabilnosti. Ti se problemi pogoršavaju s povećanjem brojem priključenih izmjenjivača u lokalnom području. Te poteškoće podrazumijevaju da je detekcija impedancije prikladna samo za pojedinačne male sustave i ne može se učinkovito koristiti za višestruke male sustave ili pojedinačne velike sustave.

4.2.2. Detekcija impedancije na određenoj frekvenciji

Ova metoda je poseban slučaj metode detekcije harmonika. Razlika, i razlog zašto se ova metoda smatra aktivnom, a ne pasivnom, je ta što ova metoda namjerno ubacuje strujni harmonika određene frekvencije u točku zajedničkog spajanja preko foto naponskog izmjenjivača. Jedna varijanta metode detekcije harmonika, oslanja se na one strujne harmonike koji se nenamjerno utiskuju u točku zajedničkog spajanja. Kada je distribucijska mreža priključena, ispituje se je li impedancija pogonskog stanja mnogo niža od impedancije opterećenja na toj frekvenciji harmonika, tada struja višeg harmonika u mreži ne stvara nikakav neprikladan napon.

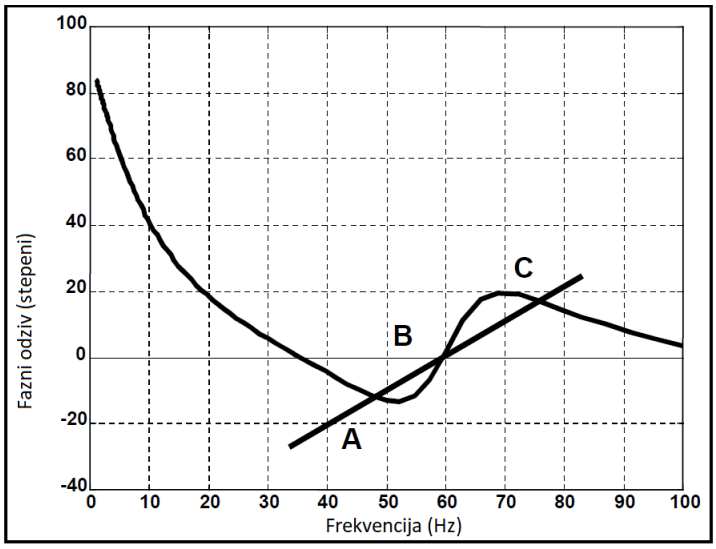
Nakon odvajanja od strane distribucijske mreže, struja harmonika ide u dio mreže u otočnom radu. Ako se pretpostavi da je lokalno opterećenje linearno (tj. može biti predstavljeno paralelnim RLC krugom), tada je moguće utisnuti struju višeg harmonika u čvor. Opterećenje tada generira harmonično izobličenje napona, koji se tada može detektirati. Naziv ove metode proizlazi iz činjenice da će amplituda proizvedenog naponskog harmonika biti proporcionalna impedanciji opterećenja na frekvenciji struje harmonika.

Budući da je ova metoda poseban slučaj metode detekcije harmonika, one imaju iste prednosti, a samim time i slabosti. Moguće je djelomično prevladati ovu slabost, ako se koristi pod-harmonični napon. Nažalost, to je obično nepoželjno iz perspektive distribucijske mreže, jer, osim ako je harmonična amplituda vrlo mala, može uzrokovati nepravilan rad opreme i probleme s transformatorima [138]. Višestruki izmjenjivači utiskivanjem istih harmonika istovremeno mogu proizvesti lažne dojave otočnog rada distribuiranog izvora, jer se amplituda napona na tom harmoniku povećava, čak i pri niskoj impedanciji mreže i smanjuje amplitudu utisnutog harmonika kako bi onemogućila ispravnu detekciju otočnog rada.

4.2.3. Pomicanje frekvencije klizanjem (eng. Slip Mode Frequency Shift – SMS)

Pomak frekvencije s klizanjem (SMS) jedan je od tri načina koji koriste pozitivne povratne informacije kako bi destabilizirao izmjenjivač kada nastane otočni rad, čime se sprječava postizanje stabilnog stanja koji bi omogućio dugotrajan rad. Kao što je navedeno u gornjoj jednadžbi (4-9), postoje tri parametra napona u točki zajedničkog spajanja na koje se može primijeniti pozitivna povratna veza: amplituda, frekvencija i faza. Istražene su sve tri mogućnosti. SMS primjenjuje pozitivnu povratnu informaciju na fazu napona u čvoru kao metodu za pomicanje faze, dakle kratkoročne frekvencije. Ova povratna informacija neće utjecati na frekvenciju mreže. Normalno, izmjenjivači rade na jedinstvenom faktoru snage $\cos \varphi = 1$, tako da se fazni kut između

izlazne struje invertora i točke zajedničkog spajanja napona postavlja na nulu (ili što je bliže moguće). Kod SMS metode, fazni kut napona izmjenjivača, umjesto da se uvijek kontrolira kad je nula, napravljen je da bude funkcija frekvencije točke zajedničkog spajanja napona, kao što je prikazano na slici 4.6. Krivulja faznog odziva izmjenjivača konstruirana je tako da se faza izmjenjivača povećava brže od faze (RLC) opterećenja, s brzinom promjene faktora snage blizu frekvencije potrošnje energije ω_0. To čini frekvenciju faze nestabilnom radnom točkom izmjenjivača [127]. Dok je distribucijska mreža povezana sa distribuiranim izvorom, ona stabilizira radnu točku na frekvenciji mreže osiguravajući čvrstu fazu i referencu frekvencije. Međutim, nakon što nastane otočni pogon, radna točka frekvencije opterećenja i izmjenjivača mora biti na sjecištu linije tereta i krivulje odziva izmjenjivača. Linija opterećenja i krivulja izmjenjivača presijecaju se u točki označenoj s B, na frekvenciji od 60 Hz i fazi nula, i rade tamo dok je priključen uređaj. Sada pretpostavimo da se distribucijska mreža odvoji. Ako postoji mala promjena frekvencije točke zajedničkog spajanja napona od 60 Hz, krivulja faznog odziva u obliku slova S uzrokuje povećanje fazne pogreške, a ne smanjenje. To je mehanizam pozitivnih povratnih veza i uzrokuje klasičnu nestabilnost. Ta nestabilnost izmjenjivača pri ω_0 uzrokuje da ojača promjenu i dovodi sustav u novu radnu točku, bilo u točki A ili C, ovisno o smjeru poremećaja. Ako je fazna krivulja izmjenjivača ispravno projektirana za ovo RLC opterećenje, točke A i C će biti na frekvencijama koje se nalaze izvan nad/pod frekvencijskih granica zaštite, a izmjenjivač će se isključiti zbog pogreške frekvencije. SMS je implementiran kroz prisustvo ulaznog filtra na zatvorenom algoritmu koji se konstantno ponavlja. Prvo se razmatra slučaj u kojem ulazni filtar nema fazni pomak s klizanjem. U tom slučaju, fazni kut napona izmjenjivača je nula za sve frekvencije. Ako bi frekvencija u otočnom radu bila narušena prema više, ulazni filtar bi otkrio negativnu faznu pogrešku i smanjio bi svoju frekvenciju, kako bi pretvorio struju izmjenjivača i napon čvora u fazni balans. Kada se frekvencija poveća, zbog pozitivne povratne veze na fazu uzrokovane karakteristikom navedene metode u ulaznom filtru na zatvorenom algoritmu, algoritam povećava svoju frekvenciju rada. Upravljačko djelovanje je sada u pogrešnom smjeru kako bi se ispravila fazna pogreška. Taj se uvjet nastavlja sve dok se ne postigne frekvencija na kojoj se krivulje opterećenja i frekvencijskog odziva izmjenjivača ponovno sijeku. To pokazuje nestabilnost navedene metode, ona djeluje tako da pomjera radnu točku sustava od zadane frekvencije, jer se faza metode povećava čak brže i u suprotnom smjeru od faze RLC opterećenja.



Slika 4.7. Naponski fazni kut i frekvencija na izmjenjivaču prikazujući trenutak kada SMS metoda prepozna otočni rad distribuiranog izvora. [118]

Ova metoda, kao i mnoge druge aktivne metode, je relativno jednostavna za provedbu, budući da uključuje samo malu modifikaciju komponente koja je već ionako potrebna. Također, vrlo je učinkovita u prevenciji otočnog rada (mala zone ne detekcije), u usporedbi s drugim aktivnim metodama. SMS je vrlo učinkovit u primjeni više izmjenjivača na istoj sabirnici i pruža dobar kompromis između učinkovitosti detekcije otočnog rada, kvalitete izlazne snage i utjecaja na prolazni odziv cjelokupne distribucijske mreže.

Fazni pomak napona s klizanjem zahtijeva smanjenje kvalitete izlazne energije foto naponskog izmjenjivača, ali malo. Također, na vrlo visokim razinama udjela distribuiranih izvora i trenucima visoke proizvodnje energije, SMS bi mogao uzrokovati pogoršanje kvalitete električne energije na razini sustava i probleme kod prijelaznih poremećaja. Ovaj problem je zajednički za sve tri metode koje koriste pozitivne povratne informacije.

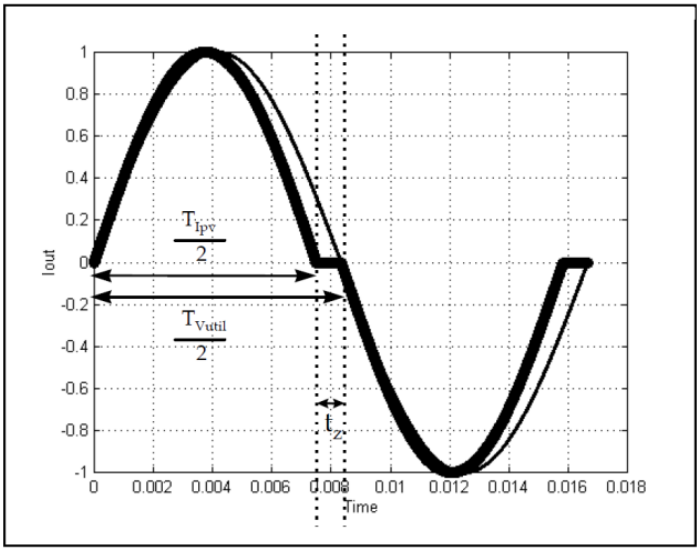
4.2.4. Odstupanje frekvencije

Frekvencijsko odstupanje ili metoda aktivne frekvencije (MAF), lako se implementira u izmjenjivaču s mikroprocesorskim upravljanjem. U ovoj metodi, valni oblik struje koja se utiskuje u čvor pomoću izmjenjivača je blago iskrivljena, tako da postoji kontinuirani trend promjene frekvencije. Međutim, kada je spojen na mrežu, nemoguće je promijeniti frekvenciju bez prorade frekvencijske zaštite. Kada se isključi iz mreže, frekvencija napona je prisiljena pomjerati se gore i/ili dolje, (prikazano na slici 4.7), povećavajući "prirodni" pomak frekvencije uzrokovan sustavom koji traži rezonantnu frekvenciju opterećenja. Primjer valnog oblika izlazne struje izmjenjivača

($I_{FN\text{-}inv}$) koji implementira MAF, zajedno s neiskrivljenim sinusnim valom za usporedbu. To se također može postići lako s malom ili nikakvom radio frekventnom interferencijom pomoću glatkih valnih oblika kao što je drugi harmonijski sinusni val. T_{Vutil} je perioda napona mreže, T_{IFN} je perioda sinusnog dijela strujnog izlaza izmjenjivača, a t_z je nulto vrijeme. Omjer nultog vremena t_z do polovice perioda valnog oblika napona, T_{Vutil} / 2, naziva se "frakcija sjeckanja" (cf):

$$cf = \frac{2t_z}{T_{Vutil}} \tag{4-10}$$

Tijekom prvog dijela prve poluperiode, strujni izlaz izmjenjivača je sinusna s frekvencijom nešto višom od one napona napajanja. Kada izlazna struja izmjenjivača dosegne nulu, ostaje na nuli za vrijeme t_z prije početka druge poluperiode. Za prvi dio druge poluperiode, izlazna struja izmjenjivača je negativna polovica sinusnog vala iz prve poluperiode. Kada struja izmjenjivača ponovno dosegne nulu, ostaje na nuli sve do prelaska nultog napona napajanja. Važno je napomenuti da nulto vrijeme u drugoj poluperiodi nije fiksno i ne mora biti jednako t_z.



Slika 4.8. Primjer valnog oblika korišten za primjenu metode Odstupanja frekvencije za otkrivanje otočnog rada [118].

Kada se ovaj trenutni valni oblik primijeni na omsko opterećenje u slučaju otočnog pogona, njegov naponski odziv će slijediti izobličeni valni oblik struje i otići na nulu u kraćem vremenu (T_{Vutil} - t_z) nego što bi to bilo pod čisto sinusoidnom pobudom. To uzrokuje da se križanje nule u uzlaznom periodu dogodi ranije nego što se očekivalo, što dovodi do fazne pogreške između napona u točki zajedničkog spajanja i $I_{FN\text{-}inv}$. izmjenjivač zatim povećava frekvenciju $I_{FN\text{-}inv}$ kako bi pokušao eliminirati faznu pogrešku. Naponski odziv omskog opterećenja opet ima svoj nulti prijelaz u

vremenu u odnosu na ono gdje se očekivalo, a izmjenjivač još uvijek detektira faznu pogrešku i ponovno povećava svoju frekvenciju. Taj se proces nastavlja sve dok se frekvencija ne udalji dovoljno od ω_0, da bi se detektirala zaštita od nad/pod frekvencije (NFZ/PFZ).

U mikroprocesorskim invertorima, ova metoda je relativno jednostavna za primjenu. Metoda frekvencijskog odstupanja zahtijeva malu degradaciju kvalitete izlazne snage izmjenjivača. Osim toga, kako bi se zadržala učinkovitost u slučaju više izmjenjivača, moralo bi postojati dogovor svih proizvođača izmjenjivača u kom smjeru frekvencije ići. Ako su neki izmjenjivači bili orijentirani prema rastu frekvencije, a drugi prema padu, mogli bi se međusobno poništiti kada se izmjenjivač isključi. Prekid struje mogu uzrokovati zračenje i provoditi radio frekvencijske smetnje.

4.2.5. Sandia frekvencijsko pomjeranje (eng. Sandia Frequency Shift - SFS)

Sandia frekvencijsko pomjeranje (SFS) je proširenje metode frekvencijskog odstupanja i još je jedna metoda koja koristi pozitivnu povratnu vezu kako bi se spriječio otočni rad distribuiranih izvora. U ovoj metodi, frekvencija napona na čvoru točki zajedničkog spajanja na koju se primjenjuje pozitivna povratna sprega ovisi o vrsti izmjenjivača. Postoje dva slučaja koja se razmatraju. To su:

1. izmjenjivač je dvosmjerni,
2. izmjenjivač je jednosmjerni.

Da bi se primijenila pozitivna povratna sprega napravljena je da bude funkcija pogreške u valnom obliku frekvencije u izrazu (4-11):

$$cf = cf_0 + K\left(f_a - f_{line}\right) \tag{4-11}$$

gdje je cf_0 frakcija sjeckanja kada nema pogreške frekvencije, K je koeficijent ubrzanja koji ne mijenja smjer, f_a je izmjerena frekvencija napona na točki zajedničkog spajanja, a f_{line} je frekvencija izvora napajanja. Moguće su i druge funkcije procjene pogreške frekvencije, a i djelomično-linearne funkcije uspješno su primjenjive. Kada se priključi na mrežu, detektiraju se manje promjene frekvencije i metoda pokušava povećati promjenu frekvencije, ali krutost mreže sprječava bilo kakvu promjenu. Kada se spojna mreža isključi i f_a povećava frekvencijsku pogrešku, povećava se frakcija usitnjavanja, a izmjenjivač također povećava svoju frekvenciju. Izmjenjivač tako djeluje kako bi pojačao odstupanje frekvencije, a taj se proces nastavlja dok frekvencija ne dosegne prag. Postupak je sličan ako se f_a smanjuje, na kraju frakcija sjeckanja

postaje negativna, što znači da razdoblje $I_{FN\text{-}inv}$ postaje dulje od perioda napona u točki zajedničkog spajanja.

Ovu metodu nije teško provesti i ima jednu od najmanjih zone ne detekcije svih aktivnih metoda za detekciju otočnog rada i pokazala se vrlo djelotvornom [139]. Također, čini se da SFS, kao i SMS, pruža dobar kompromis između djelotvornosti detekcije otočnog rada, kvalitete izlazne snage i učinaka prijelaznih pojava sustava. Također, treba napomenuti da je SFS implementiran u kombinaciji sa Sandia naponsko izobličenje (eng. Sandia Voltage Shift - SVS) metodom detekcije pojave otočnog rada. Utvrđeno je da je ova kombinacija iznimno učinkovita [140]. SFS zahtijeva da se kvaliteta izlazne snage izmjenjivača malo smanji kada je spojena na mrežu, jer pozitivna povratna sprega pojačava promjene koje se događaju na mreži. Također, moguće je da nestabilnost izlazne snage izmjenjivača uzrokuje nepoželjne kratkotrajne prijelazne pojave u mreži kada je priključena mreža slaba. Taj bi problem narastao kako bi se povećao udio distribuiranih sustava na mreži. Oba ova učinka mogu se upravljati smanjenjem koeficijenta K, što povećava veličinu zone ne detekcije. Pretpostavlja se da će od tri metode s pozitivnim povratnim vezama ova metoda uzrokovati najmanje problema s prijelaznim pojavama i kvalitetom el. energije, pri visokim razinama udjele foto naponskih izvora u mreži. To proizlazi iz činjenice da se frekvencija u elektroenergetskim sustavima vrlo čvrsto regulira, u usporedbi s amplitudom i fazom. Ova metoda i druge metode pozitivne povratne veze obično se stimuliraju šumom ili harmonicima na referentnom valnom obliku. Izuzetno kvalitetni valni oblici izmjenjivača, linearna opterećenja i niska razina šuma smanjuju osjetljivost. Neki su izmjenjivači prošli anti-otočno testiranje u realnom pogonu, ali nisu uspjeli u dobro kontroliranim laboratorijskim ispitivanjima. Točni razlozi nisu objavljeni, ali teorija za neke metode sugerira da je laboratorijski test koristio zaštitu i vrlo nisku postavku testa šuma, koja je smanjila prag okidanja potreban za pokretanje pozitivnih povratnih veza.

4.2.6. Sandia Naponsko pomjeranje (eng. Sandia Voltage Shift – SVS)

Ovo je treća metoda koja koristi pozitivne povratne veze kako bi spriječila pojavu otočnog rada. Sandia naponsko pomjeranje (SVS) primjenjuje pozitivnu povratnu spregu na amplitudu napona u točki zajedničkog spajanja. Ako je došlo do smanjenja amplitude napona (obično je to efektivna vrijednost koja se mjeri u praksi), izmjenjivač smanjuje svoj strujni izlaz i time svoju izlaznu snagu. Ako je napojna mreža povezana sa distribuiranim izvorom, malo je ili uopće nema učinka kada se napona smanji. Kada je distribucijskoj mreži odsutna i postoji smanjenje napona, doći će do daljnjeg smanjenja amplitude napona kako je diktirano odzivom prema Ohm-vom zakonu

(RLC) impedancije opterećenja na manju struju. Ovo dodatno smanjenje amplitude napona dovodi do daljnjeg smanjenja izlazne struje izmjenjivača, što dovodi do smanjenja napona koji se može detektirati od strane pod naponske zaštite.

Moguće je povećati ili smanjiti izlaznu snagu izmjenjivača, što dovodi do odgovarajuće prorade nad-naponske zaštite. Međutim, poželjno je odgovoriti smanjenjem snage i pod naponskom zaštitom, jer je manje vjerojatno da će oštetiti opremu potrošača. Američki znanstvenici predložili su koncept ubrzanja prorade [120]. Koncept je da izmjenjivač reagira na male promjene napona ili frekvencije, s odgovarajućim promjenama u radnoj ili jalovoj snazi, koje su dovoljne da uzrokuju daljnje promjene u istom smjeru. Ako se napon ili frekvencija nastavi kretati u istom smjeru, svaki se odgovor "ubrzava" eksponencijalno dok se ne pojavi pod/nad napon ili pod/nad frekvencija. Na primjer, smanjenje snage u odgovoru na otočni rad moglo bi biti 0,5%, 1%, 2%, 4%, 8%, 16% i 32%, a onda bi pod naponska zaštita proradila. Ubrzanje poboljšava vrijeme odziva, ima vrlo male promjene snage (obično <1%) kada je distribucijskoj mreži prisutna, i radi u sustavima s više izmjenjivača. U mikroprocesorskim izmjenjivačima, ova metoda je jednostavna za primjenu. Također, od tri metode zasnovane na pozitivnim povratnim vezama, vjeruje se da će ova biti najučinkovitija u smislu detekcije otočnog rada distribuiranog izvora. Kao što je prethodno navedeno, SVS se uobičajeno provodi istodobno s SFS-om, a ta kombinacija metoda pokazala se vrlo učinkovitom u sprječavanju otočnog rada, s tako malom zone ne detekcije da je vrlo teško eksperimentalno locirati [120]. Ova metoda ima dvije manje slabosti. Prva je da zahtijeva vrlo malo smanjenje kvalitete izlazne snage zbog pozitivnih povratnih informacija. Veličina tog gubitka ovisit će o kvaliteti energije mreže na koju je priključen. Drugo, postoji malo smanjenje učinkovitosti izmjenjivača zbog različitih načina upravljanja točkama maksimalne snage. Uobičajeno će izmjenjivač raditi na točki najveće snage preko regulatora unutar izmjenjivača, ali u normalnim radnim uvjetima, male promjene amplitude napona će uzrokovati da izmjenjivač reagira smanjenjem snage i pomicanjem izmjenjivača s maksimuma za neko vrijeme. Druga slabost SVS-a je da postoje naznake da ova metoda može imati mali utjecaj na prijelazni pojave distribucijskog sustava i kvalitetu električne energije. Ako bi preliminarna istraživanja bila točna, razine udjela izmjenjivača koji koriste SVS možda će se morati držati nisko na slabijim mrežama, kako bi se izbjegli problemi na razini sustava.

4.2.7. Frekvencijski skok (eng. Frequency Jump – FJ)

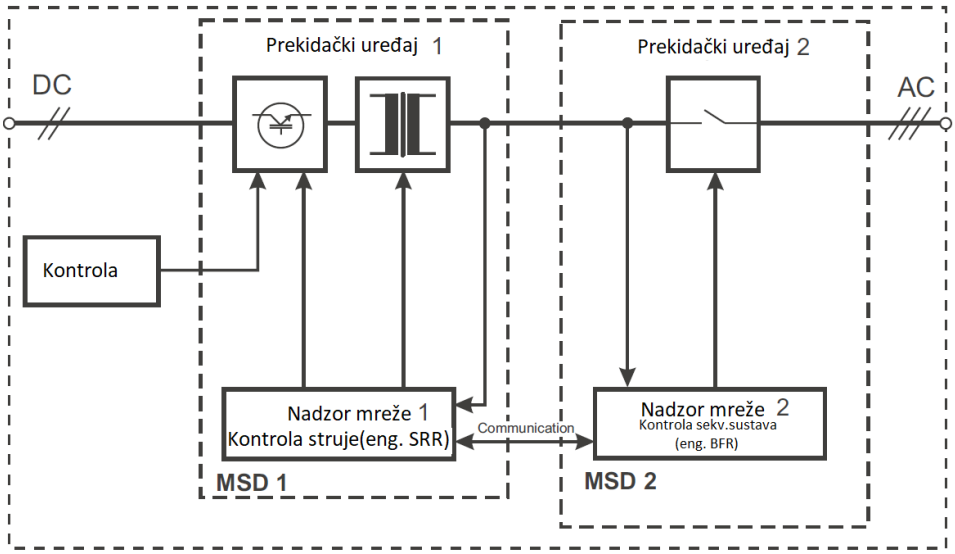
Metoda skoka frekvencije (FJ) je modifikacija metode frekvencijskog pomjeranja i konceptualno je slična mjerenju impedancije. U FJ metodi, nulte zone su umetnute u valni oblik izlazne struje,

ali ne u svakom ciklusu. Umjesto toga, frekvencija je "odbijena" prema unaprijed određenom uzorku. Na primjer, nulte zone mogu biti umetnute u svaki treći ciklus. U nekim primjenama, kao što je „Zebra“ metoda, nestabilnost uzorka može biti vrlo sofisticirana. Kada se spoji na sabirnice napojne mreže, skok frekvencije rezultira modificiranom strujom izmjenjivača $I_{FN\text{-}inv}$ koja je povremeno iskrivljena, ali napojna mreža dominira svojim valnim oblikom napona i frekvencijom u točki zajedničkog spajanja. Kada se distribuirani izvor isključi sa mreže, metoda FJ sprječava formiranje otočnog rada bilo zbog forsiranja odstupanja u frekvenciji, kao u metodi prenaprezanja frekvencije, ili omogućavanjem izmjenjivaču da detektira varijaciju frekvencije napona u točki zajedničkog spajanja koja odgovara varijanti podrhtavanja koju koristi izmjenjivač. Ako je uzorak dovoljno sofisticiran, FJ može biti relativno učinkovit u sprječavanju otočnog rada ako se koristi s jednim izmjenjivačem. Primarna slabost FJ metode je u tome što ona, kao i metode mjerenja impedancije i frekvencijskog odstupanja, gubi učinkovitost u slučaju primjene više izmjenjivača, osim ako podrhtavanje frekvencije nije nekako sinkronizirano. Ako nije sinkronizirano, varijacije uvedene višestrukim izmjenjivačima mogu djelovati tako da se međusobno poništavaju, što dovodi do greške detekcije otočnog rada distribuiranog izvora.

4.2.8. Jedinice mrežnog nadzora s dodijeljenim višeslojnim sklopnim uređajima spojenim u seriji (eng. Mains Monitoring Units with Allocated All-pole Switching Devices Connected in Series – MSD, ili ENS)

Metoda jedinica mrežnog nadzora je zapravo opis automatskog posebnog sklopa koje se sastoji od dva neovisna, različita paralelna uređaja za praćenje s dodijeljenim sklopovima koji su spojeni u nizu u faznom i neutralnom vodiču. Drugim riječima, dva sklopna uređaja u nizu se neovisno upravljaju. U navedenoj metodi se koriste višestruke procedure za otkrivanje otočnog rada. Radi se o metodi detekcije impedancije s dodatnim nad/pod naponskim zaštitama. Svaka od tih nezavisnih jedinica kontinuirano prati kvalitetu povezane mreže praćenjem napona, frekvencije i impedancije. Redundantni projekt, kao i automatska samo provjera prije svakog spajanja na mrežu, osiguravaju poboljšanje pouzdanosti metode. Redundantni projekt prikazan je na slici 4.7. Različita rješenje koji danas koriste proizvođači, variraju ovisno o tome kada je rješenje implementirano u odnosu na tehnološka poboljšanja koja su se dogodila. Sve jedinice prate napon, frekvenciju i impedanciju. Kada i kojom se impedancija provjerava metodom, u središtu je većine tehnoloških poboljšanja. Opći blok dijagram opisan u standardu DIN VDE 0126 prikazan je na slici 4.9. Uređaj obično utiskuje malu struju kako bi odredio impedanciju. Krug je projektiran za otkrivanje značajnih promjena impedancije u kratkom vremenskom razdoblju koje bi se dogodilo,

ako bi se distribucijska mreža isključila. Obično je potrebna izmjena (kada je spojena na mrežu u odnosu na kada se isključuje iz mreže) koja se detektira u impedanciji ΔZ_{ac}> 0,5 ohma za izmjenjivače standardnih veličina. Dodatne studije koje koriste specifičnu konfiguraciju mreže, koje se značajno razlikuju od zemlje do zemlje, a ponekad i od efikasnosti, procjene izmjenjivača vjerojatno će pronaći drugačiju vrijednost za ΔZ_{ac}. Svi prekidači koji se koriste u ovoj metodi imaju procjenu prekidanja opterećenja u skladu s nazivnom izlaznom snagom izmjenjivača i imaju elektromehaničke elemente kao što su releji ili kontaktori. Kada izmjenjivač koristi izolacijski transformator, jedan od polova može koristiti upravljivi poluvodički uređaj koji osigurava funkcionalnost sklopa na propisan i redovit način. Svi izmjenjivači koji koriste ovu metodu, moraju proći 100% testiranje u krugu tvornice prije isporuke. Redundantni projekt i redovita samo provjera pri pokretanju izmjenjivača omogućuju korisniku da instalira jedinicu bez potrebe za povremenim provjerama, kako bi se utvrdilo je li anti-otočki sustav funkcionalan. Snage opisane u metodi mjerenja impedancije, također vrijede za ovu metodu. Potrebno je imati na umu da se predviđa, ali još nije dokazano, da se na stotine jedinica koje rade zajedno mogu povezati na zajednički točki zajedničkog spajanja bez smetnji. Budući da metoda detekcije impedancije koristi impuls struje ubrizganog u distribucijski mrežni sustav, primjenjuju se iste slabosti kao metode promjene izlaza. Za situacije s više izmjenjivača, biti će dovoljna jedinica spojena na istu mrežnu granu gdje će njihove ENS injekcije ometati neku drugu injekciju ili interakciju više jedinica, uzrokujući lažne signale da je u pitanju otočni rad. Većina današnjih izmjenjivača provjerava druge instalacije navedene metode i prilagođava trenutna vremena injektiranja, kako bi smanjila vjerojatnosti interferencije dva uređaja. Interferencija višestrukih jedinica može rezultirati neugodnim prekidanjima strujnih kola, ali su novi de-sinkronizirani projekti povećali broj jedinica koje se mogu spojiti bez smetnji. Suočavanje s promjenama impedancije distribucijske mreže zbog promjene topologije iste je slabost koja će zahtijevati nekoliko skupova programskih paketa, ili projekta koji povećavaju broj modela i verzija algoritama koji se mogu ugraditi paralelno na jedan točki zajedničkog spajanja, a da ne ometaju rad među sobom.



Slika 4.9. Projekt uređaja za automatsko odvajanje prema DIN –VDE-0126.

4.3. Komunikacijske metode

Treća kategorija metoda za otkrivanje otočnog rada temelji se na komunikaciji između distribuiranog izvora i distribucijske mreže. Tri glavne metode koje koriste komunikaciju su detaljno opisane u [118],:

- Napojeni vod koji služi kao nosač za komunikaciju između izmjenjivača i pomoćne mreže [141]. Neprekidni signal prenosi se putem komunikacijske mreže kroz vodove. Prijamnik je potreban za spoj sa distribuiranog izvora za otkrivanje gubitka ovog signala i time određivanje uvjeta otočnog rada.

- Signal proizveden isključenjem. Ova metoda pretpostavlja da je prekidač na napojnoj mreži opremljen odašiljačem, koji komunicira s distribuiranim izvorima kada se otvori i time šalje signal distribuiranom izvoru.

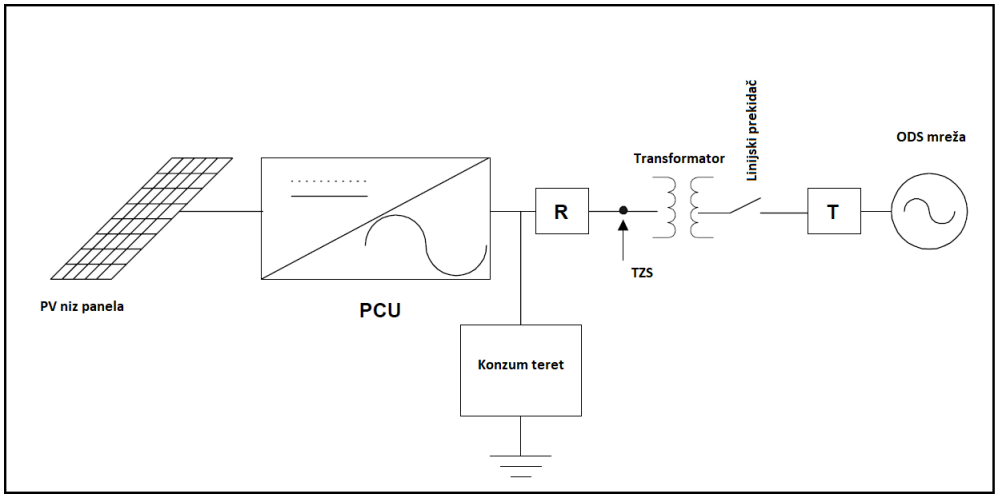
- SCADA kao metoda koristi postavljanje senzora napona na mjestu gdje je distribuiranog izvora spojen i integraciju tih senzora u SCADA sustav za praćenje i alarmiranje kada se foto naponski sustav isključi u slučaju otočnog rada [142].

Sa sve većim brojem distribuirani izvora spojenih na mrežu, nadzor napona u stvarnom vremenu za svaki izvor u distribucijskoj mreži postaje zahtjevan proces. Komunikacijske metode zahtijevaju efikasnu provedbu programa otkrivanja otočnog rada, što ih čini manje prihvatljivim za praktičnu provedbu i jer su skupe. Budući da komunikacija dodaje i troškove distribuiranom

izvoru i infrastrukturi distribucijske mreže, danas se te metode rijetko koriste. Koristeći komunikacijske standarde kao što su IEC 61850 [143] i njegova proširenja za distribuirane izvore [144], SCADA/DMS aplikacija se može primijeniti za komunikaciju sa svim distribuiranim izvorima u distribucijskoj mreži i informirati ih o otočnim uvjetima na mreži.

4.3.1. Napojeni vod koji služi kao nosač za komunikaciju

Predložena je upotreba komunikacijskih veza s dalekovodima (PLCC -eng. Power-line carrier communication) kao način rješavanja problema povezanih s detekcijom otočnog rada izmjenjivača [145]. PLCC sustavi šalju komunikacijski signal niske energije kroz sam vod. Slika 4.9. prikazuje primjer konfiguracije sustava koje uključuje metodu vodova kao nositelja komunikacije za sprječavanje otočnog rada distribuiranog izvora.



Slika 4.10. Podešenje sustava uključujući PLCC odašiljač (T) i prijemnik (R)

Budući da se vod koristi kao komunikacijski kanal, moguće je koristiti infrastrukturu PLCC tehnologije te kroz njen signal za ispitivanja prekida voda. Ako se osigura takav signal, jednostavan uređaj instalira na strani fotonaponske elektrane, u točki zajedničkog spajanja može se otkriti prisutnost ili odsutnost PLCC signala. Ako signal nestane, to ukazuje na prekid, a izmjenjivač se može isključiti. PLCC odašiljač (T) šalje signal duž voda do prijemnika (R). Potrebno je znati da se prijemnik nalazi na točki zajedničkog spajanja. Prijemnik se može uključiti u izmjenjivač, ili može biti odvojen i komunicirati s izmjenjivačem, ili može sadržavati vlastiti prekidač i ne mora se uopće priključiti na PCU. Kada se PLCC signal izgubi, prijemnik daje informaciju prekidaču otvori, ili može otvoriti svoj vlastiti prekidač za izolaciju foto naponskog izmjenjivača i tereta iza točke zajedničkog spajanja. Detekcija otočnog rada temeljena na PLCC-u olakšava korištenje foto naponskih sustava kao rezervnog napajanja, jer bi prijemnik mogao

isključiti korisnika iz točki zajedničkog spajanja s pomoćnim signalom bez isklopa samog izmjenjivača. Ta mogućnost može povećati vrijednost foto naponskih i drugih distribuiranih izvora za sve potrošače.

Moguće je koristiti distribucijski PLCC signal za detekciju otočnog rada, bez ometanja njegove uobičajene upotrebe i bez dekodiranja informacija u signalu. Metode PLCC-a trenutno se koriste za signale za punjenje baterijskih spremnika, koji se šalju iz distribucijskog postrojenja za nekritična opterećenja u razdobljima visokih opterećenja i koji se danas koriste u područjima gdje postoji visoka gustoća naseljenosti i industrijski kupci. Alternativno, automatizirano očitavanje brojila koristi signale koje korisnik šalje korisniku u malom broju distribucijskih područja. Da bi bio učinkovit u ovoj shemi, PLCC signal bi trebao imati tri karakteristike.

Prvo, on mora biti poslan od krajnjeg korisnika na kraj mreže do prijemnika. Nekoliko PLCC sustava koji se koriste za automatsko očitavanje brojila koriste signal koji se šalje samo od krajnjeg proizvođača do krajnjeg potrošača. Oni se mogu koristiti kao dio sheme za otkrivanje harmonika kao što je prethodno opisano, ali očito ne kao provjera kontinuiteta linije zasnovana na PLCC-u.

Drugo, signal treba koristiti kontinuirani prijenos. Ako je prijenos isprekidan, mogućnost njegovog korištenja kao testa za prekid voda se gubi, jer nije moguće razlikovati gubitak signala zbog prekida voda i gubitak signala zbog prestanka prijenosa dekodiranja signala. Također, upotreba kontinuiranog prijenosa čini sustav u biti sigurnim, u tome što kvar predajnika ili prijemnika rezultira gubitkom PLCC signala koji bi uzrokovao gašenje izmjenjivača.

Treće, signal bi trebao biti takav da će se dobro širiti kroz distribucijsku mrežu na koju su spojeni foto naponski izmjenjivači. Budući da će niz induktiviteta transformatora blokirati bilo koji visokofrekventni signal, ovaj zahtjev traži primjenu niskofrekventnih signala. Poželjni bi bili sub-harmonični signali, jer bi se oni lako širili kroz sustav i ne bi se pogrešno proizvodili pri otočnom radu, osim u vrlo nenormalnim uvjetima rada distribucijske mreže. Prevencija otočnog rada temeljena na PLCC-u ima višestruke prednosti, osobito s povećanom gustoćom distribuirane proizvodnje. Prvo, on nema zonu ne detekcije unutar širokog raspona opterećenja i obećava da će biti iznimno učinkovit u prevenciji otočnog rada. Drugo, ne zahtijeva nikakvu degradaciju u kvaliteti izlazne snage izmjenjivača, te ne uzrokuje nepovoljan utjecaj izmjenjivača na odziv sustava ili kvalitetu električne energije. Zapravo, u određenim okolnostima detekcija otočnog rada temeljena na PLCC-u mogla bi zapravo poboljšati osobine na razini sustava, dopuštajući izmjenjivaču i drugim distribuiranim izvorima da "prođe" kroz neke poremećaje i podrže napon sustava tijekom tih poremećaja. Treće, ne utječe na broj izmjenjivača u sustavu, te bi bio učinkovit

na bilo kojoj razini udjele distribuiranog izvora, s bilo kojom veličinom sustava i s bilo kojim tipom distribuiranog izvora. Četvrto, moguće je koristiti postojeće PLCC signale u tu svrhu, bez ometanja njihovih uobičajenih funkcija pomoću npr. jeftinog prijamnika. Dakle, ne postoji sukob između ove i drugih uporaba ograničene propusne moći distribucijske mreže. Peto, ako se koristi signal gore opisanog tipa, potreban je samo jedan odašiljač za pokrivanje velikog dijela mreže. Ne bi bilo potrebno zasebno serijski ili paralelni odašiljač imati instaliran za bolju pokrivenost mreže.

4.3.2. Signal generiran na isključenju distribucijskoj mreži-a

Kao što je upravo opisana metoda temeljena na PLCC-u, metoda signal generiran na isključenju distribucijskoj mreži-a (eng. Signal Produced by Disconnect - SPD), također se oslanja na komunikaciju između mreže i foto naponskih izmjenjivača kako bi se spriječi otočni rad. SPD se razlikuje od PLCC-bazirane metode u tome što se vod za napajanje ne koristi kao komunikacijski kanal. Umjesto toga, mrežni je prekidač opremljen malim odašiljačem koji šalje signal distribuiranom izvoru preko mikrovalne veze, telefonske linije ili na neki drugi način, kada se ponovno otvara prekidač. Na taj način, stanje prekidača je izravno priopćeno distribuiranom izvoru. Također, kada se koristi ova metoda treba koristiti kontinuirani nosač signal. To će spriječiti kvar metode zbog neispravnog odašiljača, kanala ili prijemnika. Također, ova metoda bi omogućila dodatnu kontrolu nad distribuiranim izvorima pomoću mrežnih programa u dispečerskim centrima, što bi rezultiralo koordinacijom između distribuiranih izvora i operatera distribucijskog sustava. Primjer situacije u kojoj bi takva koordinacija bila korisna, bila bi uvjet crnog starta (proces vraćanja dijela mreže pod naponom bez utjecaja vanjskog napajanja na njen pogon). Izmjenjivači se mogu koristiti za povratak slabih dijelova u distribucijskoj mreži, a kontrola i koordinacija izmjenjivača i alata može poboljšati karakteristike pokretanja sustava. Nažalost, ova metoda pati od mnogih nedostataka. Bilo bi potrebno koordinirati sve serijske ili paralelne sklopke koje vode do potencijalnog otočnog rada, kao što je to bio slučaj s umetanjem impedancije. Ako se koristi telefonska veza, potrebno je dodatno ožičenje za svaki distribuirani izvor u potencijalnom otočnom radu. To bi se moglo izbjeći uporabom mikrovalne veze, ali takva veza bi zahtijevala licenciranje, a "pokrivene rupe" bi mogle postojati u području koje bi potencijalno moglo stvoriti otočni rad, tako da bi foto naponski izmjenjivači na određenim mjestima mogli imati poteškoća s prijemom signala bez odašiljača ili pojačala. Navedeni problemi jasno pokazuju da bi ova metoda bila relativno skupa i mogla bi uključivati značajne komplikacije u vezi s izdavanjem dozvola i projekta same arhitekture mreže.

4.3.3. Nadzor, kontrola i prikupljanje podataka (eng. Supervisory Control and Data Acquisition -SCADA)

Uključivanje foto naponskih izmjenjivača u SCADA sustav je logičan izbor za prevenciju otočnog rada. Komunalni sustavi već koriste opsežnu komunikacijsku i senzorsku mrežu za kontrolu vlastitih procesa, praćenje stanja njihovih sustava i omogućavanje brzog odgovora na nepredviđene okolnosti. Većina distribucijskih sustava uključuje instrumentaciju od najviše naponske razine, do kontrolnog uređaja na najnižoj razini koji se može kontrolirati u distribucijskom sustavu (obično u distribucijskoj stanici), te tako SCADA komunikacijska mreža pokriva veći dio elektroenergetske mreže. Korištenje SCADA sustava za prevenciju otočnog rada je jednostavno. Kada je instaliran izmjenjivač, uređaji (senzori) za mjerenje napona se mogu instalirati u lokalni dio distribucijskog sustava, ako takvi senzori već ne postoje. Ako ti senzori detektiraju napon u trenutku kada je izvor napajanja odvojen od tog dijela sustava, mogu se oglasiti alarmi ili poduzeti korektivne mjere. Na primjer, ako je napon na strani kupca otkriven nakon ručne prorade prekidača, može se oglasiti alarm koji upozorava servisno osoblje da je vod još uvijek pod naponom. Također, rastavljač može biti usklađen s izmjenjivačem tako da se ne dogodi ponovno zatvaranje. Alternativno, ako se otkrije nenormalan napon na strani klijenta, rastavljač može dopustiti dulji "off" interval prije blokiranja, što izmjenjivaču daje dovoljno vremena da se isključi prije ponovnog uključenja. Konačno, ako su izmjenjivači bili spojeni na SCADA sustav, distribucijski operater mreže bi mogao imati određenu kontrolu nad izmjenjivačem. Djelovanje SCADA-a je u suštini isto kao i signali dobiveni metodom koja je upravo opisana. Ako je sustav ispravno koordiniran i sve potrebne komunikacijske veze su dostupne, ova metoda bi trebala eliminirati otočni rad i pružiti prednosti djelomične ili potpune kontrole od strane dispečerske službe. Ova metoda također ima i mnoge slabosti zbog generiranih signala nastalih isključivanjem mreže. Ako postoji više izmjenjivača, svi oni zahtijevaju odvojene instrumente i/ili komunikacijske veze. Drugi problem je taj da ova metoda zahtijeva veliku angažiranost korisnika u procesu instalacije i izdavanja dozvola, što bi predstavljalo glavobolju za manje sustave i moglo bi dodatno predstavljati trošak za distribuciju i potrošače. Osim toga, važno je napomenuti da se SCADA sustavi često ne protežu u sustav ispod razine pod stanica, tj. ne idu na niski napon, ali je ispod razine trafostanica, gdje ustvari postoje većina malih distribuiranih izvora.

Tablica 4.3 [118] oslanja se na glavne značajke metoda za detekciju otočnog rada distribuiranih izvora. Pasivne metode su osnovni zaštitni paket svakog distribuiranog izvora priključenog na mrežu. Danas se više preferiraju aktivne metode zbog njihove niske zone ne detekcije. Međutim, jedan od glavnih nedostataka koji mogu pridonijeti pomaku od korištenja aktivnih metoda je

njihov negativan doprinos kvaliteti energije u mreži. Buduća dostupnost komunikacijske mreže za električnu mrežu, u kombinaciji s većim interesom poduzeća za praćenje imovine u mreži, može olakšati pomak prema korištenju komunikacijskih metoda za otkrivanje otočnog rada.

Tablica 4.3. Usporedba metoda otkrivanja otočnog rada distribuiranih izvora [118].

Metoda	**Prednosti**	**Slabosti**	**Pozitivna za mrežu**
Pasivne	*Pozitivna za mrežu *Jednostavna i jeftina za primjenu	*zone ne detekcije velika u usporedbi sa ostalim metodama	DA
Aktivne	*malena zone ne detekcije *neke metode jednostavne za primjenu	*Može stvoriti probleme s kvalitetom el. energije *Može inicirati lažni signal isključenja *Neke su teške za primjenu *Moguća interakcija između izmjenjivača na istoj mreži	*pogodna za konačan broj izvora
Komunikacijske	*Pouzdana *Neke metode jednostavne za primjenu *Teoretski nema zone ne detekcije	*Skupe za primjenu *Potrebno komunikacijska infrastruktura *Neophodno uključivanje ODS komponenti u rad metodu	DA

5. METODE UMJETNE INTELIGENCIJE

Kada se raspravlja o metodama umjetne inteligencije koje su proistekle iz informacijskih znanosti, onda se govori o: neuronskim mrežama (NN), neizrazitoj logici (FL), raznim evolucijskim algoritmima, dubokom učenju (DL), metoda potpornih vektora (MPV) i hibridnim metodama koje su kombinacija navedenih. Međutim, lista metoda se ovim ne završava, nego se proširuje metodama strojne inteligencije sa inteligencijom roja čestica, teorije kaosa, razne stohastičke metode itd. Kako imena nekih metoda govore, neke su metode kreirane po uzoru na biološke sustave koji se ponašaju inteligentno ili su arhitektura inteligentnog ponašanja, pa su samim time postali modeli za kreiranje umjetnih inteligentnih metoda, koje oponašaju svoje uzore iz prirode. Većina problema koji se rješavaju sa metodama umjetne inteligencije su uglavnom problemi za koje ne postoji učinkoviti način rješavanja standardnim matematičkim alatima, ili su potrebni specijalizirani postupci koji često nedostaju. Složenost problema vrlo često ne omogućava učinkovito djelovanje standardnih matematskih modela.

Kako se moglo vidjeti u poglavlju 2 ove disertacije, gdje se predstavila literatura koja obrađuje slične ili iste teme, metode umjetne inteligencije nisu nepoznat mehanizam rješavanja problema koji su specifični, dok se konkretne matematske metode ne mogu elegantno i jednostavno uključiti u rješavanje navedenih problema. Upravo zbog svoje sposobnosti da se takvi problemi rješavaju na većem apstraktnom nivou za korisnika, u ovom slučaju inženjera, od onog kojem pripadaju matematske analitičke metode, metode umjetne inteligencije dobivaju svoje mjesto u elektroenergetici te se na nov i brz način rješavaju problemi koji su bili do sada nerješivi.

Iako se metode umjetne inteligencije tek zadnjih nekoliko godina uvode kao standardne, koje se redovito koriste u optimizaciji, predviđanju, klasifikaciji, traženju rješenja na osnovu kognitivnog znanja, ipak njihova definicija nije novijeg datuma. U referatu [146] autor Jyh-Shing R. Jong, već je 1991. godine razmatrao mogućnost kombiniranja metode neizrazite logike sa Kalmanovim filterom i generaliziranim neuronskim mrežama kao novu hibridnu metodu za rješavanje problema. Metoda je uključivala istreniran sustav neizravne logike u kombinaciji sa neuronskom mrežom i na kraju jednim krugom Kalmanovog filtera, kojim se provjeravaju rezultati iz tog hibridnog sustava, te time se ponovno provjeravaju izlazi prema treniranim vrijednostima. U referatu se dva problema riješena:

1. nema formalnih načina za pretvaranje iskustava ili znanja stručnjaka, u bazu pravila i bazu podataka sustava neizrazitog zaključivanja,

2. nedostatak prilagodljivosti ili algoritama učenja za podešavanje funkcija pripadnosti, kako bi se smanjila pogreška.

Prvi se problem, međutim, smatra djelomično riješenim, jer je u navedenom pristupu određen broj funkcija pripadnosti, kao i broj pravila. Rad koristiti metodu grupiranja za grubo pronalaženje potrebnog broja funkcija pripadnosti, a zatim primjenjuje pronalaske optimalnih oblika tih funkcija. Budući da je predloženi algoritam učenja postupak spuštanja gradijenta, ponekad se može zaustaviti oko lokalnih minimuma. Međutim, konačni prosječni postotak pogreške i dalje je prihvatljiv, iako globalni minimum nije pronađen. Nadalje u sustavu neizrazitog zaključivanja koji se kombinira s umjetnim neuronskim mrežama, ako je dostupno prethodno znanje o izvornom sustavu, možemo ga ugraditi u početne vrijednosti parametara. To osigurava početnu točku u blizini optimalnog prostora u premisi, čime se smanjuje mogućnost zarobljavanja u lokalnim minimumima tijekom procesa učenja.

Navedenim referatom se tada već krenulo u razvijanje kognitivnih metoda uz pomoć već dostupnih tehnika umjetne inteligencije, te se time više približilo konkretnim problemima u elektroenergetici.

Ovo poglavlje se sastoji od tri cjeline: u pod poglavlju 5.1 objašnjena je detaljno metoda adaptivnih neuronskih neizrazitih zaključivanja (ANFIS-a), s tim da je naglasak na samom matematskom aparatu. U pod poglavlju 5.2 je opisana detaljno metoda dubokog učenja (DL) , s naglaskom na konvolucijske neuronske mreže. U pod poglavlju 5.3 je objašnjena metoda strojna potpora vektorima (MPV), s naglaskom na klasifikaciju objekata u klastere uz pomoć kernela, što je glavni alat navedene metode. S tim pregledom se kompletira uvid u metode umjetne inteligencije koji je počeo sa pregledom literature.

5.1. Adaptivni sustav neuro-neizrazitog zaključivanja (en. ANFIS)

Postoje različita područja primjene u kojima su umjetne neuronske mreže i neizrazita logika uspješno provedeni, bilo pojedinačno ili kao nadopuna drugih metoda. Kombinirani neuro-fuzzy pristup nedavno je prihvaćen od istraživača koji rade u različitim područjima. Sveobuhvatna studija autora referata [147] prikazuje primjenu u različitim područjima metoda mekoga računarstva, koje se posebno fokusiraju na neuronske mreže i neizrazitu logiku, i mogu se naći u referatu [148]. Tu je tehniku, koja se bavila nelinearnim i složenim problemima raspravio J. R. Jang. Ova studija uključuje sustav neizrazitog zaključivanja koji se primjenjuje u formiranju

adaptivnih mreža. Predloženi ANFIS može generirati mapiranje ulazno-izlaznih podataka, temeljeno na ljudskom znanju i unaprijed određenim parovima ulazno-izlaznih podataka pomoću hibridnog algoritma. Simulacijske studije za arhitekturu sustava koriste se za modeliranje nelinearnih funkcija, identifikaciju nelinearnih komponenti u mreži u upravljačkim sustavima i predviđaju stohastičkih procesa kao i kaotične serije podataka, a sve to daje izvanredne rezultate. Nadalje, autor je usporedio sustav s umjetnim neuronskim mrežama na prethodno testiran sustav.

Sveobuhvatno istraživanje algoritama za stvaranje neuro-neizrazitih pravila za primjenu u stvarnom vremenu ispituje S. Mitra i sur. u radu [149]. Predloženi algoritmi koriste neizrazite skupove i pomoć u informacijama s ljudskim razumljivijem ili prirodnom obliku i mogu odrediti nesigurnost na različitim razinama. Opsežno istraživanje pokazuje da se kvalitativno bolji rezultati dobivaju primjenom ekstrakcije i preciziranjem pravila iz dodatnih uzoraka za treniranje . Modeli unutar ANFIS-a su skupina pravila temeljena na razini njihove međusobne sinteze. Predložena metodologija ima dodatnu korist u drugim softverima kao što su genetski algoritmi i ukupni skupovi generalizacije. Na temelju sustava neizrazitog zaključivanja (FIS) osigurana je primjena u stvarnom životu i u području medicine. Korisnost adaptivnog neuro-fuzzy sustava za predviđanje hrapavosti površine u operaciji okretanja, ispituje S.S. Roy [150]. Za modeliranje problema korišteni su različiti ulazni parametri, odnosno brzina rezanja, brzina uvlačenja i dubina rezanja. Tijekom faze osposobljavanja usvojene su dvije različite funkcije pripadnosti u obliku trokuta i zvona. Ovaj pristup uspoređuje vrijednosti ANFIS-a s eksperimentalnim podacima za funkcije pripadnosti u obliku trokuta i zvona. Razvijeni model temeljen na prvome redu Takagi-Sugeno i Kang za okretanje, pokazao je veću točnost predviđanja pomoću funkcije pripadnosti u zvonu.

Arshdeep i sur. [151] raspravljali su o novom pristupu rješavanju problema za klimatizacijski sustav pomoću Mamdani i Sugeno modela. Ovaj pristup ističe osnovnu razliku između sustava neizrazite logike tipa Mamdani i tipa Sugeno. Ova studija predlaže odabir poboljšane funkcije pripadnosti dvaju FIS sustava za klimatizaciju. Na temelju provedenog izvođenja sustava zaključivanja iz ovog rada, zaključeno je da za klimatizacijski sustav tipa FIS i tipa Sugeno tipa FIS rade slično, ali pomoću Sugenskog FIS modela, omogućuje rad klima uređaja u punom snagu. Primjene u medicinskoj dijagnostici s ANFIS-om uveo je Tamer [152]. Predloženi pristup koristi sustav baziran na adaptivnoj mreži Sugeno tipa (ANFIS) za prognoziranje postojanja mikrobakterija tuberkuloze. Skup podataka prikupljen je od 503 različite evidencije bolesnika, dobivene od privatne zdravstvene klinike. Zapis o pacijentu ima 30 različitih atributa koji obuhvaćaju podatke o demografskim i medicinskim ispitivanjima. Model ANFIS generiran je korištenjem 250 zapisa. Predloženi model klasificira slučajeve s točnošću od 97%, dok grubi skup

algoritma čini istu klasifikaciju s točnošću od 92%. Ovo učenje ima doprinos pri izboru pacijenata prije medicinskih ispitivanja. Netočnost matematičkog modeliranja postrojenja obično degradira rad regulatora, posebno za nelinearne i složene probleme upravljanja. Korištenje ANFIS kontrolera za upravljanje nelinearnim sustavom objasnio je A.V Gite [153]. Simulacijska studija pokazuje da je ANFIS najbolji kontroler u usporedbi s klasičnim PID regulatorom. Predložena tehnika može se koristiti u regulatoru temperature vode.

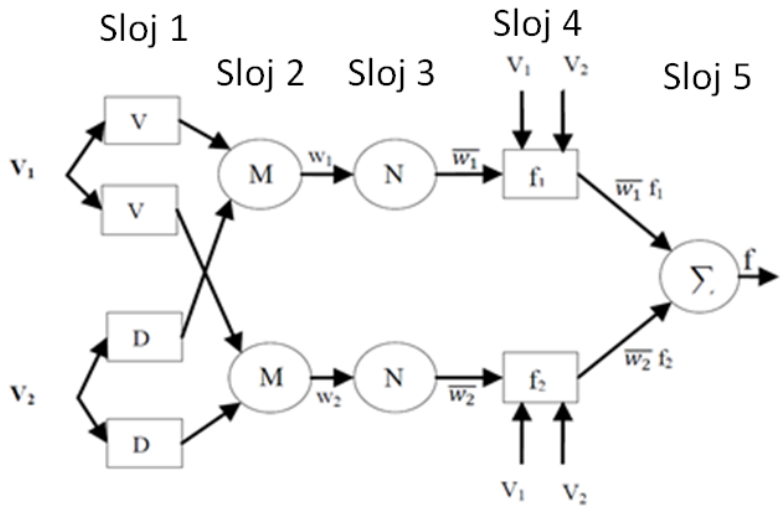
Navneet [154] je predložio medicinski ekspertni sustav za dijagnosticiranje tuberkuloze. Predloženi sustav medicinskih stručnjaka (MES) trebao je pomoći liječnicima dijagnosticirati simptome povezane s tropskom bolešću, sugeriraju vjerojatnu bolest i potiču moguće liječenje na temelju dijagnoze MES-a. Abu-Rub i sur. [155] predstavili su primjenu ANFIS-a za maksimalnu isporuku snage na opterećenje, temeljeno na praćenju točke najveće snage. Predloženi MPPT temeljen na ANFIS-u, nudi iznimno brz dinamički odgovor s velikom točnošću. Tehnika projiciranja autora testirana je za izolirane uvjete opterećenja. Za validaciju predložene sheme koriste se simulacijski i eksperimentalni pristupi [22].

C. Loganathan i sur. [156] uspješno je razmotrio sustav koji koristi neizraziti sustav za karakteriziranje znanja, na način koji se može interpretirati i sposobnost učenja izvedenu iz Runge-Kutta metode učenja (RKLM) za prilagodbu funkcija i parametara članstva, kako bi se povećala učinkovitost sustava. Otkrivanje prikladnih funkcija pripadnosti i neizrazitih pravila, često su naporan proces pokušaja i pogrešaka. To zahtijeva od korisnika da prepoznaju podatke prije treninga, što je obično teško postići kada je baza podataka relativno velika. Kako bi se prevladali ovi problemi, autor je objasnio hibrid neuronske mreže s povratnim širenjem, i RKLM može kombinirati prednosti dvaju sustava.

Ovaj odjeljak opisuje klasu Neuro-neizrazitih sustava, zajedno s arhitekturama i postupcima učenja adaptivnih mreža. Temeljna mrežna struktura je nad skup svih vrsta paradigmi neuronskih mreža, sa sposobnostima učenja pod nadzorom. Neuro-neizraziti sustavi, kombinacija ANN s neizrazitom logikom, obično imaju prednost što omogućuju jednostavno prevođenje konačnog sustava u skup „ako-tada“ pravila, a neizraziti sustav može se promatrati kao struktura neuronske mreže sa znanjem koja se raspoređuje kroz jakost veze između slojeva neuronske mreže. Istraživanja i primjena na neuro-neizrazitoj metodi zaključivanja, jasno su pokazala da su neuronski i neizraziti hibridni sustavi korisni u područjima kao što su primjena kod postojećih algoritama za umjetne neuronske mreže (ANN) i izravno prilagođavanje znanja, artikulirano kao skup neizrazitih lingvističkih pravila. Adaptivna mreža, kao što joj i ime kaže, je mrežna struktura

koja se sastoji od čvorova i usmjerenih veza, a sveukupno ulazno-izlazno ponašanje određeno je vrijednostima skupa promjenjivih parametara kroz koje su čvorovi povezani [147]. Adaptivni sustav koristi hibridni algoritam učenja za identifikaciju parametara neizrazitog zaključivanja Sugenovog tipa. On primjenjuje kombinaciju metode najmanjih kvadrata i metode spuštanja gradijenta povratka za vježbanje FIS parametara funkcije pripadnosti, kako bi oponašao zadani skup podataka o obuci [157]. Mreža uči u dvije glavne faze. U fazi učenja algoritma, posljedični se parametri identificiraju i procjenu metodom najmanjih kvadrata. U zaostaloj fazi signali pogreške, koji su derivati kvadrata pogreške u odnosu na svaki izlaz čvora, propagiraju unatrag od izlaznog sloja do ulaznog sloja. U ovoj unatrag metodi, prolazni parametri se ažuriraju algoritmom za silazak u gradijentu. Faza učenja ili osposobljavanja neuronske mreže je proces kojim se određuju vrijednosti parametara, koji se dovoljno uklapaju u podatke o obuci. ANFIS trening može koristiti alternativne algoritme kako bi se smanjila pogreška treninga. Kombinacija algoritma gradijentnog spuštanja i algoritma najmanjih kvadrata, koristi se za učinkovito traženje optimalnih parametara. Glavna prednost takvog hibridnog pristupa je konvergencija mnogo brža, jer smanjuje dimenzije prostora pretraživanja metode povratnog širenja koja se koristi u neuronskim mrežama. ANFIS neizraziti Sugeno model je postavljen u okviru adaptivnog sustava koji služi za izgradnju modela i vrednovanje razvijenog modela, kako bi se olakšalo osposobljavanje i prilagodbu [150]. Kako se može vidjeti iz pregleda literature, ANFIS je veoma poznata i zastupljena metoda za rješavanje nelinearnih problema, gdje se može prikupiti povijesni trend nekakvih ulaznih veličina sa uparenim izlazima koji se traže kao rezultat rada ANFIS-a.

Adaptivna mreža je višeslojna mreža koja se sastoji od čvorova povezanih usmjerenim vezama, u kojima svaki čvor obavlja određenu funkciju na svojim dolaznim signalima za generiranje jednog izlaznog čvora. Svaka veza u adaptivnoj mreži određuje smjer protoka signala iz jednog čvora u drugi. Konkretno, konfiguracija adaptivne mreže obavlja funkciju statičkog čvora na svojim dolaznim signalima generirajući izlaz jednog čvora, a svaka funkcija čvora je parametrizirana funkcija s promjenjivim vrijednostima. Promjenom ovih parametara mijenjaju se funkcije čvora kao i cjelokupno ponašanje adaptivne mreže. Slika 5.1 prikazuje cjelokupnu arhitekturu sustava koja se sastoji od pet slojeva, odnosno neizrazitog sloja, sloja proizvoda, normaliziranog sloja, defazifikacijskog sloja i ukupnog izlaznog sloja.



Slika 5.1. Osnovna arhitektura ANFIS sustava sa dva ulaza i jednim izlazom [147].

S ulazno/izlaznim podacima za zadani skup parametara, metoda ANFIS modelira sustav neizrazitog zaključivanja (FIS), čiji se parametri funkcije pripadnosti podešavaju (prilagođavaju) koristeći ili algoritam povratnog širenja, ili u permutaciji s metodom najmanjih kvadrata. Glavni cilj ANFIS-a je odrediti optimalne vrijednosti ekvivalentnih parametara neizrazitog zaključivanja primjenom algoritma učenja. Optimizacija parametara vrši se na način da se tijekom vježbanja minimizira pogreška između cilja i stvarnog izlaza. Za optimizaciju se koristi hibridni algoritam, koji je kombinacija najmanje kvadratne procjene i metode gradijentnog spuštanja. Parametri koje treba optimizirati u ANFIS-u su parametri premisa. Ti parametri određuju oblik funkcija pripadnosti [158]. Kako bi se smanjila mjera greške, bilo koja od nekoliko rutina optimizacije može se primijeniti nakon konstituiranja funkcija pripadnosti. Skup parametara adaptivne mreže omogućuje neizrazitim sustavima učenje iz podataka koje modeliraju. Pretpostavka je da razmatrani adaptivni sustav ima dva ulaza V1 i V2 i jedan izlaz f. Proučimo sustav Takagi, Sugeno i Kang (TSK) prvog reda, koji sadrži dva pravila:

Pravilo 1: ako (v je V_1) i (d je D_1), onda je $f_1=p_1v+q_1d+r_1$

Pravilo 2: ako (v je V_2) i (d je D_2), onda je $f_2=p_2v+q_2d+r_2$

gdje su p_1, p_2, q_1, q_2, r_1 i r_2 linearni parametri, a V_1, V_2, D_1 i D_2 nelinearni parametri, u kojima su V_1 i D_1 funkcije pripadnosti ANFIS-a, a p_1, q_1, r_1 su posljedični parametri. Da bismo odrazili prilagodljive sposobnosti, koristimo oboje: krug i kvadrat. Krug označava fiksni čvor, dok kvadrat označava adaptivni čvor, tj. parametar se može promijeniti tijekom prilagodbe ili vježbanja. ANFIS se koristi od integracije neizrazite logike i neuronske mreže. Prilikom projektiranja ANFIS

modela, iznimno je važno da broj vježbi treninga, broj funkcija pripadnosti i broj neizrazitih pravila budu precizno podešeni. Mapiranje tih parametara je vrlo bitno za sustav, jer može dovesti do prevelikog uklapanja podataka u sustav ili neće moći uskladiti podatke. Ovo podešavanje se može postići korištenjem hibridnog algoritma, koji kombinira metodu najmanjih kvadrata i metodu gradijentnog spuštanja s metodom srednje kvadratne pogreške. Manja razlika između rezultata ANFIS-a i željenog cilja znači bolji (točniji) ANFIS sustav. Stoga nastojimo smanjiti pogrešku u treningu [152]. Očekivana je i razvijena integracija između neizrazite logike i neuronske mreže, odnosno neizrazite neuronske mreže (FNN). Općenito, raspored fuzzy logike i neuronske mreže nazivaju se ANFIS. Neuronski sustav ima mnogo ulaza i također ima višestruke izlaze, ali neizrazita logika ima mnogo ulaza i jedan izlaz, tako da je kombinacija ova dva poznata kao ANFIS.

5.1.1. Slojevi ANFIS-a

Radi jednostavnosti, sustav neizrazitog zaključivanja razmatra dva ulaza *v, d* i jedan izlaz *f*. U nastavku je prikazan kratak sažetak pet slojeva ANFIS algoritma.

Sloj 1

Svaki ulazni čvor u ovom sloju je adaptivni čvor koji proizvodi stupanj pripadnosti jezične oznake. To je neizraziti sloj u kojem su *v* i *d* ulaz sustava. O_1, je izlaz i-tog čvora sloja 1. Svaki adaptivni čvor je kvadratni čvor s kvadratnom funkcijom predstavljenom pomoću jednadžbe (5-1):

$$O_{1,i} = \mu_{v,i}(v)\, za\, i = 1,2 \qquad O_{1,j} = \mu_{d,j}(v)\, za\, j = 1,2 \tag{5-1}$$

gdje $O_{1,i}$, i $O_{1,j}$, označavaju izlaznu funkciju, a $\mu_{v,i}$ i $\mu_{d,j}$ označavaju funkciju pripadnosti. Na primjer, ako izaberemo funkciju trokutastog izgleda kao funkciju pripadnosti, $\mu_{v,i}(v)$ je dano kao:

$$\mu_{vi}(v) = \max\left[min\left(\frac{v - a_i}{b_1 - a_i}, \frac{c_i - v}{c_i - b_i} \right), 0 \right] \tag{5-2}$$

gdje je $\{a_i, b_i, c_i\}$ parametar trokutne funkcije pripadnosti. U drugom primjeru, ako odaberemo $\mu_{v,i}(v)$ u obliku zvona:

$$\mu_{vi}(v) = \frac{1}{1 + \left\{ \left(\frac{v - c_i}{a_i} \right)^2 \right\}^{b_i}} \tag{5-3}$$

gdje je {a_i, b_i, c_i} skup parametara koji u skladu s tim mijenja oblike MF-a. Vrijednost a_i i c_i koja se može podesiti za promjenu središta i širine funkcije pripadnosti, a zatim bi se koristiti za kontrolu nagiba na točkama prijelaza sljedeće funkcije pripadnosti. Parametri u ovom sloju nazivaju se "parametrima ulaznih vrijednosti“.

Sloj 2

Ovaj sloj provjerava težine svake funkcije pripadnosti, prima ulazne vrijednosti v_i iz prvog sloja i djeluje kao funkcija pripadnosti za predstavljanje neizrazitih skupova odgovarajućih ulaznih varijabli. Svaki čvor u ovom sloju je fiksni čvor označen s M i izlaz se izračunava pomoću umnoška svih dolaznih signala. Izlaz u ovom sloju može se prikazati pomoću jednadžbe (5-4):

$$O_{2,i} = w_i = \mu_{v,i}(v).\mu_{Dj}(d), i = 1,2 \tag{5-4}$$

Koja prikazuje snagu aktivacije neurona. Općenito, bilo koji T_{norm} operator koji izvodi neizrazito AND, može se koristiti kao funkcija čvora u ovom sloju.

Sloj 3

Svaki čvor u ovom sloju je fiksiran i označen krugom označenim s N, što ukazuje na normalizaciju snage iz prethodnog sloja. Ovaj sloj obavlja usklađivanje pred-uvjeta neizrazitih pravila, tj. izračunava razinu aktivacije svakog pravila, a broj slojeva jednak je broju neizrazitih pravila. I-ti čvor u ovom sloju izračunava odnos snage i-tog pravila prema zbroju svih pravila paljenja. Izlaz ovog sloja može se izraziti kao w_i pomoću jednadžbe 5-5:

$$O_{3,i} = \overline{w_i} = \frac{w_1}{w_1 + w_2}, i = 1,2 \tag{5-5}$$

Zbog praktičnosti, izlazi ovog sloja će se zvati kao normalizirane snage aktivacije.

Sloj 4

Ovaj sloj osigurava izlazne vrijednosti y, koje su rezultat zaključivanja pravila. Rezultirajući izlaz je jednostavno proizvod normalizirane snage aktivacije i polinoma prvog reda. Ponderirani izlaz pravila predstavljen funkcijom čvora kao:

$$O_{4,i} = \overline{w_i} f_i = \overline{w_i}(p_i v + q_i d + r_i), i = 1,2 \tag{5-6}$$

gdje $O_{4,i}$ predstavlja izlaz 4 sloja. U ovom sloju, p_i, q_i i r_i su linearni parametar ili slijedni parametar.

Sloj 5

Taj se sloj naziva izlazni sloj koji sumira sve ulaze koji dolaze iz sloja 4 i pretvara neizrazite rezultate klasifikacije u oštre (eng. Crisp) vrijednosti. Ovaj se sloj sastoji od jednog fiksnog čvora označenog kao „Σ". Ovaj čvor izračunava zbroj svih dolaznih signala izračunatih pomoću jednadžbe 5-7.

$$O_{5,i} = \sum_i \overline{w_i} f_i = \frac{\sum_i w_i f_i}{w_1 w_2}, i = 1,2 \tag{5-7}$$

Prema tome, opaženo je da kada su vrijednosti parametra premisa fiksne, ukupni izlaz adaptivne mreže može se izraziti kao linearna kombinacija posljedičnog parametra. Konstruirana mreža ima potpuno istu funkciju kao Sugeno fuzzy model. Ukupni izlaz sustava (z) može se izraziti kao u jednadžbi (5-8). Može se primijetiti da se arhitektura ANFIS-a sastoji od dva prilagodljiva sloja, odnosno prvog sloja i četvrtog sloja. Tri modificirana parametra $\{a_i, b_i, c_i\}$ su takozvani parametar premisa u prvom sloju, a u četvrtom sloju postoje i tri promjenjiva parametra $\{p_i, q_i, r_i\}$ koji se odnose na polinom prvog reda. Ovi parametri su tzv. posljedični parametri [150].

$$z = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 + \ldots + \frac{w_n}{w_{n-1} + w_n} f_n$$

$$z = \overline{W_1}\left(p_1 Q + q_1 M + \ldots + m_1 F + r_1\right) + \ldots + \left(\overline{W_n}\left(p_n Q + q_n M + \ldots + m_n F + r_n\right)\right. \tag{5-8}$$

Neuro-adaptivne tehnike učenja, daju metodu za postupak neizrazitog modeliranja kako bi saznali informacije o skupu podataka. Ona izračunava parametre funkcije pripadnosti koji najbolje omogućuju pridruženom sustavu neizrazitog zaključivanja praćenje zadanih ulaznih / izlaznih podataka. Parametri povezani s funkcijama pripadnosti mijenjaju se kroz proces učenja. Kako bi se što učinkovitije nosili s problemima stvarnog svijeta, zadatak algoritma učenja za ovu arhitekturu je podešavanje svih parametara koji se mogu mijenjati, kako bi se formulirao ANFIS izlazni podatak koji odgovara podacima obuke. Kako bi se poboljšala brzina konvergencije, hibridna mreža može se obučiti hibridnim algoritmom učenja koji kombinira metodu najmanjeg kvadrata i može se koristiti metoda pada gradijenta. Metoda najmanjih kvadrata, može se koristiti za identificiranje optimalnih vrijednosti slijednog parametra na sloju 4, s fiksnim parametrom premise. Gradijentni vektor daje mjeru koliko dobro sustav neizrazitog zaključivanja modelira ulazne/izlazne podatke za zadani skup parametara. Kada se dobije vektor gradijenta, može se primijeniti bilo koja od nekoliko rutina optimizacije, kako bi se parametri prilagodili i smanjila neka mjera pogreške. Kada parametri premise nisu fiksni, prostor pretraživanja postaje veći i

konvergencija treninga postaje sporija. Hibridni algoritam sastoji se od prolaska prema naprijed (LSM) i zaostalog prolaza tj. prolaza unazad (GDM). Jednom kada se pronađu optimalni slijedni parametri, počinje prolazak unatrag. U prolazu unatrag, greške se propagiraju unatrag, a parametri premisa koji odgovaraju neizrazitim skupovima u ulaznoj domeni, ažuriraju se metodom gradijentnog spuštanja [150]. ANFIS koristi kombinaciju procjene najmanjih kvadrata i povratnog propagiranja za procjenu parametara funkcije pripadnosti. Dva prolaza u hibridnom algoritmu učenja za ANFIS, prikazana su u tablici 5.1.

Tablica 5.1.. Prolazi hibridnog algoritma učenja [147].

	Prolazak unaprijed	**Prolazak unatrag**
Parametri premise	Fiksiran	Opadanje gradijenta
Posljedični parametri	Najmanji kvadrat	Fiksiran
Signali	Izlazi čvorova	Signal greške

Izlazna pogreška se koristi za prilagođavanje parametara premise pomoću standardnog algoritma za povratno rasprostiranje, kako bi se minimizirala funkcija kvadratne greške definirane pomoću jednadžbe (5-9). Dokazano je da je ovaj hibridni algoritam vrlo učinkovit u obuci ANFIS-a.

$$E(\theta) = \sum_{i=1}^{m} (z_i - a_i^T \theta)^2 = e^T e = (z - A\theta)^T (z - A\theta) \tag{5-9}$$

gdje je e = z - $A\theta$ vektor pogreške dobiven specifičnim izborom θ. U jednadžbi (50), kvadratna pogreška je minimizirana i naziva se najmanji kvadratni procjenitelj (LSE) [159]. Stoga se hibridni algoritam učenja može primijeniti izravno. Specifičnije, signali greške umnažaju se unatrag, a parametri premise se ažuriraju pomoću gradijentnog spuštanja (GD), a izlazi čvorova idu naprijed dok sloj 3 i posljedični parametri nisu identificirani metodom najmanjeg kvadrata (LS). Ovo hibridno učenje strukturirano je tako da se određivanjem, linearnim i nelinearnim parametrima izražava svaka iteracija (epoha) GD ažuriranja nelinearnih parametara, a LS slijedi za identifikaciju linearnih parametara [160].

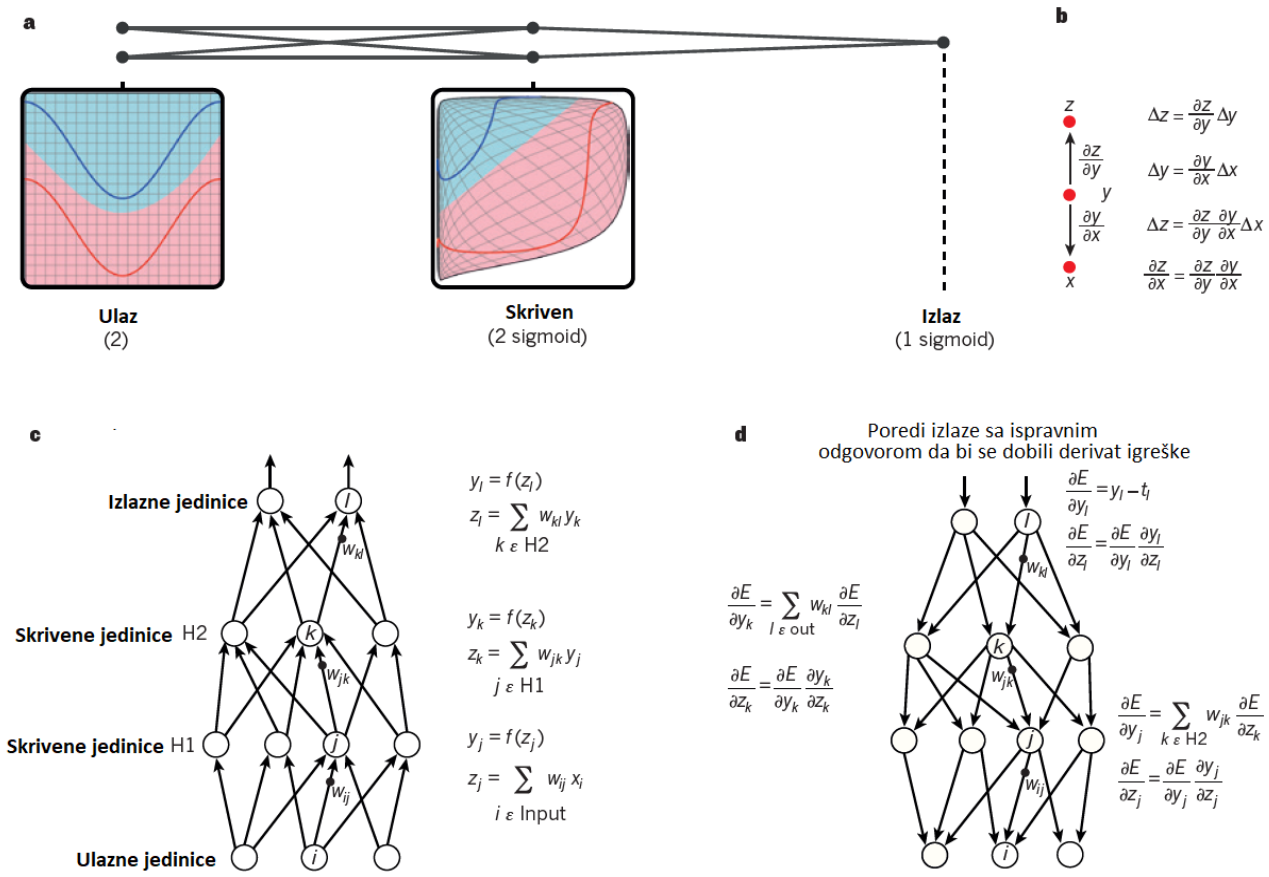
5.2. Duboko Učenje (eng. Deep Learning – DL)

Sustavi strojnog učenja koriste se za identifikaciju objekata u slikama, pretvorbu govora u tekst, podudaranje vijesti, postove ili proizvode s interesima korisnika te odabir relevantnih rezultata

pretraživanja. Ove aplikacije sve više koriste klasu tehnika nazvanu duboko učenje (eng. Deep Learning – DL). Konvencionalne tehnike strojnog učenja, bile su ograničene u sposobnosti obrade prirodnih podataka u svom izvornom obliku. Desetljećima je projektiranje sustava za prepoznavanje uzoraka ili strojno učenje zahtijevalo pažljivo inženjerstvo i znatnu stručnost u toj domeni, kako bi se projektirao uređaj za izvlačenje značajki koji je transformirao sirove podatke (kao što su vrijednosti piksela slike) u odgovarajući interni prikaz ili vektor značajki, iz kojeg podsustav za učenje, često klasifikator, može otkriti ili klasificirati uzorke na ulazu. Učenje reprezentacije je skup metoda koje omogućuju stroju da se hrani sirovim podacima i da automatski otkrije reprezentacije potrebne za otkrivanje ili klasifikaciju. Metode dubinskog učenja su metode učenja reprezentacije s višestrukim razinama, koje se dobivaju komponiranjem jednostavnih, ali nelinearnih modula, od kojih svaki pretvara prikaz na jednoj razini (počevši od izvornog ulaza) u reprezentaciju na višoj, malo više apstraktnoj razini. Sa skupom dovoljno takvih transformacija, mogu se naučiti vrlo složene funkcije. Za klasifikacijske zadatke, viši slojevi predstavljanja pojačavaju aspekte inputa, koji su važni za diskriminaciju i suzbijaju irelevantne varijacije [161]. Slika, na primjer, dolazi u obliku niza vrijednosti piksela, a naučene značajke u prvom sloju prikazivanja tipično predstavljaju prisutnost ili odsutnost rubova na određenim orijentacijama i lokacijama na slici. Drugi sloj obično detektira motive uočavanjem određenih rasporeda rubova, bez obzira na male varijacije u rubnim položajima. Treći sloj može sastaviti motive u veće kombinacije koje odgovaraju dijelovima poznatih objekata, a sljedeći slojevi će otkriti objekte kao kombinacije tih dijelova. Ključni aspekt dubokog učenja je da ovi slojevi značajki nisu projektirani od strane ljudskih inženjera, oni se uče iz podataka pomoću postupka opće namjene učenja. Duboko učenje čini veliki napredak u rješavanju problema, koji su se odupirali najboljim pokušajima zajednice umjetne inteligencije dugi niz godina. Pokazalo se da je vrlo dobar u otkrivanju zamršenih struktura u visoko dimenzionalnim podacima, te je stoga primjenjiv na mnoge domene znanosti, poslovanja i vlade. Osim analize zapisa u prepoznavanju slika [162] i prepoznavanja govora [163], pobijedila je druge tehnike strojnog učenja u predviđanju aktivnosti potencijalnih molekula lijeka [164], analizirajući podatke o akceleratoru čestica [165], rekonstruirajući sklopove mozga [166], te predviđajući učinke mutacija u ne kodirajućoj DNA na ekspresiji gena i bolesti [167]. Možda je još više iznenađujuće da je duboko učenje dalo iznimno obećavajuće rezultate za različite zadatke u razumijevanju prirodnog jezika, posebno klasifikacija tema, analiza sentimenta, odgovaranje na pitanja. Autori referata [161] smatraju da će duboko učenje imati mnogo više uspjeha u bliskoj budućnosti jer zahtijeva vrlo malo ručne izrade, tako da lako može iskoristiti povećanje količine dostupnih izračuna i podataka.

Najčešći oblik strojnog učenja, dubok ili ne, je nadzirano učenje. Zamislimo da želimo izgraditi sustav koji može klasificirati slike koje sadrže, recimo, kuću, automobil, osobu ili kućnog ljubimca. Prvo prikupljamo veliki skup podataka o kućama, automobilima, ljudima i kućnim ljubimcima, od kojih je svaki označen kategorijom. Tijekom treninga, stroju se prikazuje slika i proizvodi izlaz u obliku vektora rezultata, po jedan za svaku kategoriju. Želimo da željena kategorija ima najviše bodova svih kategorija, ali to se vjerojatno neće dogoditi prije treninga. Mi izračunavamo objektivnu funkciju koja mjeri pogrešku (ili udaljenost) između izlaznih rezultata i željenog uzorka rezultata. Uređaj zatim mijenja svoje unutarnje podesive parametre kako bi smanjio ovu pogrešku. Ovi podesivi parametri, koji se često nazivaju utezima, stvarni su brojevi koji se mogu vidjeti kao "gumbi" koji određuju ulazno-izlaznu funkciju stroja. U tipičnom sustavu dubokog učenja, mogu postojati stotine milijuna tih podesivih težina i stotine milijuna označenih primjera s kojima bi se stroj mogao trenirati. Da bi se ispravno prilagodio vektor težine, algoritam učenja izračunava vektor gradijenta koji, za svaku težinu, pokazuje u kojoj se količini pogreška povećava ili smanjuje, ako se težina poveća za malu količinu. Vektor za težinu se zatim podešava u suprotnom smjeru od gradijentnog vektora. Objektivna funkcija, usrednjena na sve primjere treninga, može se promatrati kao vrsta brdovitog krajolika u visoko dimenzionalnom prostoru težinskih vrijednosti. Vektor negativnog gradijenta označava smjer najstrmijeg spuštanja u ovom pejzažu, uzimajući ga bliže minimumu, gdje je izlazna pogreška u prosjeku niska. U praksi, većina praktičara koristi postupak koji se zove stohastički gradijentni silazak (SGD). To se sastoji od prikazivanja ulaznog vektora za nekoliko primjera, izračunavanja izlaza i pogrešaka, izračunavanja prosječnog gradijenta za te primjere i odgovarajuće prilagodbe utega. Proces se ponavlja za mnoge male skupove primjera iz skupa vježbanja, sve dok se prosjek funkcije cilja ne zaustavi. Zove se stohastički, jer svaki mali skup primjera daje bučnu procjenu prosječnog gradijenta na svim primjerima. Ova jednostavna procedura obično pronalazi dobar skup težina iznenađujuće brzo, u usporedbi s daleko složenijim tehnikama optimizacije [168]. Nakon treninga, učinkovitost sustava se mjeri na drugom skupu primjera nazvanim test skup podataka. To služi za testiranje sposobnosti generalizacije stroja, njegove sposobnosti da proizvede razumne odgovore na nove ulaze koje nikada nije vidio tijekom treninga. Arhitektura dubokog učenja je višeslojni niz jednostavnih modula, od kojih su svi (ili većina) podložni učenju, a mnogi od njih izračunavaju nelinearna ulazno-izlazna mapiranja. Svaki modul u nizu pretvara svoj ulaz kako bi povećao i selektivnost i varijantnost prikaza. S višestrukim nelinearnim slojevima, recimo dubinom od 5 do 15, sustav može implementirati iznimno zamršene funkcije svojih ulaza koji su istodobno osjetljivi na najsitnije detalje, razlikovanje samojeda od bijelih vukova, i neosjetljivi na velike irelevantne varijacije kao što je pozadina, poziranje, osvjetljenje i okolni objekti.

Postupak povratnog širenja za izračun gradijenta objektivne funkcije obzirom na utege višeslojnog sklopa modula, nije ništa više od praktične primjene pravila lanca za derivate. Ključni uvid je da se derivat (ili gradijent) cilja u odnosu na ulazni modul, može izračunati radeći unatrag od gradijenta obzirom na izlaz tog modula (ili ulaz sljedećeg modula), kao što je prikazano na slici 5.2:



Slika 5.2. Višeslojna neuronska mreža i postupak povratnog širenja [161].

a) Višeslojna neuronska mreža (prikazana povezanim točkama) može iskriviti ulazni prostor kako bi se klase podataka (čiji su primjeri na crvenim i plavim linijama) linearno razdvojili. Obratiti pažnju na to kako se pravilna rešetka (prikazana na lijevoj strani) u ulaznom prostoru, također transformira (prikazana u srednjem panelu) skrivenim jedinicama. Ovo je ilustrativan primjer sa samo dvije ulazne jedinice, dvije skrivene jedinice i jednu izlaznu jedinicu, ali mreže koje se koriste za prepoznavanje objekata ili obradu prirodnog jezika, sadrže desetke ili stotine tisuća jedinica.
b) Lančano pravilo derivata govori nam o tome kako su sastavljena dva mala efekta (mala promjena x na y i y na z). Mala promjena Δx u x, najprije se pretvara u malu promjenu Δy u y dobivanjem množenjem ∂y/∂x (tj. definicijom parcijalne derivacije). Slično tome,

promjena Δy stvara promjenu Δz u z. Zamjenom jedne jednadžbe u drugu, daje se pravilo lanca izvedenica - kako Δx pretvara u Δz množenje pomoću produkta $\partial y/\partial x$ i $\partial z/\partial x$. Djeluje također kada su x, y i z vektori (a derivati su Jacobijine matrice).

c) Jednadžbe koje se rabe za izračunavanje prolaska prema naprijed u neuronskoj mreži s dva skrivena sloja i jednim izlaznim slojem, od kojih svaki čini modul kroz koji se može razmaknuti gradijent. Na svakom sloju najprije izračunamo ukupni ulaz z za svaku jedinicu, što je ponderirani zbroj izlaza jedinica u sloju ispod. Tada se n nelinearna funkcija f (.)primjenjuje na z, kako bi se dobio izlaz jedinice. Radi jednostavnosti izostavljeni su uvjeti pristranosti. Nelinearne funkcije koje se koriste u neuronskim mrežama uključuju ispravljenu linearnu jedinicu (ReLU) $f(z) = \max(0,z)$, koja se uobičajeno koristi posljednjih godina, kao i konvencionalnije sigmoide, kao što je hyberbolic tangenta, $f(z)=(\exp(z) - \exp(-z)) / (\exp(z) + \exp(-z))$ i logistička funkcija , $f(z)=1/(1+\exp(-z))$.

d) Jednadžbe korištene za izračunavanje unatrag. Na svakom skrivenom sloju izračunava se derivat pogreške u odnosu na izlaz svake jedinice, koja je ponderirana suma izvedenih pogrešaka u odnosu na ukupne ulaze u jedinice u gornjem sloju. Potom se pretvara derivat pogreške u odnosu na izlaz, u derivat pogreške -obzirom na ulaz, množenjem s gradijentom f(z). Na izlaznom sloju, derivat pogreške u odnosu na izlaz jedinice izračunava se razlikovanjem funkcije troška. To daje $y_l - t_l$, ako je funkcija troška za jedinicu *l* vrijednost $0,5 (y_l - t_l)^2$, gdje je t_l ciljna vrijednost. Jednom kada je $\partial E/\partial z_k$ poznat, derivat pogreške za težinu wjk na spoju iz jedinice j u sloju ispod, je samo yj $\partial E/\partial z_k$.

Jednadžba širenja unatrag može se primijeniti više puta kako bi se gradijenti širili kroz sve module, počevši od izlaza na vrhu (gdje mreža radi svoje predviđanje) sve do dna (gdje se napaja vanjski ulaz). Kada se ti gradijenti izračunaju, jednostavno je izračunati gradijente obzirom na težinu svakog modula. Mnoge aplikacije dubinskog učenja koriste napredne arhitekture neuronskih mreža što se može vidjeti sa slike 20, koje uče mapirati ulaz fiksne veličine (na primjer, neku proizvoljnu sliku) na izlaz fiksne veličine (na primjer, vjerojatnost za svaku od nekoliko kategorija). Za prelazak s jednog sloja na drugi, skup jedinica izračunava ponderirani zbroj svojih ulaza iz prethodnog sloja i prosljeđuje rezultat kroz nelinearnu funkciju. Trenutno je najpopularnija nelinearna funkcija ispravljena linearna jedinica (eng. Rectified Linear Unit - ReLU), koja je jednostavno poluvalni ispravljač $f(z)=\max(z,0)$. U posljednjih nekoliko desetljeća, neuronske mreže koristile su glatkije nelinearnosti, kao što su tanh(z) ili $1/(1+\exp(-z))$, ali ReLU obično uči mnogo brže u mrežama s mnogo slojeva, dopuštajući obuku dubokog nadzora bez prethodne obuke bez nadzora [169]. Jedinice koje nisu na ulaznom ili izlaznom sloju, nazivaju se

uobičajeno skrivene jedinice. Skriveni slojevi mogu se smatrati kao izobličeni ulaz na nelinearni način, tako da kategorije postaju linearno odvojive od posljednjeg sloja, prikazano na slici 20.

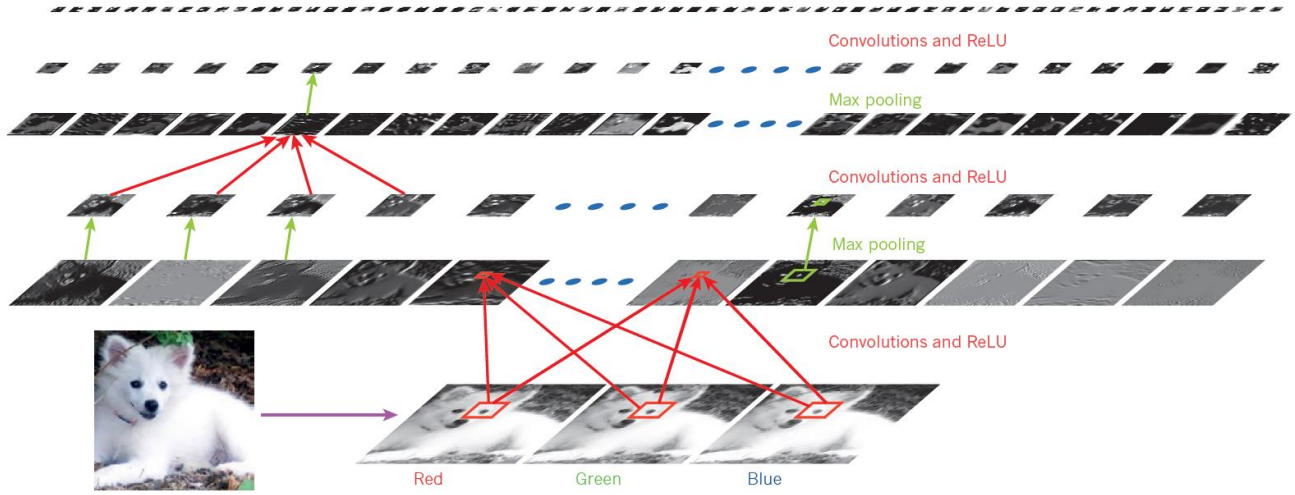
Neuronske mreže i širenje unatrag, uvelike su napuštene od strane zajednice za strojno učenje i ignorirane od strane računalnih vizija i zajednica prepoznavanja govora. Općenito se smatralo da je nemoguće naučiti korisne, više stupanjske značajke ekstraktorima s malo prethodnog znanja. Konkretno, smatralo se da bi jednostavno spuštanje u gradijentu bilo zarobljeno u siromašnim lokalnim minimalnim konfiguracijama težine, za koje bi se malim promjenama smanjila prosječna pogreška. U praksi, loši lokalni minimumi rijetko su problem s velikim mrežama. Bez obzira na početne uvjete, sustav gotovo uvijek doseže rješenja vrlo slične kvalitete.

Međutim, postojala je jedna posebna vrsta duboke, napredne mreže koju je mnogo lakše trenirati i generalizirati puno bolje od mreža s potpunom povezanošću susjednih slojeva. To je bila konvolucijska neuronska mreža (ConvNet) [170] [171]. Postigao je mnoge praktične uspjehe u prepoznavanju predmeta na slikama i uživo preko kamere, a to u razdoblju kada su neuronske mreže bile u servis za druge metode i nedavno je široko prihvaćena od strane računalne zajednice kao jedna od glavnih metoda umjetne inteligencije.

5.2.1. Konvolucijske neuronske mreže (eng. Convolutional Neural Network – CNN)

ConvNets su projektirane za obradu podataka koji dolaze u obliku višestrukih nizova, npr. slika u boji sastavljena od tri 2D polja, koja sadrže intenzitete piksela u tri kanala boje. Modaliteti podataka su u obliku višestrukih polja: 1D za signale i komponente, uključujući jezik; 2D za slike ili audio spektrograme i 3D za video ili volumetrijske slike. Postoje četiri ključne ideje koje stoje iza ConvNetsa koje koriste prednosti prirodnih signala: lokalne veze, zajedničke težine, udruživanje i korištenje više slojeva. Arhitektura tipičnog ConvNet-a, predstavljena na slici 5.3, strukturirana je kao niz stupnjeva.

Izlazi svakog sloja (vodoravno) tipične arhitekture konvolucijske mreže, primjenjuju se na sliku psa dolje lijevo i RGB (crvena, zelena, plava) ulaza, dolje desno. Svaka pravokutna slika je karta svojstava koja odgovara izlazu za jednu od naučenih značajki, detektiranu na svakom položaju slike. Informacija teče odozdo prema gore, a značajke niže razine djeluju kao orijentirani detektori rubova, a rezultat se izračunava za svaku klasu slike u izlazu.

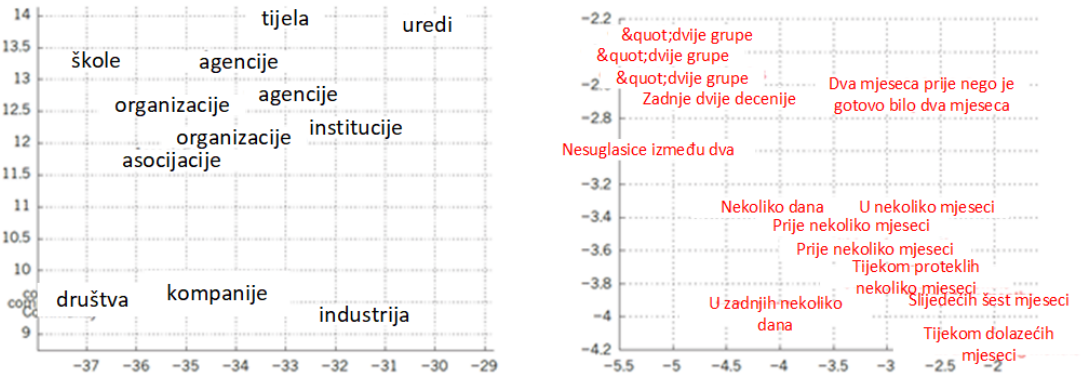


Slika 5.3. Unutrašnja struktura konvolucijske neuronske mreže [161].

Prvih nekoliko stupnjeva sastoji se od dva tipa slojeva: konvolucijski slojevi i slojevi koji se spajaju. Jedinice u konvolucijskom sloju su organizirane u mapama značajki, unutar kojih je svaka jedinica povezana s lokalnim zakrpama u mapama značajki prethodnog sloja, kroz skup težina koje se nazivaju banka filtara. Rezultat te lokalne ponderirane sume, zatim se prolazi kroz nelinearnost kao što je ReLU. Sve jedinice u mapi značajki dijele istu banku filtra. Različite karte značajki u sloju koriste različite banke filtara. Razlog za takvu arhitekturu je dvostruk. Prvo, u nizu podataka kao što su slike, lokalne skupine vrijednosti, često su visoko korelirane, tvoreći prepoznatljive lokalne motive koji se lako otkrivaju. Drugo, lokalna statistika slika i drugih signala su nepromjenjivi prema lokaciji. Drugim riječima, ako se motiv može pojaviti na jednom dijelu slike, mogao bi se pojaviti bilo gdje, stoga je ideja jedinica na različitim lokacijama dijeliti iste težine i otkriti isti uzorak u različitim dijelovima polja. Matematički, operacija filtriranja koju izvodi karta svojstava je diskretna konvolucija, otuda i ime. Iako je uloga konvolucijskog sloja u otkrivanju lokalnih konjunkcija značajki iz prethodnog sloja, uloga sloja udruživanja je spajanje semantički sličnih značajki u jednu. Budući da se relativni položaji obilježja koja tvore motiv mogu donekle mijenjati, pouzdano detektiranje motiva može se izvršiti grubim granuliranjem položaja svake značajke. Tipična jedinica za grupiranje, izračunava maksimum lokalne zakrpe jedinica u jednoj karti značajki (ili u nekoliko karata značajki). Susjedne jedinice za spremanje, unose podatke iz zakrpa koje su pomaknute za više od jednog retka ili stupca, čime se smanjuje dimenzija reprezentacije i stvara invarijantnost na male pomake i izobličenja. Dva ili tri stupnja konvolucije, nelinearnosti i udruživanja su složeni, nakon čega slijede slojevi koji su više povezani i potpuno povezani. Gradijenti koji prodiru natrag kroz ConvNet su jednostavni kao kroz redovnu duboku mrežu, omogućujući da se obučavaju svi utezi u svim bankama filtera. Duboke neuronske mreže iskorištavaju svojstvo da su mnogi prirodni signali kompozicijske hijerarhije, u kojima se

značajke više razine dobivaju komponiranjem onih niže razine. U slikama, lokalne kombinacije rubova tvore motive, motivi se spajaju u dijelove, a dijelovi oblikuju objekte. Slične hijerarhije postoje u govoru i tekstu od zvukova do telefona, fonema, slogova, riječi i rečenica. Sakupljanje omogućuje da se prikazi vrlo malo razlikuju kada se elementi u prethodnom sloju razlikuju po položaju i izgledu. Konvolucijski i skupni slojevi u ConvNetsu, izravno su inspirirani klasičnim pojmovima jednostavnih stanica i složenih stanica u vizualnoj neuro znanosti, a cjelokupna arhitektura podsjeća na LGN-V1-V2-V4-IT hijerarhiju u ventralnom putu vizualnog korteksa [172]. Kada su ConvNet modeli i majmuni prikazani na istoj slici, aktiviranje jedinica na visokoj razini u ConvNetu, objašnjava pola varijance slučajnih skupova od 160 neurona u majmunovom infero temporalnom korteksu. ConvNets imaju svoje korijene u neokognitronu, čija je arhitektura donekle slična, ali nije imala algoritam za nadgledanje od kraja do kraja, kao što je širenje unatrag. Za prepoznavanje fonema i jednostavnih riječi korišten je primitivni 1D ConvNet, koji se zove neuralna mreža s vremenskom odgodom [173].

Teorija dubokog učenja pokazuje da duboke mreže imaju dvije različite eksponencijalne prednosti u odnosu na klasične algoritme učenja, koji ne koriste distribuirane prikaze. Obje ove prednosti proizlaze iz moći kompozicije i ovise o podlozi koja generira distribuciju, koja ima odgovarajuću komponencijalnu strukturu [174]. Prvo, učenje raspodijeljenih prikaza omogućuje generalizaciju novih kombinacija vrijednosti naučenih značajki izvan onih koje se vide tijekom treninga (na primjer, moguće su 2n kombinacije s n binarnim značajkama). Drugo, sastavljanje slojeva predstavljanja u dubokoj mreži, donosi potencijal za još jednu eksponencijalnu prednost (eksponencijalno u dubini). Skriveni slojevi višeslojne neuronske mreže uče da predstavljaju ulaze mreže, na način koji olakšava predviđanje ciljnih izlaza. To je lijepo prikazano obukom višeslojne neuronske mreže za predviđanje sljedeće riječi u nizu iz lokalnog konteksta ranijih riječi [175]. Svaka riječ u kontekstu predstavljena je mreži kao jedan od N vektora, tj. jedna komponenta ima vrijednost 1, a ostatak je 0. U prvom sloju, svaka riječ stvara različiti uzorak aktivacija, ili vektora riječi, slika 5.4.



Slika 5.4. Vizualizacija naučenih jezičnih vektora [175].

Na slici 5.4, s lijeve strane je ilustracija naučenih riječnih reprezentacija za jezik modeliranja, nelinearno projicirana u 2D za vizualizaciju pomoću t-SNE algoritma1[177]. Na desnoj strani je 2D prikaz fraza koje je učila engleska enkoder-dekoder povratna neuronska mreža. Može se primijetiti da su semantički slične riječi ili sekvence riječi mapirane u obližnje prikaze. Distribuirane reprezentacije riječi dobivaju se korištenjem povratne veze za zajedničko učenje reprezentacije, za svaku riječ i funkciju koja predviđa ciljnu količinu kao što je sljedeća riječ u nizu (za modeliranje jezika) ili cijeli niz prevedenih riječi (za strojno prevođenje).

U jezičnom modelu, ostali slojevi mreže uče kako pretvoriti ulazne vektore riječi u vektor izlazne riječi za predviđenu sljedeću riječ, što se može koristiti za predviđanje vjerojatnosti da se bilo koja riječ u rječniku pojavi kao sljedeća riječ. Mreža uči vektore riječi koji sadrže mnoge aktivne komponente od kojih se svaka može protumačiti kao zasebna značajka riječi, kao što se prvi put pokazalo u kontekstu učenja distribuiranih prikaza simbola. Ove semantičke značajke nisu bile eksplicitno prisutne u ulazu. Procesom učenja su otkriveni kao dobar način faktorizacije strukturiranih odnosa između ulaznih i izlaznih simbola u višestruke „mikro-pravila“. Pokazalo se da učenje vektora riječi također dobro funkcionira kada riječi sekvence dolaze iz velikog korpusa stvarnog teksta, a pojedinačna mikro pravila su nepouzdana [175]. Primjerice, kada se nauči predvidjeti sljedeću riječ u vijestima, naučeni riječni vektori za utorak i srijedu su vrlo slični, kao i riječni vektori za Švedsku i Norvešku. Takvi se prikazi nazivaju distribuirani prikazi, jer njihovi elementi (značajke) se međusobno ne isključuju i njihove brojne konfiguracije odgovaraju varijacijama koje se vide u promatranim podacima. Ovi riječni vektori su sastavljeni od naučenih značajki koje stručnjaci nisu unaprijed odredili, već automatski otkriveni neuronskom mrežom. Vektorske reprezentacije riječi naučene iz teksta sada su vrlo široko korištene u primjeni prirodnog jezika [176]. Pitanje reprezentacije leži u središtu rasprave između paradigmi za spoznaju koje su nadahnute logikom i koje su nadahnute neuronskom mrežom. U paradigmi inspiriranoj logikom,

primjer simbola je nešto za što je jedino svojstvo da je identično ili nije identično drugim primjercima simbola. Nema unutarnju strukturu koja je relevantna za njezinu uporabu, ona mora biti vezana za varijable u razumno odabranim pravilima zaključivanja. Nasuprot tome, neuronske mreže samo koriste velike vektore aktivnosti, velike matrice težine i skalarne ne-linearnosti da bi izvele tip brzog "intuitivnog" zaključka koji podupire razumno rasuđivanje.

Prije uvođenja modela živog jezika [175], standardni pristup statističkom modeliranju jezika nije iskorištavao distribuirane prikaze: temeljio se na brojanju frekvencija pojavljivanja kratkih simbolskih nizova duljine do N (nazvanih N-grama). Broj mogućih N-grama određen je redoslijedom VN, pri čemu je V veličina vokabulara, tako da bi uzimanje u obzir više od nekoliko riječi zahtijevalo vrlo velike korpuse izobrazbe. N-grami tretiraju svaku riječ kao atomsku jedinicu, tako da ne mogu generalizirati semantički povezane sekvence riječi, dok modeli neuronskih jezika mogu, jer povezuju svaku riječ s vektorom stvarnih značajki, a semantički povezane riječi završavaju blizu jedna drugoj u tom vektorskom prostoru, kao što je već prikazano na slici 5.4.

5.3. Metoda Potpornih Vektora (eng. Support Vector Machine – SVM)

U ovom poglavlju će biti predstavljen metoda potpornih vektora (MPV) kao rješenje za dvije grupe klasifikacijskih problema. Strojna potporu vektora, kombinira 3 ideje: tehniku rješenja iz optimalnih hiperpovršina (koja omogućuje širenje vektora rješenja na vektorima podrške), ideju konvolucije proizvoda (koja proširuje površine rješenja od linearnih do ne linearno) i pojam mekih margina (kako bi se omogućile pogreške na skupu za vježbanje). Algoritam je testiran i uspoređen s osobinama drugih klasičnih algoritama [178]. Unatoč jednostavnosti projekta na površini odlučivanja, algoritam pokazuje vrlo fino izvođenje u usporedbi drugih karakteristika, kao što su kontrola snaga i jednostavnost promjene provedene površine odlučivanja, čine MPV za podršku izuzetno moćnom i univerzalnim strojem za učenje. U ovom dodatku izvest ćemo i metodu konstruiranja optimalnih razdjelnika prostora i mekanih razdjelnika (eng. Hyperplanes).

Da bi se konstruirao optimalna hiperpovršina mora biti zadovoljena sljedeća jednadžba:

$$w_0 x + b_0 = 0, \tag{5-10}$$

što razdvaja set podataka za treniranje:

$$(y_1, x_1), \ldots, (y_l, x_l), \tag{5-11}$$

a potrebno je učiniti radi toga minimizaciju:

$$\Phi = w^* w \tag{5-12}$$

podređenu ograničenjima:

$$y_i \left(x_i^* w + b \right) \geq 1, \quad i = 1, \ldots, l \tag{5-13}$$

U tu svrhu koristi se standardna tehnika optimizacije. Kreiran je Lagrangian-ov odnos prethodnih izraza

$$L\left(w, b, \Lambda\right) = \frac{1}{2} w^* w - \sum_{i=1}^{l} \alpha_i \left[y_i \left(x_i^* w + b \right) - 1 \right], \tag{5-14}$$

gdje je: $\Lambda^T = (\alpha_1, \ldots \alpha_l)$ vektor ne-negativan Lagrange multiplikatora u vezi sa ograničenjima (5-14). Poznato je da je rješenje optimizacijskog problema određeno sjedištem ovog Lagrangijana u 2l + 1 dimenzionalnom prostoru w, Λ, i b, gdje je minimum potrebno uzeti obzirom na parametre w i b, i maksimum treba uzeti obzirom na Lagrangeove multiplikatore Λ. Na mjestu minimuma (obzirom na w i b) dobiva se:

$$\frac{\partial L\left(w.b.\Lambda\right)}{\partial w} \Big|_{w=w_0} = \left(w_0 - \sum_{i=1}^{l} \alpha_i y_i x_i \right) = 0 \tag{5-15}$$

$$\frac{\partial L\left(w.b.\Lambda\right)}{\partial b} \Big|_{b=b_0} = \left(\sum_{\alpha_i} y_i \alpha_i \right) = 0 \tag{5-16}$$

Iz jednakosti (5-16) imamo izvod:

$$W_0 = \sum_{i=1}^{l} \alpha_i y_i x_i \tag{5-17}$$

koji izražava da se optimalno rješenje hiperplaniranja može napisati kao linearna kombinacija vektora vježbanja. Napominjemo da samo vektori vježbanja x_i sa $\alpha_i > 0$ imaju učinkovit doprinos zbroju (5-17).

Zamjenjivanjem (5-17) i (5-16) u (5-15) dobije se:

$$W\left(\Lambda\right) = \sum_{i=1}^{l} \alpha_i - \frac{1}{2} W_0 W_0 \tag{5-18}$$

$$= \sum_{i=1}^{l} \alpha_i - \frac{1}{2} \sum_{i=1}^{l} \sum_{j=1}^{l} \alpha_i \alpha_j y_i y_j x_i x_j \tag{5-19}$$

U sintaksi vektorskog zapisa izgleda kao u (5-20):

$$W(\Lambda) = \Lambda^T 1 - \frac{1}{2}\Lambda^T D\Lambda \tag{5-20}$$

gdje znamenka 1 predstavlja l-dimenzionalni jedinični vektor, i D je simetrična lxl matrica sa elementima

$$D_{ij} = y_i y_j x_i x_j \tag{5-21}$$

Da bi se našla točka u sedlu potrebno je pronaći maksimum od (5-21) prema ograničenima (5-20):

$$\Lambda^T Y = 0 \tag{5-22}$$

gdje je $Y^T = (y_1,...y_l)$ i

$$\Lambda \geq 0 \tag{5-23}$$

Kuhn-Tucker-ova teorema ima važnu ulogu u teoriji optimizacije. Prema ovoj teoremi, na sedlastoj točki u w_o, b_o, A_o, bilo koji Lagrangeov multiplikator α_i^0 i njegovo odgovarajuće ograničenje povezani su s jednakošću:

$$\alpha_i \left[y_i \left(x_i W_0 + b_0 \right) - 1 \right] = 0, \quad i = 1,\ldots l \tag{5-24}$$

Iz ove jednakosti dolazi da ne-nula vrijednost α_i može se jedino postići u slučajevima gdje je:

$$\left[y_i \left(x_i W_0 + b_0 \right) - 1 \right] = 0 \tag{5-25}$$

To znači, drugim riječima, $\alpha_i \neq 0$ samo za slučajeve gdje je nejednakost isposlovana kao jednakost. Vektori xi se definiraju, gdje jednadžba:

$$\left[y_i \left(x_i W_0 + b_0 \right) = 1 \right] \tag{5-26}$$

važi za svaki vektor potpore. Primjetno je da u ovoj terminologiji jednadžba (58) govori da rješenje vektor W_0 može biti proširen na vektor podrške. Još jedno opažanje, temeljeno na Kuhn-Tucker ekvivalentima (5-15) i (5-17) za optimalno rješenje, je odnos između maksimalne vrijednosti W (Λ_0) i udaljenosti razdvajanja p_o:

$$W_0 W_0 = \sum_{i=1}^{l} \alpha_i^0 y_i x_i W_0 = \sum_{i=1}^{l} \alpha_i^0 \left(1 - y_i b_0\right) = \sum_{i=1}^{l} \alpha_i^0 \tag{5-27}$$

Zamjenjujući ovu jednakost u izrazu (5-18) za W(Λ_0) dobije se:

$$W\left(\Lambda_0\right)=\sum_{i=1}^{l}\alpha_i^0-\frac{1}{2}W_0W_0=\frac{W_0W_0}{2} \tag{5-28}$$

Uzimajući u obzir izraz:

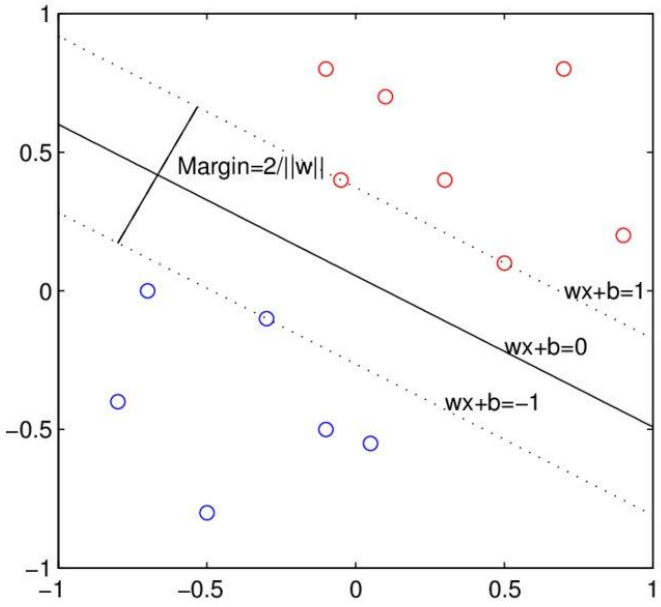
$$\rho\left(W_0,b_0\right)=\frac{2}{\left|W_0\right|} \tag{5-29}$$

dobije se na kraju:

$$W\left(\Lambda_0\right)=\frac{2}{\rho_0^2} \tag{5-30}$$

gdje je ρ_0 granica za optimalni hiperprostor tj. razdjelnik prostora između dva skupa.

Na kraju vizualni prikaz predstavljenog optimalnog hiperprostora, koji dijeli dva segmenta, je predstavljen na slici 5.5 [179].



Slika 5.5. Vizualna reprezentacija metoda potpornih vektora sa označenom granicom i hiperprostorom [179].

5.3.1. Algoritam hiperprostora mekane margine

Treba razmotriti slučaj kada se dvije klase ne mogu nikako razdvojiti zbog nesigurnosti u mjerenju. Uvjet za optimalni hiperprostor može biti labavo uzet uključujući dodatni uvjet:

$$y_i\left(x_i^T W + b\right) \geq 1 - \xi_i, \quad i = 1, \ldots m \tag{5-31}$$

Što je u jednadžbi

Za minimalnu grešku $\xi_i \geq 0$, trebalo bi biti minimizirani također ||W||, i funkcija cilja postaje:

Minimizirati $$W^T W + C\sum_{i=1}^{m} \xi_i^k \tag{5-32}$$

Imajući na umu $$y_i\left(x_i^T W + b\right) \geq 1 - \xi_i, \quad i = 1, \ldots m \tag{5-33}$$

Ovdje C je parametar regulacije koji kontrolira kompromis između maksimiziranja margine i minimiziranja pogreške treninga. Dovoljno mala vrijednost konstante C ima tendenciju naglašavati marginu, a ignorira granice u podacima o obuci, dok veliki C može imati tendenciju prepuniti podatke o treningu i time sustav izgubi generalitet.

Kada je k = 2, to se naziva problem 2-norme meke margine, te se izraz (5-32) pretvara u:

Minimizirati $$W^T W + C\sum_{i=1}^{m} \xi_i^2 \tag{5-34}$$

Imajući na umu $$y_i\left(x_i^T W + b\right) \geq 1 - \xi_i, \quad i = 1, \ldots m \tag{5-35}$$

Može se primijetiti da uvjet $\xi_i \geq 0$ nije više ne važi pa je sada $\xi_i < 0$, te se sada može postaviti na 0 i cilj funkcije je još više reduciran. Alternativno, ako se dozvoli da je k=1, problem se može:

Minimizirati $$W^T W + C\sum_{i=1}^{m} \xi_i \tag{5-36}$$

Imajući na umu $$y_i\left(x_i^T W + b\right) \geq 1 - \xi_i, \quad i = 1, \ldots m \tag{5-37}$$

Ovakav izraz se naziva 1-norma meka margina. Kada se 1-norma algoritam usporedi sa 2-norma logaritmom, on je manje osjetljiv na šum u mjerenju podataka za treniranje.

6. METODOLOGIJA PRIKUPLJANJA ULAZNIH PODATAKA I PREPORUČENE METODE DETEKCIJE

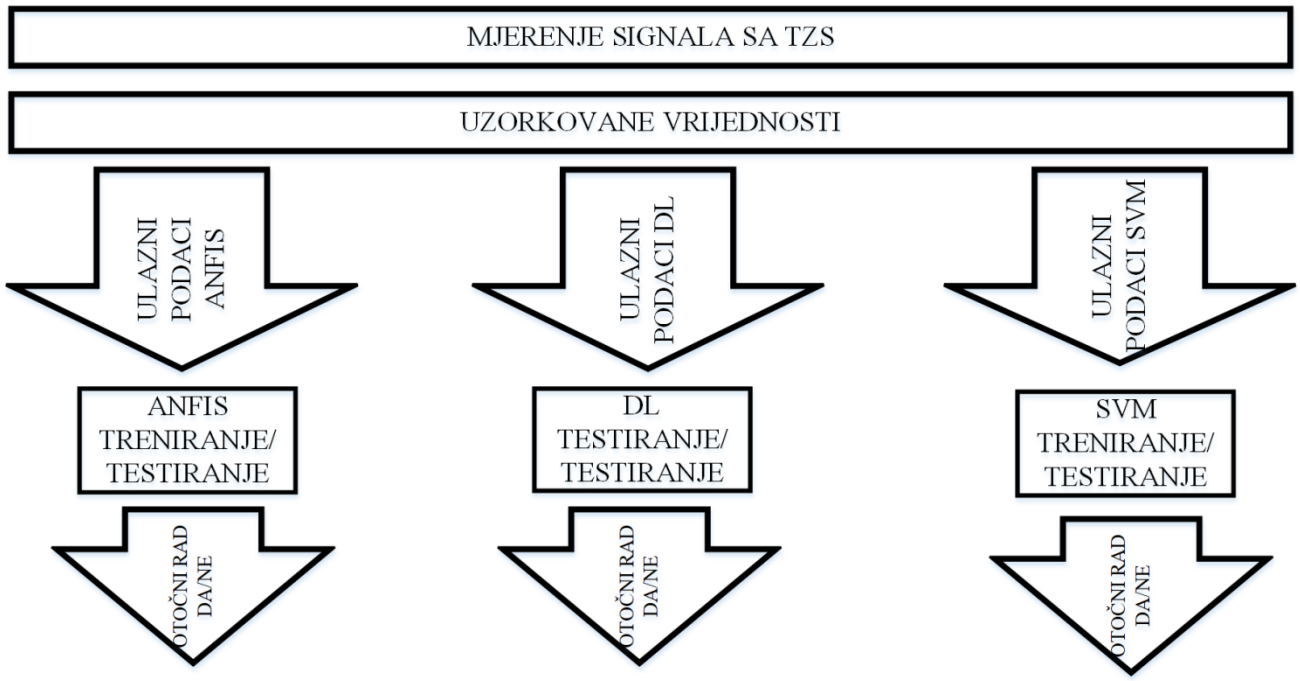
Iako su napredne metode umjetne inteligencije korištene za detekciju otočnog rada, ipak mjesta za poboljšanje istih i to na nekoliko polja: boljem uzorkovanju ulaznih podataka, pokrivanju većeg dijela zone ne detekcije, uključujući pojave koje se mogu klasificirati kao prelazak u otočni rad distribuiranog izvora, a to nisu, te standardizaciju predloženih metoda.

Posljedice koje sa sobom donosi nenamjerni otočni rad distribuiranog izvora u distribucijskoj mreži je objašnjen u poglavlju 3, tako da imajući u vidu moguće posljedice od nenamjernog otočnog rada, problematika ove disertacije ima dodatnu motivaciju. Bez obzira na tehnološku i normativnu praksu koju mora svaki vlasnik distribuiranog izvora poštivati, te svoju proizvodnju električne energije podrediti navedenim pravilima, operater distribucijskog sustava je to tijelo koje odgovara za kvalitetu el. energije kod svojih kupaca, te za sigurnost ljudi i ispravnost opreme. Navedene su neke komponente distribucijskoj mreži-e, koje imaju veliki direktan utjecaj na ponašanje signala kada se otočni rad desi, te time unose nepreciznost u metode detekcije otočnog rada, a naravno sa tim na umu je potrebno predložiti novu metodu.

Pregledom navedenih metoda se može utvrditi da prostora za poboljšanje ima i to ne samo sa metodama umjetne inteligencije, nego sa mnogim drugim prijedlozima koje su mnogi autori predložili, a kombinacija su postojećih metoda ili uvođenje novih mehanizama koji na inovativan način obrađuju signale sa mreže, da bi riješile problem.

Kako iza svake od objašnjenih metoda stoji kompleksan matematski aparat, to nameće korištenje navedenih metoda sa razumijevanjem, bez obzira na alat kojim se one treniraju, te testiraju. Alati koji koriste navedene metode nude veliki nivo hibridizacije pri kreiranju svog sustava metoda, te veliku elastičnost kada su u pitanju uvjeti simulacije otočnog rada.

U ovom poglavlju će biti objašnjeno uzorkovanje podataka na točki zajedničkog spajanja, koje je osnova uspješnosti predloženih metoda. Sama metodologiju sakupljanja podataka, te njihovo klasificiranje u određene oblike koji su specifični za svaku metodu, posebno će biti objašnjena u narednim pod poglavljima. Metodologija uzorkovanja u istoj arhitekturi sa pripadajućim algoritmima je predstavljena na slici 6.1. Slika predstavlja hodogram kretanja podataka kroz cijeli proces kreiranja metoda, ne ulazeći u pojedinu strukturu metode, što će biti ostavljeno za pojedinačna pod poglavlja.



Slika 6.1. Globalna arhitektura metodologije kreiranja i testiranja metoda sa uzorkovanjem ulaznih podataka za svaku

U literaturi nije objašnjena, niti predložena metodologija rada pri kreiranju samih sustava temeljenih na umjetnoj inteligenciji, međutim gornji hodogram koji je usvojen, nalaže da se za treniranje samih metoda prvo mora sakupiti određeni skup ulaznih podataka sa željenim izlazom za svaku od razmatranih metoda u disertaciji, te onda prići testiranju kroz standarde i praktične slučajeve u distribucijskoj mreži. Na kraju se dobije izlaz iz svake od metoda, te se na osnovu njih zaključuje koliko je ista precizna i brza i pouzdana.

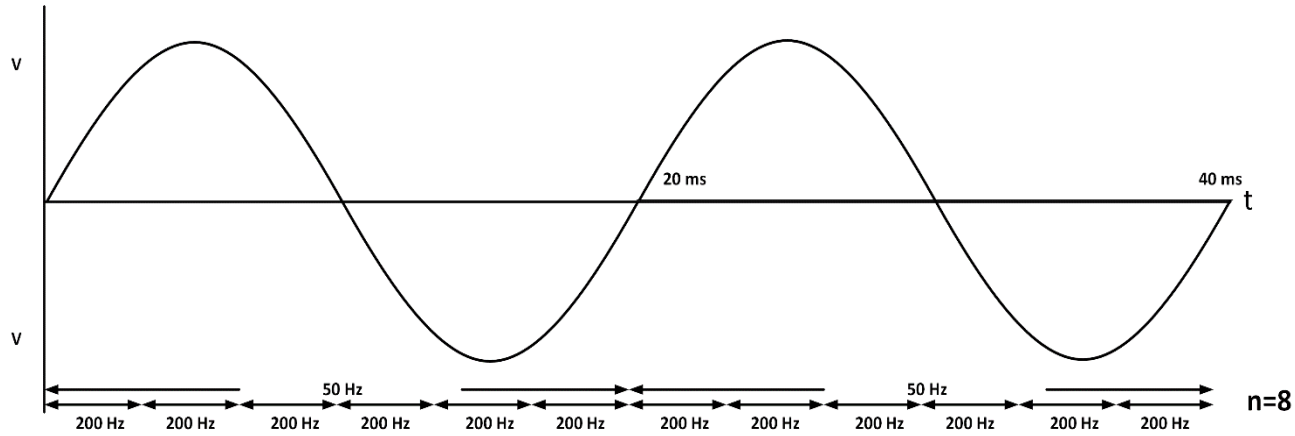
U narednim pod poglavljima je objašnjen proces uzorkovanja, te priprema podataka za određene cjeline koje su ulazni parametri za pojedine metode. Zbog svoje prirode svaka metoda ima drugačiju cjelinu, koja sadrži određeni fond podataka potrebnih za treniranje i klasifikaciju kao konačni rezultat.

6.1. Uzorkovanje podataka sa distribucijske mreže u točki zajedničkog spajanja

Ulaz u proceduru učenja predloženih metoda se dobiva mjerenjem veličina kvalitete električne energije u točki zajedničkog spajanja. Kvaliteta ulaznih podataka definira učinkovitost predloženih metoda kao gotovog obučenog sustava za otkrivanje otočnog rada distribuiranog izvora. Pod pojmom kvaliteta ulaznih podataka u sustav učenja metodama umjetne inteligencije , podrazumijeva se, da što je uzorak manji, odnosno što je vrijeme uzorkovanja između dvije mjerne

veličine manje, to je kvaliteta veća. Ta činjenica, naravno postavlja veliki izazov načinu uzorkovanja, pod čime se misli na metodu uzimanja uzoraka u realnom vremenu. Ako je uzorak dovoljno kvalitetan može se uzeti dodatna tolerancija za vrijeme detekcije otočnog rada, a samim time i točnost metode, naravno ako je to moguće treba se izbjeći. Važnost načina uzorkovanja daje imperativ na vrijeme detekcije i selektivnosti otkrivanja otočnog rada. S ciljem pravovremenog otkrivanja, zahtjev je za što kraćim vrjemenom uzorkovanja. Nasuprot vremenu detekcije otočnog rada, skraćivanje vremena uzorkovanja čini cilj postizanja selektivnosti težim, jer se unutar malog uzorka može greškom prepoznati otočni rad, a on to nije. Pored utjecaja na selektivnost, javlja se usporedo s tim povećanje zone ne detekcije, jer jednim ne otkrivanjem otočnog rada distribuiranog izvora se dodaje prostor na zone ne detekcije i time se gubi na cilju koji je postavljen. Između ta dva cilja, javlja se potreba za optimizacijom brzine uzorkovanja, odnosno definiranja vremena između dva uzorka.

Da bi se zadržala mala vremenska razlika između dva uzorka, te smanjilo vrijeme detekcije otočnog rada, a istovremeno povećala preciznost i smanjila zone ne detekcije, u istraživanju je uzet veći broj signala koji se uzorkuju, te se time pokrilo veće polje na kojem se javlja otočni rad. Predložena metoda uzorkovanja čuva pasivnu prirodu metode otkrivanja otočnog rada uzimanjem 7 mjerenih parametara: srednju efektivnu vrijednost napona (RMS_U), srednju efektivnu vrijednost struje (RMS_I), ukupno harmonijsko izobličenje napona (THD_U), ukupno harmonijsko izobličenje struje (THD_I), frekvencija (f), aktivna snaga koju daje distribuirani izvor (P_G), reaktivna snaga koju daje distribuirani izvor (Q_G). Autor ove disertacije je uzeo navedenih sedam signala koji su ujedno i parametri kvalitete električne energije, kao temelj za detekciju otočnog rada iz razloga što svaki od njih na svoj način manifestira prelazak iz sinkronog u otočni rad. U mnogo scenarija prelazak u otočni rad rezultira veoma malim ili nikakvim poremećajima u nekim signalima te da bi se prepoznao prelazak potrebno je uzeti više signala za istu analizu. Stoga je bitno da se obuhvate svi ili u najmanju ruku što više scenarija da bi se uspješno detektirao otočni rad distribuiranog izvora. Sa svih sedam signala, predložena metoda minimizira zonu ne detekcije, te povećava preciznost otkrivanja, a istovremeno vrijeme uzorkovanja se ne povećava i time vrijeme otkrivanja ostaje isto. Obzirom na sve signale koji se mjere s točki zajedničkog spajanja, može se uzeti dovoljno mala vremenska razlika između uzoraka, pa je brzina uzorkovanja svih signala pet milisekundi (0,005 s) sa 8 uzoraka, što znači uzorkovanje tijekom dvije periode sinusoide. Slika 6.2 prikazuje učestalost uzorkovanja i korelaciju s glavnom frekvencijom signala napona. Identična je metoda za ostale signale. Broj uzoraka je 8 tako da cjelokupno uzorkovanje traje 40 ms, kako je prezentirano u tablici 6.1.



Slika 6.2. Prikaz frekvencije uzorkovanja podataka.

Podaci se prikupljaju putem očitanja sa modela unutar alata u kojem je metoda trenirana, model mreže je simuliran, te su urađeni i testovi. Svi podaci obrađuju se u prikladne pakete podataka koji se sastoje od 8 brojeva za svaki signal: THD_U, THD_I, RMS_U, RMS_I, f, P i Q. Svi navedeni signali su jedan skup podataka organizirani različito za svaku od navedenih metoda detekcije. Svaki skup je posebno objašnjen u slijedećim pod poglavljima za svaku od metoda. Nakon što se podaci poredaju u skup podataka, idu na daljnju proceduru treniranja, pa onda testiranja metodom umjetne inteligencije. Pošto metode nisu kompatibilne s načinom čitanja ulaznih podataka, onda se mora formirati posebni skup za svaku metodu sukladno njenim dimenzioniranim ulaznim kanalima.

Nakon definiranja dimenzija ulaza, na testnom modelu se simulira otočni rad distribuiranog izvora, te sve ostale situacije koje se mogu uključiti za provjeru efikasnosti predloženih metoda, a to su: kvarovi na mreži, uključivanje dodatnog tereta na distribuiranog izvora, isključivanje tereta s distribuiranog izvora, brzo punjenje hibridnih automobila na nisko naponskoj strani distribucijske mreže, te posebni uvjeti promjene faktora kvalitete (Q_f) distribucijske mreže prema standardu UL 1741.

Tablica 6.1. Detalji uzoraka i skupa uzoraka koji se plasira dalje za treniranje i testiranje metoda.

	Signal	**Vrijeme uzorka [s]**	**Broj uzoraka**	**Vrijeme trajanja skupa [s]**	**Frekvencija skupa [Hz]**
Skup podataka	RMS_U	0.005	8	0.04	200
	RMSI	0.005	8		
	THD_U	0.005	8		
	THD_I	0.005	8		
	f	0.005	8		
	P	0.005	8		
	Q	0.005	8		

Osjetljivost predloženih metoda je povezana s vremenom uzorka i trajanjem uzorkovanja kao i brojem signala koji se uzorkuju. Prema zadanim vrijednostima navedenih uzorkovanih signala, optimalno vrijeme za otkrivanje otočnog rada je:

$$t_{uzorak} * N_{uzoraka} = 0,005\,s * 8 = 0,04\,s \tag{6-1}$$

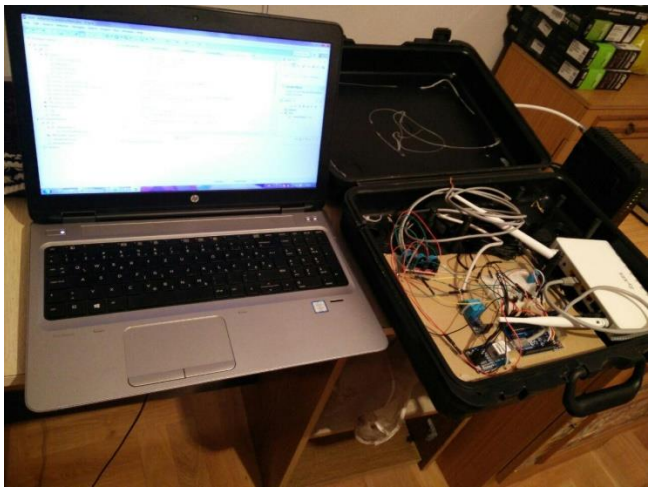
Svaki novi uzorak izbacuje najstariji uzorak iz podatkovnog skupa, zadržavajući istu količinu uzoraka cijelo vrijeme u skupu podataka. Imajući na umu minimiziranje zone ne detekcije, broj signala ima tendenciju podizanja s ciljem obuhvaćanja svih aspekata parametara kvalitete električne energije. Zbog toga se dobiva sedam signala za detekciju otočnog rada: RMS_V, RMS_I, THD_V, THD_I, *f, P i Q*, prikazanih u tablici 6.1. Broj izmjerenih vrijednosti korištenih za ulazne podatke su:

$$N_{signala} * N_{uzoraka} = 7 * 8 = 56 uzoraka \tag{6-2}$$

Ulazna matrica od 56 uzoraka podijeljena je u 7 redaka i 8 stupaca. Zavisno od metode koja će se koristiti za detekciju otočnog rada, ovih 56 uzoraka se formira na jedinstven način, te kao takav postaje ulaz za korištenu metodu.

Uzorci za obuku predloženih metoda su dobiveni eksperimentalnim mjernim uređajem u točki zajedničkog spajanja stvarne fotonaponske elektrane. Mjerni uređaj, prikazan na slici 6.3 obrađen u sklopu referata [180], je sastavljen od: strujnih mjernih transformatora ENTES ENT.B 75/5 A u kombinaciji s TA12-100 5A, naponskog transformatora ZMPT101B, Arduino UNO ploče R3.

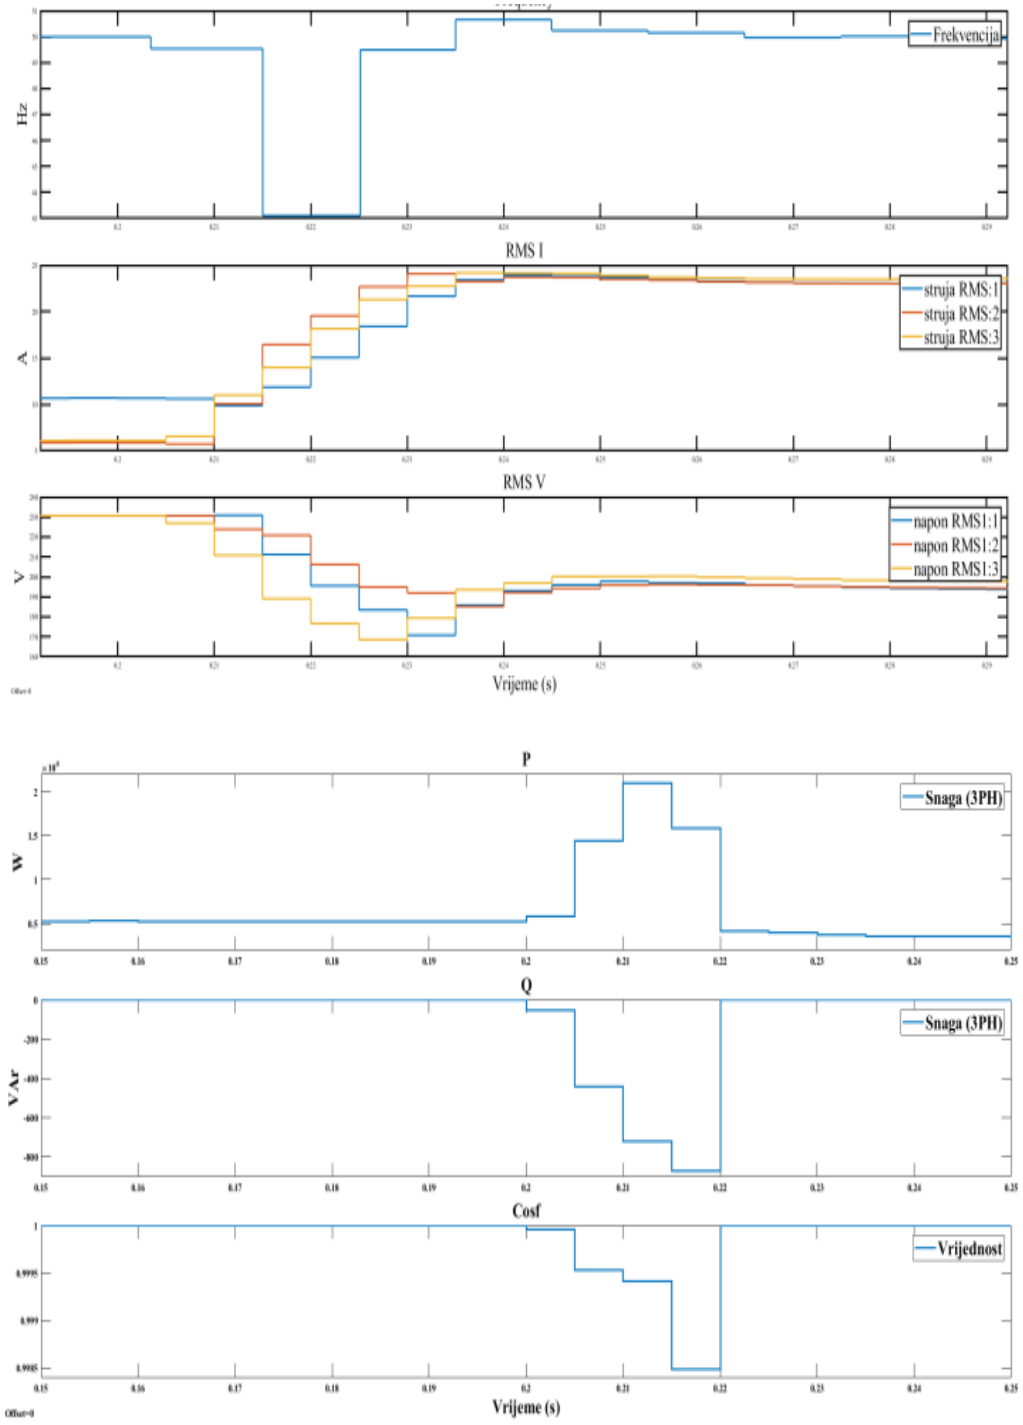
Program za pohranu podataka programiran je u Java programskom jeziku. Pojedinosti o korištenim improviziranim elektroničkim uređajima (IED) navedene su u [180]. Brzina uzorkovanja definira kvalitetu ulaznih podataka klasifikacije koji dodatno definira učinkovitost predloženih metoda. Vrijeme detekcije i smanjenje zone ne detekcije su najvažniji ciljevi istraživanja, u cilju visoke preciznosti. Obzirom na vrijeme uzorkovanja, treba uzeti u obzir ponašanje signala, gdje se svih 7 signala ponašaju u skladu s uvjetima u mreži. Ponašanje signala u otočnom radu i stanju kvara prikazano je na slici 6.4. Slog podataka cijelog signala traje 40 ms, i sadrži 8 uzoraka. Stoga se izbjegavaju smetanja u signalu u slučaju da su kraći od 5 ms i uzimaju se kao ponašanje signala ako traju između 5 i 40 ms. Ovaj pristup uzorkovanja prikazan je na slici 6.2. Ovo vrijeme uzorkovanja i broj uzoraka u jednom podatkovnom skupu povećava selektivnost. Slijedom toga, više selektivnosti uzrokuje rast zone ne detekcije. Smanjenje zone ne detekcije zahtijeva uključivanje različitih signala na koje utječe otočni rad i distributivna mreža.

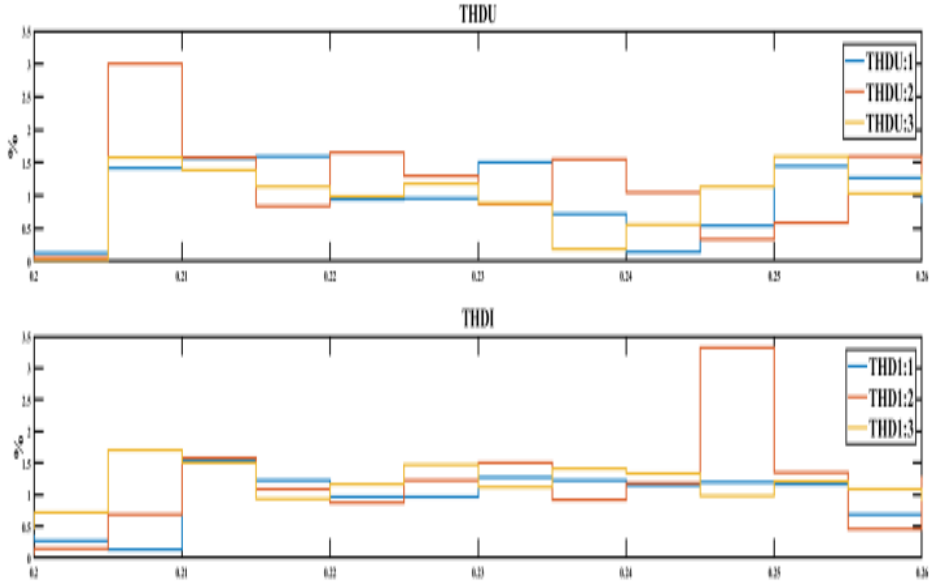


Slika 6.3. Elektronički uređaj (IED) sastavljen za mjerenje na licu mjesta na točki zajedničkog spajanja-u.

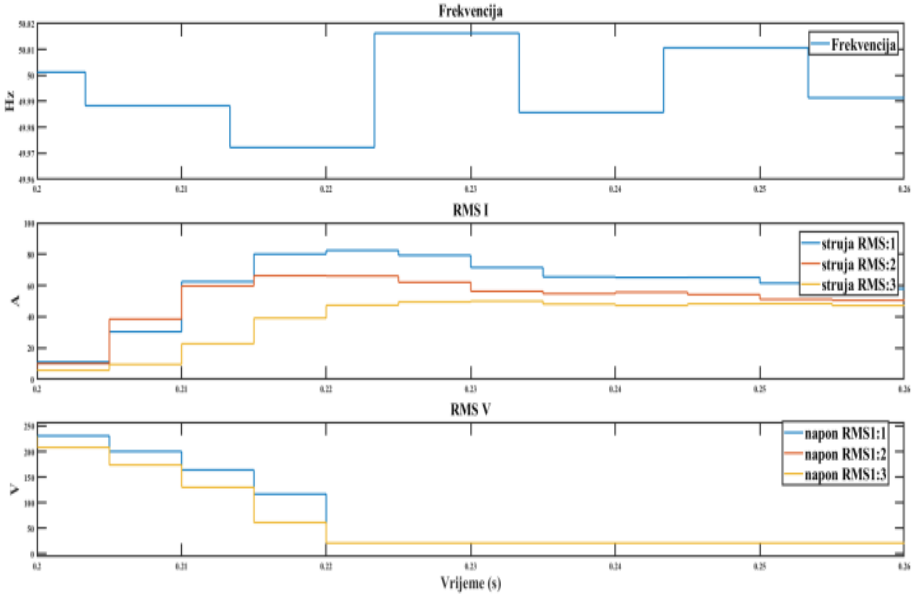
U istraživanju su predložene metode koje su po prirodi rada pasivne u otkrivanju otočnog rada, praćenjem sedam (7) parametara distribucijske mreže koji su odgovorni za kvalitetu električne energije. Uz svih sedam signala uključenih u otkrivanje otočnog rada, predložene metode minimiziraju zone ne detekcije. Redoslijed podataka uzorkovanja od 8 uzoraka, pohranjuje se u slog podataka s operativnim režimom po principu prvi ulazi, zadnji izlazi. Svaki novi uzorak nalazi se na vrhu sloga podataka, a najstariji se pomakne iz istog, čuvajući slog svjež i ažuriran za pravovremeno otkrivanje, što je prikazano na slikama 6.4, 6.5 i 6.6. Slog podataka je ulazni blok podataka za pripremu vježbanja algoritma za svih 7 parametara, u svrhu otkrivanja otočnog rada i

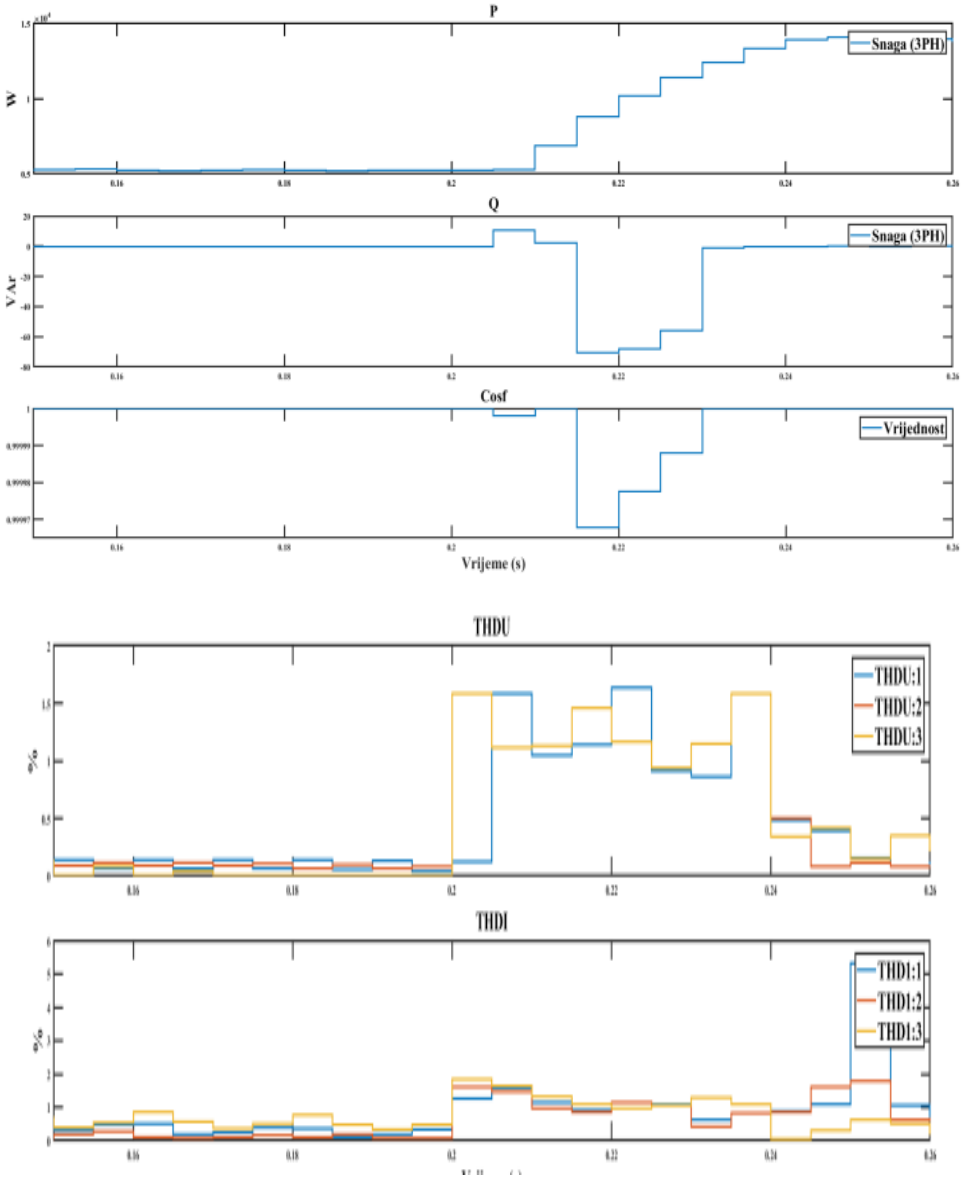
otkrivanje kvarova na mreži, kao što je slučaj sa metodom potpornih vektora. Pregled signala, brzina uzorkovanja i vrijeme uzorkovanja prikazani su na slici 6.2 i tablici 6.1.




THDU
THDU:1
THDU:2
THDU:3
%
THDI
THDI:1
THDI:2
THDI:3
%

a)Otočni rad


Frekvencija
Frekvencija
Hz
RMS I
struja RMS:1
struja RMS:2
struja RMS:3
A
RMS V
napon RMS1:1
napon RMS1:2
napon RMS1:3
V
Vrijeme (s)



b) Kvar na mreži

Slika 6.4. Trend signala na točki zajedničkog spajanja u trenutku prelaska u otočni rad, odozgo prema dolje: frekvencija*(f)*, RMS_I, RMS_U, aktivna snaga generirana od strane distribuiranog izvora (P_G), i reaktivna snaga generirana od strane distribuiranog izvora (Q_G), THD_I , THD_U.

Informacije za sve signale temelje se isključivo na dvije izmjerene vrijednosti: Naponi sve tri faze niskog napona i struje sve tri faze. Izračuni za potrebne signale su sljedeći:

1) Frekvencija (*f*). Budući da mjerni uređaj stalno šalje podatke u Java softver, dok je uzorak unutar programa postavljen za primanje podataka od 1 ms koji nam daju pristup izračunu induktivitetu. Svaka 1 ms jedna je izmjerena točka sa oblika vala napona i struje. Ulazni podatak za MPV klasifikaciju zahtijeva uzorak od 5 ms, stoga je u jednom valu sadržavao

20 ms, a time i 4 uzorka po 5 ms. Stoga su svakih 5 uzoraka sa vremenskog prozora od 1 ms između sebe. Ako usporedimo trenutni njegov vrh s naponskim vrhom, saznat ćemo koliko ima trenutnih kašnjenja nakon naponskog signala ili obratno ako prednjači. Tu se može izračunati koliko je kašnjenje struje za naponom tj. ima li u impedanciji induktivnog otpora tj. koliki je kut kašnjenja. Stoga je formula za izračun frekvencije:

$$I = \frac{V}{z} \tag{6-3}$$

$$z = r + j\varpi L \tag{6-4}$$

$$f = \frac{V - Ir}{IL} \tag{6-5}$$

gdje su:

I - AC struja,
f – frekvencija napona ,
V - efektivna vrijednost napona,
Z - totalna impedancija,
r - otporno opterećenje,
L - induktivnost.

2) Aktivna snaga (P),

$$P = \frac{V^2}{r} \tag{6-6}$$

3) Reaktivna snaga (Q),

$$Q = \sqrt{\left(\frac{V^2}{z}\right)^2 - P^2} \tag{6-7}$$

4) Srednji kvadrat struje (efektivna vrijednost) (RMS_I),

$$I_{RMS} = \frac{I_{Peak}}{\sqrt[2]{2}} \tag{6-8}$$

5) Srednji kvadrat napona (efektivna vrijednost) (RMS_V),

$$V_{RMS} = \frac{V_{Peak}}{\sqrt[2]{2}} \tag{6-9}$$

6) Ukupno harmonijsko izobličenje struje (THD_I). Budući da se koristi RMSI, sljedeća je jednadžba:

$$THD_I = \sqrt{\left(\frac{I_{RMS}}{I_1}\right)^2 - 1} \tag{6-10}$$

7) Ukupno harmonijsko izobličenje napona (THD_V),

$$THD_V = \sqrt{\left(\frac{V_{RMS}}{V_1}\right)^2 - 1} \tag{6-11}$$

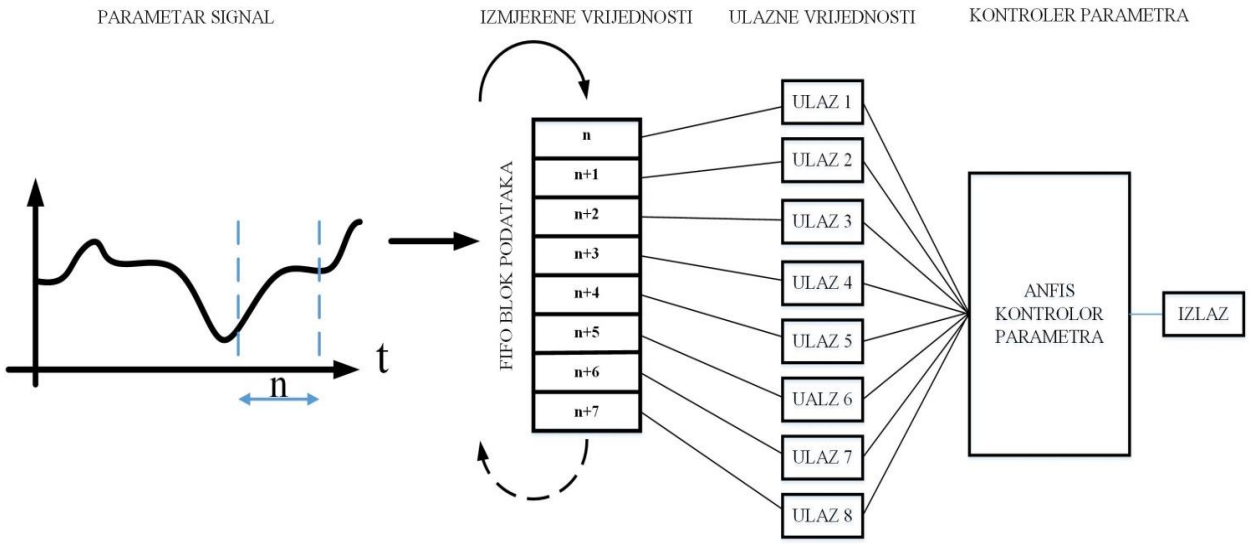
6.2. Slaganje podataka i treniranje metode umjetne inteligencije

U ovom pod poglavlju će biti objašnjeno slaganje podataka koji su prikupljeni od mjerenja na primarnoj strani u slog podataka, koji se koristi za treniranje i testiranje predloženih metoda.

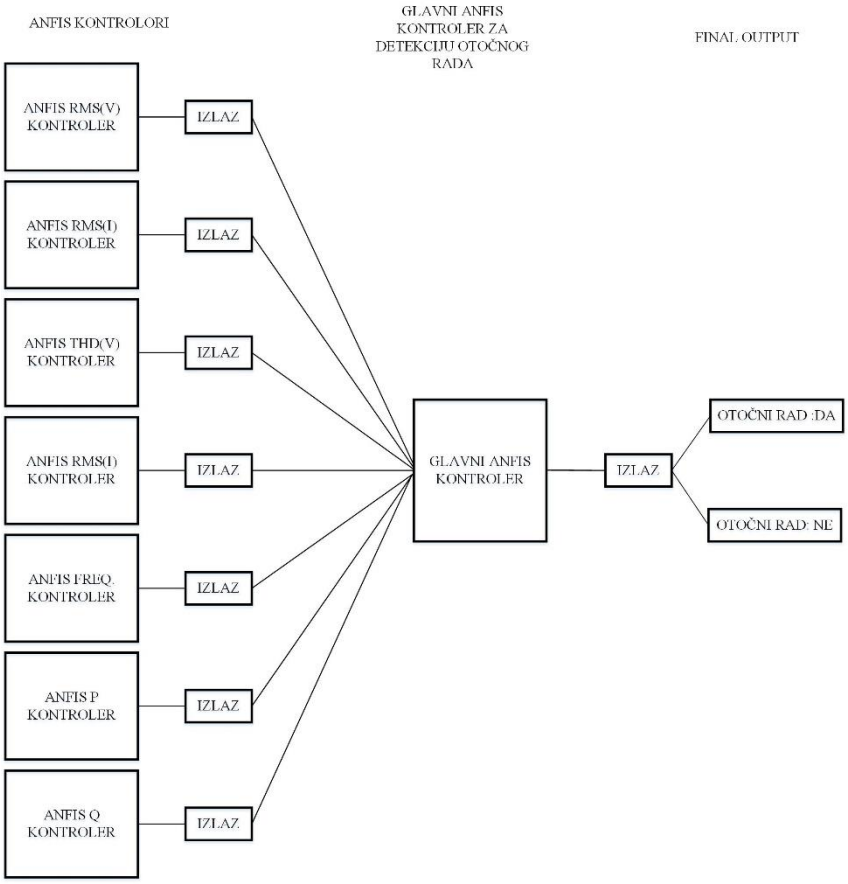
6.2.1. Adaptivni sustav neuro-neizrazitog zaključivanja (eng. Adaptive Neuro-Fuzzy Inference System -ANFIS)

Kao što je spomenuto u pod poglavlju 6.1, podaci se prikupljaju putem posebno izrađenog uređaja s vremenom uzorkovanja od 5 ms. Mrežni analizator nije tehnički u mogućnosti pružiti detaljan uzorak, te se on isključivo koristi za ispitivanje kvalitete električne energije. Uređaj koji se koristio za prikupljanje podataka sa mreže je obrađen i predstavljen u [180]. Svi podaci se obrađuju tako da su prikladni za slaganje u slogove podataka koji se sastoje od 8 brojeva za svaki od navedenih signala: THD_U, THD_I , RMS_U, RMS_I, *f, P i Q*. Svi navedeni signali su ulazi pojedinačno za određeni ANFIS koji je odgovoran samo za obradu ulaza tog signala na izlazni podatak (slika 28). Tih signalnih ANFIS-a ima ukupno 7 koliko i signala. Nakon toga se prikupljaju izlazi iz svih sedam ANFIS kontrolora za svaki od mjerenih signala, nakon čega se provodi trening glavnog ANFIS algoritma nad prikupljenim podacima, tj. izlazima iz signalnih ANFIS-a, koji će dati krajnji izlaz o stanju mreže. Glavni ANFIS algoritam izračunava konačni izlaz na temelju svih ostalih izlaznih

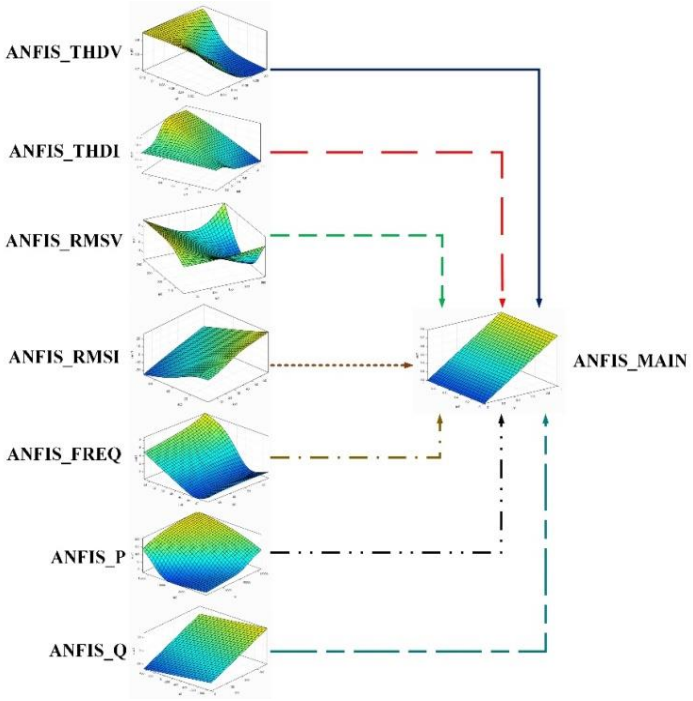
signalnih ANFIS-a, pri čemu nema mjesta za pogrešno shvaćeno stanje distribucijske mreže. Pošto je svaki od navedenih signala prepoznao ulazak u otočni rad na poseban način, a sve zavisno od situacije do situacije, onda se mora na kognitivan način zaključiti je li distribuirani izvor ušao u otočni rad ili je još u sinkroniziranom radu s distribucijskoj mrežom. Vizualni prikaz spomenutog postupka obuke, uključujući kretanje površine svih uključenih signala i glavnog ANFIS-a, prikazan je na slici 29 i slici 30. Postoji linearna ovisnost svih ulaza o izlazu zbog prirode predložene metode, tj. zaključak se donosi na osnovu kvalitete izlaznog signala: ako su svi signali između 0,9 i 1,1, otkriven je otočni rad. Posebna pažnja izlazima je posvećena u poglavlju 8.



Slika 6.5. Prikaz uzorkovanja, pakovanja i plasiranja podataka u ANFIS kontrolor za pojedinačni signal.



Slika 6.6. Detalji i arhitektura veze ANFIS kontrolora za detekciju otočnog rada.



Slika 6.7. Veza između signalnih *ANFIS*-a i glavnog *ANFIS*-a prikazano preko površina kretanja ulaznih veličina.

Ovisnost izlaznog lanca pojedinih *ANFIS*-a, o svim ulaznim vrijednostima, čini signale vezanim jedan prema drugom te tako stvaraju vezanu cjelinu koja jedinstveno opisuje pojavu ulaska u otočni rad. U prilog tome govori činjenica da ulazak u otočni rad uvijek djeluje na RMS_U i THD_U, dok na druge signale kao što su THD_I i RMS_I, a nekada i na f, ne djeluju u svakom prelasku u otočni rad. Također, treba imati na umu da zbog složenosti izlaznih podataka za sve *ANFIS* algoritme, ne možemo zaključiti jednostavno rješenje za glavni *ANFIS*, npr. sustav glasanja ili srednje težinske vrijednosti ulaza itd. Naravno, kao praktična primjena za ovu linearnu ovisnost bitno je napomenuti se da se on-line trening ili off-line ažuriranje baze znanja, izvode samo na prvom skupu ANFIS-a, tj. ANFIS-a koji obrađuju pojedine signale, bez ometanja glavnog ANFIS-a. To ovu metodu čini još fleksibilnijom za uporabu. Na temelju ANFIS opisa navedenog u poglavlju 5, obuka ANFIS-a je bez nadzora. Koristeći opisane alate (prolazak prema naprijed, prolazak unatrag i hibridna metoda učenja), osposobljavanje FIS dijela ANFIS arhitekture, u velikoj mjeri leži na ulaznim podacima. Ako se napravi kvalitetna segmentacija ulaznih podataka, te se ograniči ulaz tako da ne bude smetnji uzrokovanih nestabilnošću i/ili nedostacima u mjerenjima, onda se trening može raditi online s dobrim okruženjem, ali to nije tema ove disertacije. Koristeći zadane podatke o treningu, *ANFIS* generira sustav neizravne logike prema kvaliteti podataka i odnosu između danih ulaznih i izlaznih vrijednosti. Hibridni algoritam rješava trening, a rješenje se prati oduzimanjem klastera umjesto particioniranja na mreži. Razlog tomu je da je priroda potrebnog rješenja grupiranje podataka umjesto aproksimacije funkcija. Na taj način sustav neizravne logike ispunjava bazu znanja stvaranjem pravila „ako-tada“ (eng. „If-then“). Obzirom na iskorištenu tehniku za otkrivanje otočnog rada, predložena metoda je pasivna.

Kao što je navedeno u pod poglavlju 6.1, svi signali se dobivaju u točki zajedničkog spajanja, a izlazni signal se šalje u mrežu na prekidač u izvodu. Važan cilj istraživanja je minimiziranje zone ne detekcije i za tu svrhu se mjeri sedam signala i prikuplja 8 uzoraka za svaki signal. Grupiranje svih uzoraka je ogroman teret za pred procesiranje ulaznih podataka, što može povećati složenost i dimenzionalnost algoritma klasifikacije, gdje je potreban jedan broj kao signalizacija izlaza. Dakle, u kreiranom sustavu svaki izmjereni signal ima vlastiti ANFIS trening, samo sa svojim ulaznim podacima prema navedenim alatima i tehnikama u poglavlju 5. Na temelju sedam izlaza iz svih *ANFIS*-a, slog podataka se formira za trening glavnog ANFIS-a. Taj slog je iste dimenzioniranosti kao i oni slogovi za treniranje signalnih ANFIS-a. To skraćuje trošak vremena, jer se struktura za pakovanje podataka može reciklažno koristiti bez dupliranja mehanizma i time uštedjeti na vremenu i prostoru. Na temelju raspoloživog skupa podataka u ulaznom slogu, ANFIS se trenira s istim pravilima i alatima kao i drugi FIS sustavi. Konačni izlaz je ili signal djelovanja

da se prekidač otvori, ili da se ne otvori, što omogućuje nastavak uzorkovanja. Izraz za opisani postupak dan je izrazom (6-12).

$$Mjerenje = S\log_mjernih_vrijednosti = \begin{Bmatrix} RMS_U(n \;\; n+1 \;\; n+2 \;\; n+3 \;\; n+4 \;\; n+5 \;\; n+6 \;\; n+7) \\ RMS_I(n \;\; n+1 \;\; n+2 \;\; n+3 \;\; n+4 \;\; n+5 \;\; n+6 \;\; n+7) \\ THD_U(n \;\; n+1 \;\; n+2 \;\; n+3 \;\; n+4 \;\; n+5 \;\; n+6 \;\; n+7) \\ THD_I(n \;\; n+1 \;\; n+2 \;\; n+3 \;\; n+4 \;\; n+5 \;\; n+6 \;\; n+7) \\ f(n \;\; n+1 \;\; n+2 \;\; n+3 \;\; n+4 \;\; n+5 \;\; n+6 \;\; n+7) \\ P(n \;\; n+1 \;\; n+2 \;\; n+3 \;\; n+4 \;\; n+5 \;\; n+6 \;\; n+7) \\ Q(n \;\; n+1 \;\; n+2 \;\; n+3 \;\; n+4 \;\; n+5 \;\; n+6 \;\; n+7) \end{Bmatrix},$$

$$PODATKOVNI\ Stek = \begin{Bmatrix} ANFIS_{RMS_U(STEK^{RMS_U})} \\ ANFIS_{RMS_I(STEK^{RMS_I})} \\ ANFIS_{THD_U(STEK^{THD_U})} \\ ANFIS_{THD_I(STEK^{THD_I})} \\ ANFIS_{f(STEK^{f})} \\ ANFIS_{P(STEK^{P})} \\ ANFIS_{Q(STEK^{Q})} \end{Bmatrix}, \quad ANFIS_I_D(Podatkovni_Stek) = Izlaz \tag{6-12}$$

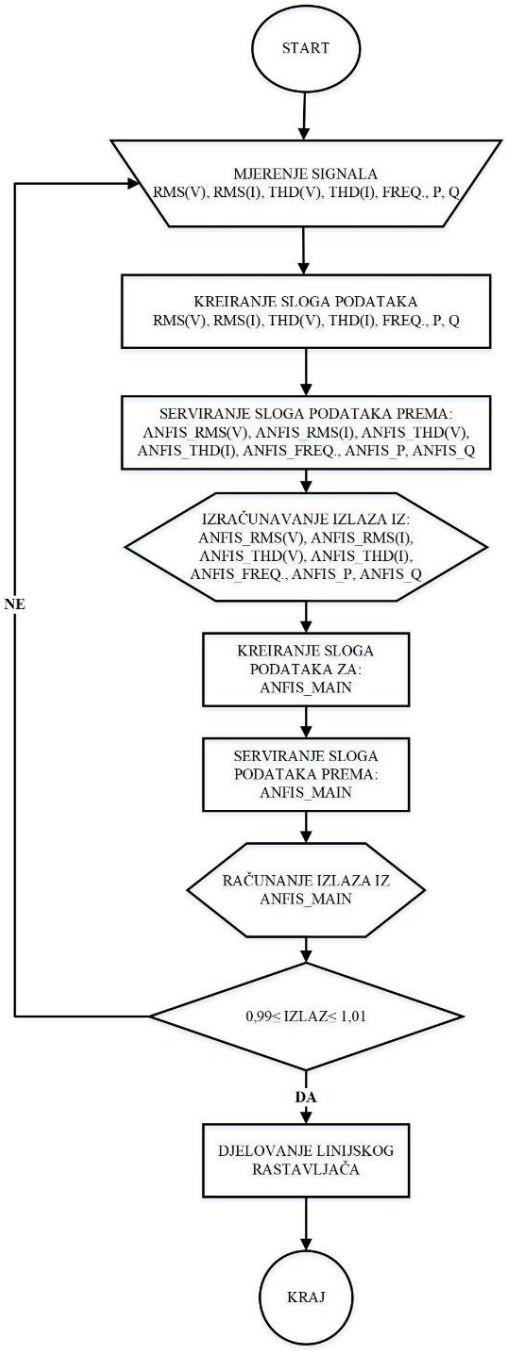
Brzina uzorkovanja ulaznih podataka, količina uzoraka i broj uzorkovanih signala, su odgovorni za kvalitetu *ANFIS*-ovog izlaza, a samim time i minimiziranju zone ne detekcije. Kao što je navedeno na početku, priprema ulaznih podataka za *ANFIS* radi se u realnom vremenu tijekom perioda uzorkovanja od n = 0.005 sekundi. Svakih 0,005 sekundi, drugi uzorak se stavlja na vrh podatkovnog sloga, a slog se dalje obrađuje u ulazni slog za *ANFIS*. Prema broju uzoraka i trajanju mjerenja, minimalno i optimalno vrijeme za otkrivanje otočnog rada je 0,04 sekunde.

Koncept predložene metode je prepoznavanje odnosa između neizrazitih ulaznih podataka s neizrazitim izlaznim podacima, koji su prevedeni prema funkcijama pripadnosti generiranih substraktivnim kategoriziranjem i hibridnom tehnikom učenja. Osjetljivost predložene metode se odnosi na vrijeme i trajanje uzorkovanja koji se koriste za treniranje. Što je uzorak detaljniji i što je kvantitativno više uzoraka pripremljenih za treniranje, to je metoda preciznija i manja je zone ne detekcije. Prema zadanim vrijednostima navedenih varijabli, optimalno vrijeme za otkrivanje otočnog rada je 40 ms.

Svaki novi uzorak izbacuje najstariji uzorak iz podatkovnog sloga, zadržavajući istu količinu uzoraka sve vrijeme u podatkovnom skupu. Imajući na umu da se minimizira zone ne detekcije, broj signala ima tendenciju podizanja s ciljem da obuhvati sve aspekte dimenzionalnosti električne energije. Prema tome, za detekciju otočnog rada se dobiva sedam signala koji su navedeni ranije. Broj izmjerenih vrijednosti korištenih za ulazni stek/slog podataka je 56 ukupno.

Ulazna matrica od 56 uzoraka podijeljena je u 7 redaka za 7 pojedinačnih ANFIS kontrolora (slika 28 i izraz 79). Izlazi iz tih 7 regulatora su ulaz za glavni ANFIS (Slika 6.7). Glavni ANFIS kontrolor za detekciju otočnog rada je treniran da dobije 7 ulaza i odgovori u obliku jednog izlaza, koji je signal za linijski rastavljač u potrebi isključenja distribuiranog izvora sa mreže.

Priprema podataka treninga provodi se prema različitim konfiguracijama opterećenja na distribucijskoj mreži: nisko opterećenje u odnosu na proizvodnju energije, isto opterećenje kao proizvodnja, veće opterećenje od proizvodnje energije, a sve ponovno s još jednim dodatnim distribuirani izvor u točki zajedničkog spajanja. Obzirom na prirodu foto naponskog sustava da ne proizvodi jalovu snagu i, problem stabilnost napona uslijed brzine promjene faktora kvalitete (Q_f) u distribucijskoj mreži, dobivaju se i podaci s različitim omjerom reaktivne induktivne i reaktivne kapacitivne snage u distribucijskoj mreži. Glavni *ANFIS*, također razmatra i za slučajeve promjene uklopnog stanja gdje se dodaje/oduzima opterećenje, te simuliraju kvarovi u distribucijskoj mreži. Dijagram tijeka kompletnog sustava za detekciju otočnog rada na temelju ANFIS, prikazan je na slici 6.8.

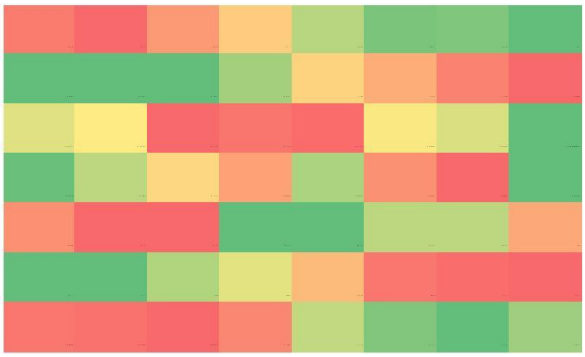


Slika 6.8. Dijagram tijeka za predloženi algoritam detekcije otočnog rada zasnovanog na ANFIS metodi. Vrijednosti 0,99 i 1,01 su proizvoljno odabrani kao prag koji treba preći da bi izlaz bio jednoznačno određen.

6.2.2. Duboko učenje (eng. Deep Learning – DL)

Ulaz u trening konvolucijske neuronske mreže (eng. Convolution Neural Network – CNN) se dobiva mjerenjem u točki zajedničkog spajanja. Kvaliteta ulaznih podataka određuje učinkovitost KNN-a kao sustava za detekciju otočnog rada. Istraživanje važnosti teme daje imperativ vremenu

detekcije i selektivnosti. U pravilu s pravodobnim otkrivanjem, dolazi do zahtjeva za što kraće vremensko uzorkovanje. Skraćivanje vremena uzorkovanja čini da se selektivnost teže postigne, a time i povećanje NDZ-a. Između ta dva cilja javlja se potreba za optimizacijom brzine uzorkovanja. Predložena CNN metoda čuva pasivnu prirodu otkrivanja otočnog rada uključivanjem 7 izmjerenih parametara koji su navedeni u pod poglavlju o prikupljanju signala. Navedeni sedam signala daje mogućnost predloženoj metodi minimiziranje zone ne detekcije-e. Brzina uzorkovanja svih signala je pet milisekundi (0,005 s) i, kako je navedeno na slici 25, prikazuje učestalost uzorkovanja i korelaciju s frekvencijom distribucijske mreže. Broj uzoraka je osam, pa cijeli uzorak traje 40 ms. Slijed uzorkovanih podataka pohranjuje se u slog podataka s operativnim režimom po principu prvi došao prvi izašao (eng. „First in First out“ - FIFO). Slog podataka je ulazni podatak za otkrivanje otočnog rada i koristi se kao podatak za vježbanje CNN-a svih sedam signala. U tablici 10 je pregled signala, brzina uzorkovanja i vrijeme uzorkovanja. Pošto je CNN metoda prepoznavanja slika, ulazni signal nije čista matrica brojeva, već slika obojenog spektra tih brojeva, zelena za najnižu vrijednost, a crvena za najveću vrijednost. Sa 40 ms vremena uzorkovanja, dolazi jedinstvena slika signala. Svaka slika od 5 ms osvježava se i dalje obrađuje na ulazni sloj CNN-a. Uzorak ulazne slike prikazan je na slici 32.



Slika 6.9. Primjer slike kao ulaznog parametra u DU sustav detekcije otočnog rada distribuiranog izvora.

Parametri ulazne slike prikazani su u tablici 6.2. Iz pod poglavlja 5.1, opis CNN-a, nadzirano treniranje CNN-a provodi se prema parametrima prikazanim u tablici 6.2. i tablici 6.3. Koristeći navedenu sliku za vježbu, kao u (92), CNN generira konvolucijske neuronske mreže. Provedena obuka obrađuje se prema uputama iz pod poglavlja 5.1. Rezultati su klasifikacija ulaznih slika u dvije skupine kao izlaz iz generiranog CNN-a. Predložena metoda otkrivanja otočnog rada je pasivna obzirom na činjenicu da su samo mjerne tehnike korištene za otkrivanje otočnog rada. Prema slici 6.8, svi signali se dobivaju u točki zajedničkog spajanja, a izlazni signal za stanje otočnog rada se šalje na prekidač za odvajanje distribuiranog izvora sa mreže. Grupiranje uzoraka

u obliku slike je automatizirano pomoću algoritma pripreme, prije slanja slike na KNN. Stoga se stvara sustav u kojem svaki izmjereni signal ima svoj vlastiti obojeni trag, samo sa svojim ulaznim podacima prema zeleno-crvenoj tehnici. Na temelju sedam signala s 8 uzoraka, formiranih u jednoj slici, CNN je obučen da daje jedan izlaz: otočni rad (pridruženi signal je „on-isl“) ili sinkroniziran (pridruženi signal je „off-syn“). Konačni izlaz je ili signal odvajanja za linijski prekidač ili ništa što omogućuje nastavak uzorkovanja. Opisana procedura je:

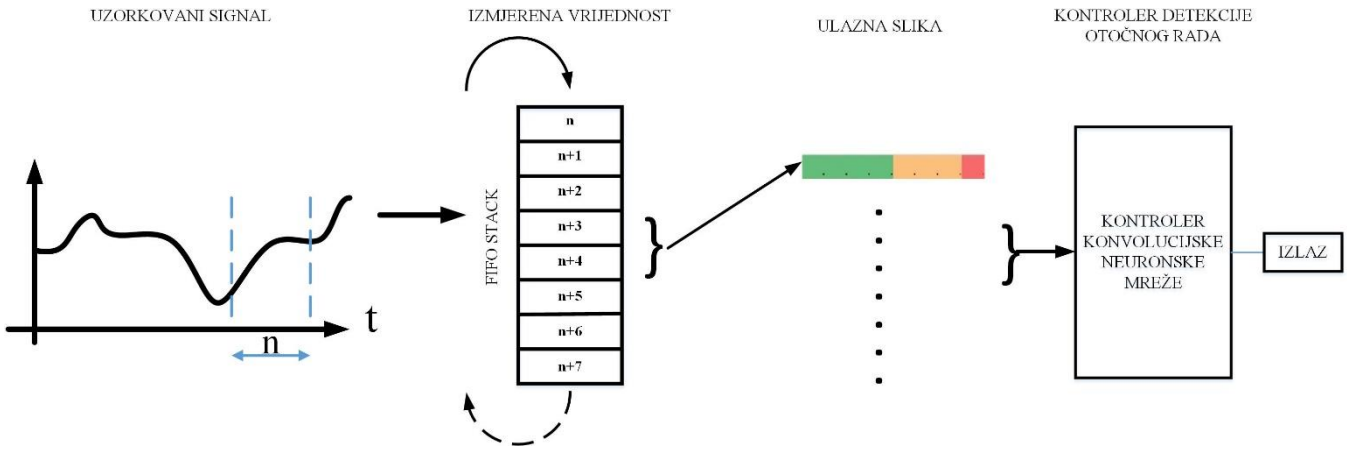
$$MJERENJE = SLOG\ MJERENIH\ VRIJ.$$

$$= \begin{Bmatrix} RMS_U(n & n+1 & n+2 & n+3 & n+4 & n+5 & n+6 & n+7) \\ RMS_I(n & n+1 & n+2 & n+3 & n+4 & n+5 & n+6 & n+7) \\ THD_U(n & n+1 & n+2 & n+3 & n+4 & n+5 & n+6 & n+7) \\ THD_I(n & n+1 & n+2 & n+3 & n+4 & n+5 & n+6 & n+7) \\ FREQ(n & n+1 & n+2 & n+3 & n+4 & n+5 & n+6 & n+7) \\ P(n & n+1 & n+2 & n+3 & n+4 & n+5 & n+6 & n+7) \\ Q(n & n+1 & n+2 & n+3 & n+4 & n+5 & n+6 & n+7) \end{Bmatrix} =$$

$$= \begin{Bmatrix} ANFIS_{RMSU(STACK^{RMSU})} \\ ANFIS_{RMSI(STACK^{RMSI})} \\ ANFIS_{THDU(STACK^{THDU})} \\ ANFIS_{THDI(STACK^{THDI})} \\ ANFIS_{FREQ(STACK^{FREQ})} \\ ANFIS_{P(STACK^{P})} \\ ANFIS_{Q(STACK^{Q})} \end{Bmatrix} = \cdots = SLIKA = \text{}$$

$$CNN(\text{}) = IZLAZ \qquad (6\text{-}13)$$

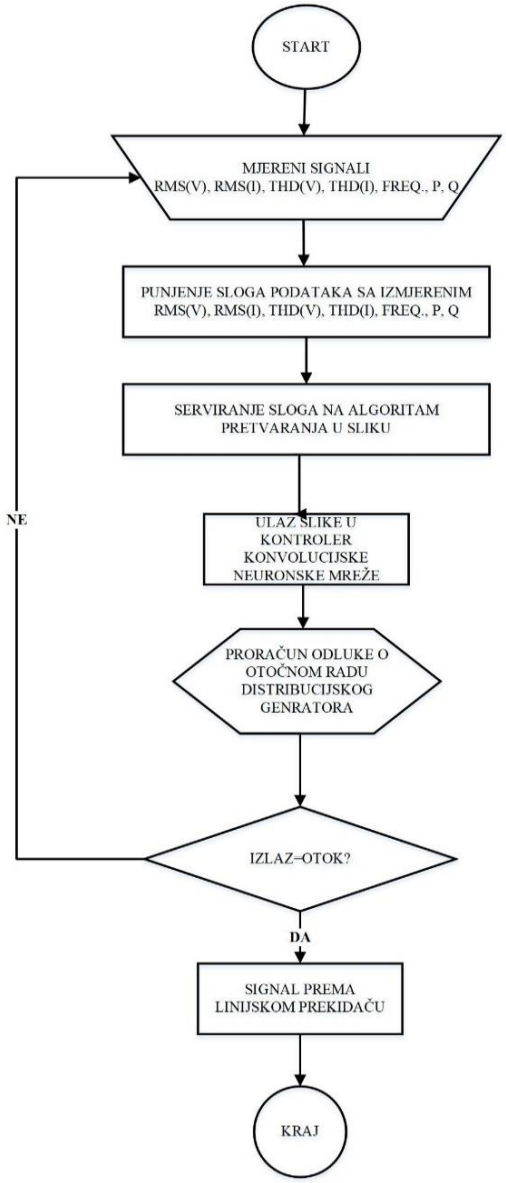
Brzina uzorkovanja ulaznih podataka, količina uzoraka i broj uzoraka, glavna su prednost i kvaliteta CNN-a. Priprema ulazne slike vrši se u realnom vremenu tijekom perioda uzorkovanja od n = 0,005 sekundi. Svakih 0,005 sekundi drugi uzorak se stavlja na vrh stogova podataka, a stog se dalje obrađuje u algoritam pripreme slike. Prema broju uzoraka i trajanju mjerenja, minimalno vrijeme za otkrivanje otočnog rada je oko 0,04 s (6-13). Uzorkovanje, slaganje podataka i priprema slike za CNN, prikazani su na slici 33.



Slika 6.10. Uzorkovanje, slaganje i priprema ulaznih podataka za CNN.

Koncept predložene metode je prepoznavanje relacija između ulaznih podataka signala formiranih u obojenu sliku. Osjetljivost predložene metode uvelike je povezana s brojem slika za vježbanje, više slika za vježbanje, veća je preciznost u odlučivanju. Prema zadanim vrijednostima navedenih varijabli, minimalno vrijeme je prikazano izrazom (6-13).

Novi uzorak izbacuje najstariji uzorak iz podatkovnog sloga, držeći istu količinu uzoraka sve vrijeme (FIFO raspoređivanje). Prikupljene slike vježbanja su u skladu s različitom konfiguracijom opterećenja na nisko naponskoj distribucijskoj mreži-u: nisko opterećenje, isto opterećenje kao generacija, veće opterećenje od generacije, a sve opet s još jednim distribuiranog izvora u istoj točki zajedničkog spajanja. Nedostatak generiranje jalove snage i nestabilnost napona zbog brze promjene kapaciteta niskonaponske distribucijske mreže, podaci za trening dobivaju se i različitim omjerom reaktivne induktivne i kapacitivne snage u niskonaponskoj distribucijskoj mreži. Prikupljene slike za treniranje su 54 skupa podataka od osam uzoraka za svaki nadzirani signal. Također su razmatrani scenariji prekidača opterećenja i isključivanja opterećenja, kvarovi u distribucijskoj mreži: 1 faza-uzemljenje, 2-fazni KS L1L2, 2-fazni KS L2L3, 3-fazni KS L1L2L3 i 3-fazno uzemljenje. Prikazani dijagram tijeka kompletnog sustava za detekciju otočnog rada na CNN-u nalazi se na slici 6.11.



Slika 6.11. Dijagram toka za metodu otkrivanja otočnog rada na temelju dubokog učenja.

Proces treniranja započinje pripremom snimaka izmjerenih ulaznih signala koji rade u ne-otočnom scenariju i slika koje rade u otočnom scenariju. Oba skupa slika imaju ista svojstva i postavke za boju, položaj signala, količinu uzoraka, dimenziju. Prikaz navedenih postavki za ulazne slike nalazi se u Tablici 6.2. Dva seta ulaznih slika podijeljena su u dvije skupine: off-syn i on-isl, prikazujući dva scenarija. Obuka se provodi na tim dvjema skupinama koje vode CNN da prepoznaju dva uvjeta u distribucijskoj mreži: distribuirani izvori koji radi u sinkronizmu s distribucijskom mrežom, distribuiranog izvora koji radi u otočnom radu. Na temelju tih podataka, algoritam CNN-a uči koje su slike članovi prve skupine, a koje su druge skupine. Rad CNN algoritma je u realnom vremenu, prepoznajući ulaze kao članove jedne od dvije skupine. Obuka CNN korisnika nadzirana je tako da svaka slika mora biti definirana za izlaznu vrijednost.

Tablica 6.2. Postavke za sliku kao ulazni podatak za CNN mrežu.

	Ulazni parametri
Dimenzije	200x200x3
Shema boja	Od zelene do crvene
Komponenta signala po redovima	*RMS($_U$)-RMS($_I$)-THD($_U$)-THD($_I$)-f-P-Q*
Broj uzoraka	8

Vremenska razlika između dvije ulazne slike je 5 ms, zbog vremena uzorkovanja signala. Broj korištenih slika treninga je 142 uzorka. Prijedlog autora ove disertacije je da se unaprijed definira arhitektura CNN-a koja će biti obučena. Svojstva CNN arhitekture prikazana su u tablici 6.3.

Tablica 6.3. Arhitektura CNN mreže nakon treniranja.

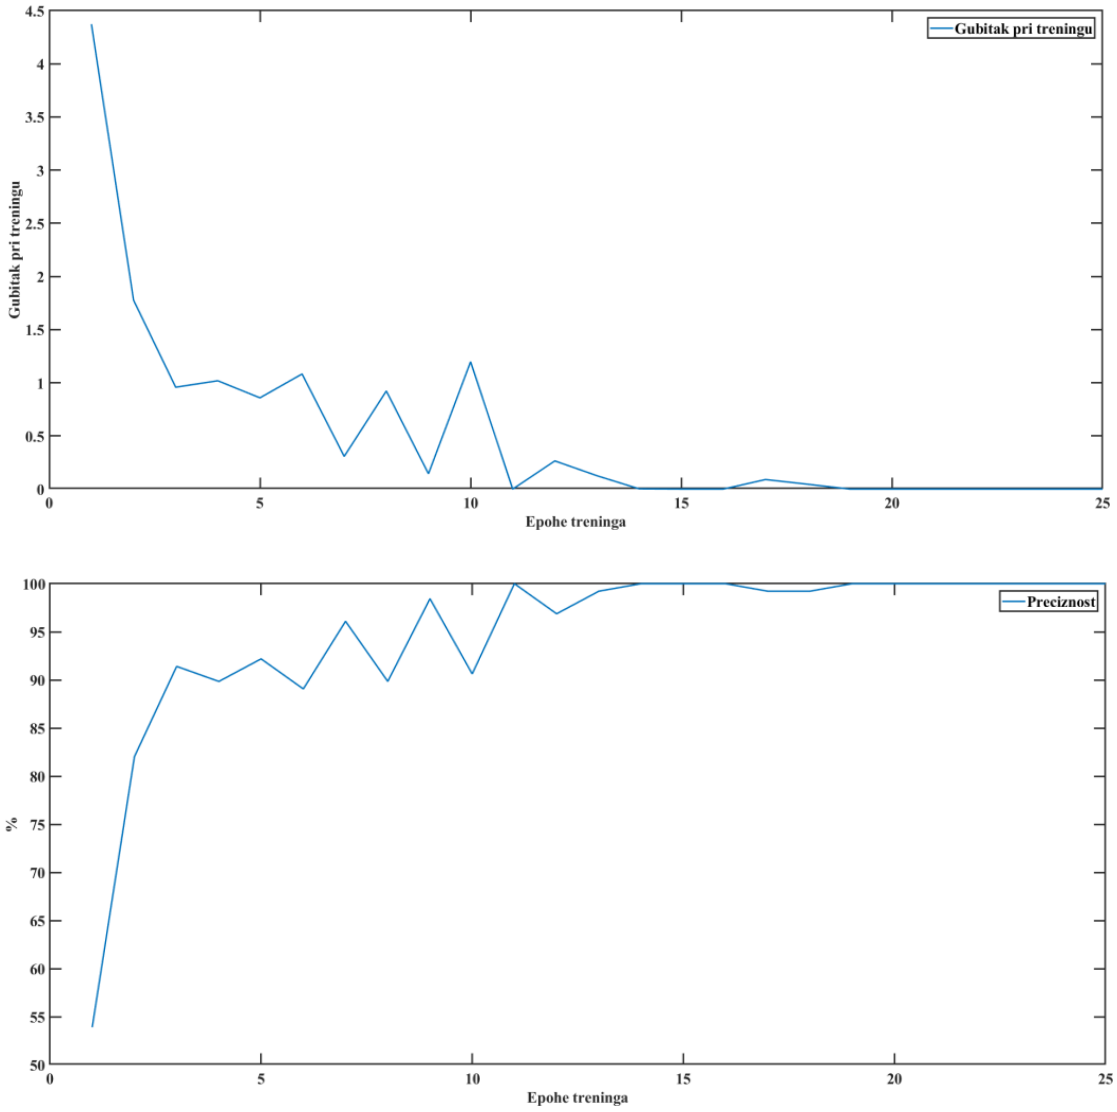
Nivoi	**Postavke**
Ulazna slika	[200x200x3]
Konvolucijski 2D	[5, 20]
ReLu	
Maksimalno udruživanje 2D	[2, "Stride", 2]
Potpuno povezani	[2]
SoftMax	
Klasifikacija	

Provedeni trening izvršen je uz sljedeće parametre:

- Moment - 0,9. Naznaka doprinosa prethodnog koraka, što znači 90% doprinosa iz prethodnog koraka.
- Inicijalna stopa učenja - $1x10^{-4}$.
- Spoznajni raspored učestalosti - komadići. Svaki određeni broj krivulja učenja epoha, ažurira se množenjem s određenim čimbenikom.
- Regulacija L2 - $1x10^{-4}$. Dodavanje težine funkciji gubitka, tako se izbjegava prekomjerno treniranje.

- Maksimalni broj epoha - 25.
- Mini serija - 128.

Ostali parametri treninga se ne spominju, jer nisu važni za izvješće o kvaliteti obuke CNN-a. Rezultati obuke prikazani su na slici 6.12.

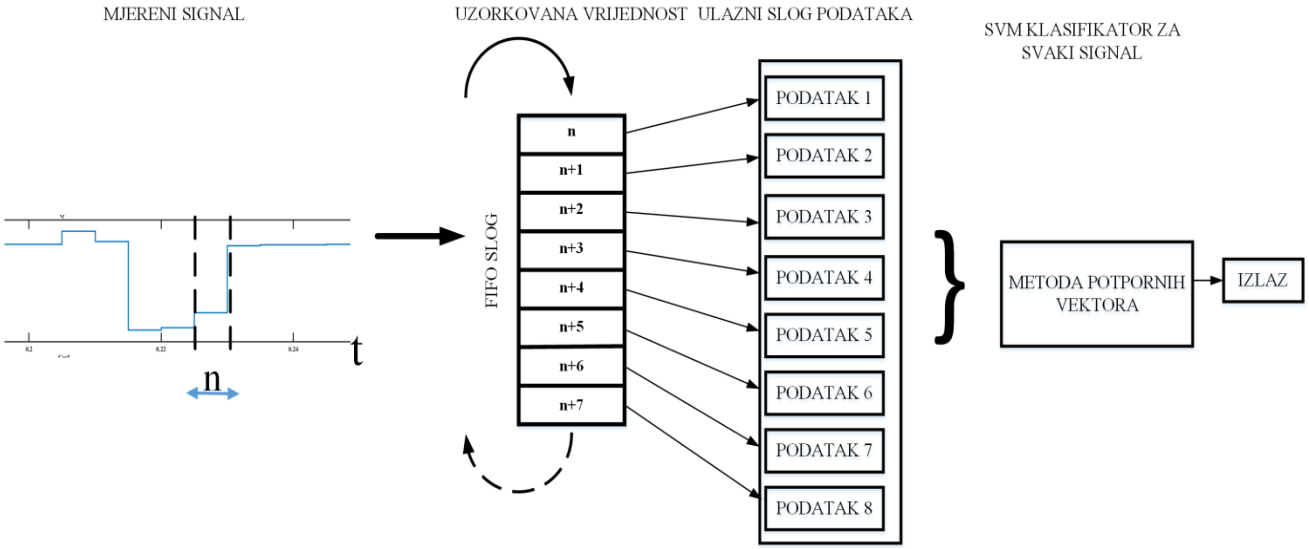


Slika 6.12. Izlazni rezultati vježbanja CNN-a pomoću postavki iz tablice 6.3., gore: gubitak treninga, dolje: točnost vježbanja.

Sa slike 6.12. vidljiv je napredak točnosti prema 100 %, s istim gubitkom treninga na 0. Prema tim podacima, CNN je obučen prihvatiti sve slike treninga kao pravila u bazi znanja bez prevelikog opremanja, zbog ograničene količine slika za trening.

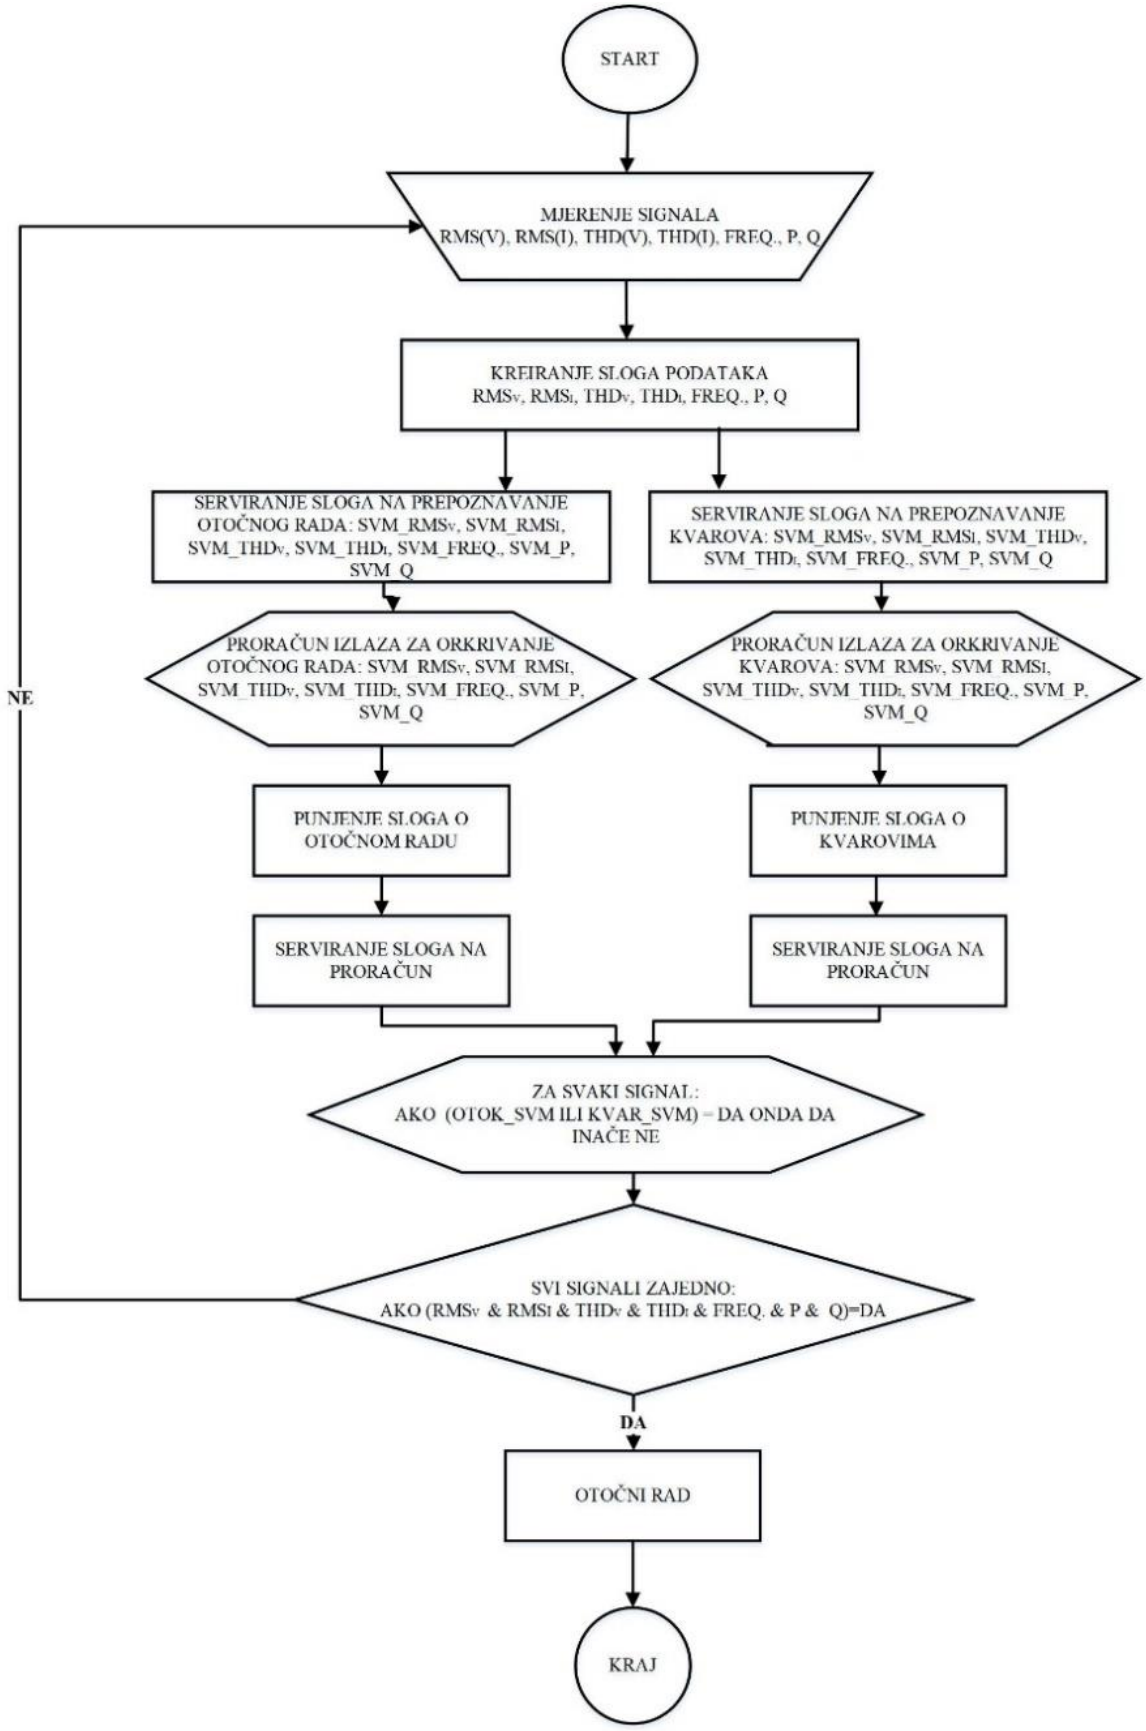
6.2.3. Metoda potpornih vektora (eng. Support Vector Machine - MPV)

Svaki signal sa slike 6.10 služi kao jedan MPV specifičan za odgovorni signal. Obrada izmjerenih signala se vrši u obliku FIFO sloga i pakira se u ulaznu podatkovnu ploču koja je ulaz za MPV. Prema ulaznim podacima, MPV stvara predviđeni izlaz klasifikacije za zadanu skupinu podataka. Taj izlaz se dalje razmatra s algoritmom prikazanim na slici 6.13, gdje sudjeluje u postupku klasifikacije trenutnih promjena koje utječe na konačni izlaz. Isti izlazni signal se koristi i za MPV detekciju otočnog rada i za MPV za otkrivanje kvarova, te u kombinaciji s "AND" Booleov-im operatorom daje konačni odgovor o prirodi praćene promjene (rad u otočnom režimu ili ne). Na slici 6.13, prikazana je arhitektura uzorkovanja za jedan od 7 signala sa njegovog MPV na kraju bloka.



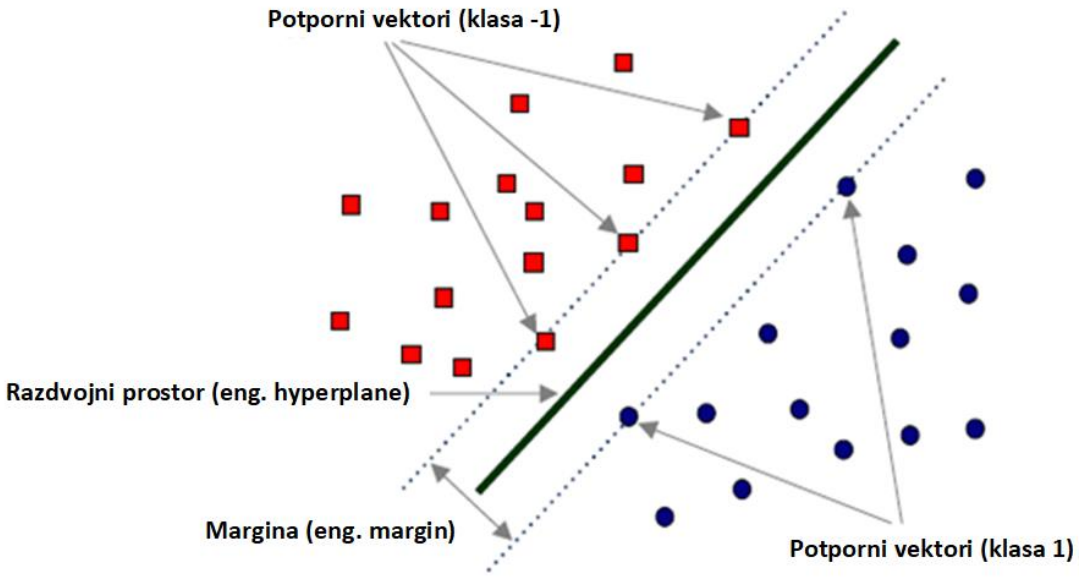
Slika 6.13. Predložena arhitektura uzorkovanja za određeni signal.

Cjelokupni predloženi algoritam za klasifikaciju pojava na mreži prikazan je na slici 6.14. Prikazuje dvije odvojene MPV klasifikacije za otočni rad i klasifikaciju kvarova s konačnom usporedbom obje.



Slika 6.14. Pregled i blok dijagram predložene MPV metode.

Metoda potpornih vektora (MPV) je algoritam učenja pod nadzorom koji se koristi za mnoge različite zadatke koji uključuju klasifikaciju ili regresiju danog skupa podataka. Zbog svoje prirode, uglavnom se koristi za probleme klasifikacije, gdje se jedan skup podataka razlikuje od drugih, koristeći neku prikladnu hiperpovršinu. Vizualna i logička reprezentacija MPV je grafički prikaz svake podatkovne stavke kao točke u n-dimenzionalnom prostoru (gdje je n broj promatranih vrijednosti), a vrijednost svakog obilježja odgovara vrijednosti određene koordinate u n-dimenzionalnom prostoru. Cilj je pronalaženje hiperpovršine koja razlikuje dvije klase podataka do razine zadovoljstva, tj. dopuštene greške, kao što je prikazano na slici 6.15.



Slika 6.15. MPV algoritam općenita klasifikacija hiperpovršinskog prikaza.

U ovoj disertaciji, klasificirane su dvije situacije: otočni rad (postoji ili ne postoji) u distribucijskoj mreži. Blok koji se koristi za MPV obuku sadrži po 8 vrijednosti. Što znači da je dimenzija MPV jezgre 8, što dalje znači da je projektiran MPV algoritam radi klasifikaciju u 8-dimenzionalnom prostoru. Hiperpovršina je u n-1 dimenzionalni pod prostor, s tim da je prostor točaka koje se diskriminiraju R^n. Iz toga proizlazi zaključak da je dimenzija točaka n=8, a hiperpovršina je 7-dimenzionalni pod prostor. Još jedan od zadataka za uspješno klasificiranje dva skupa podataka je određivanje margine. Razlog odabira velikih margina je izbjegavanje visoke šanse za klasifikaciju ulaznih podataka. Prije definiranja granice, MPV prvo odabire pravu hiperpovršinu. Prava hiperpovršina neizrazito definira marginu. Odabir pravog kernela mora se izvršiti obzirom na sve ulazne signale: *f, RMS_I, RMS_V, P, Q, THD_I i THD_V*. Razina dimenzije kernela je 8, što navodi na zaključak da bi možda trebalo napraviti „trik kernela“ koji je pod zadatak za odabir prave hiperpovršine. Kernel je definiran kao:

$$y' = sign\sum_{i=1}^{N}\omega_i y_i k\left(x_i, x'\right) \tag{6-14}$$

gdje su:

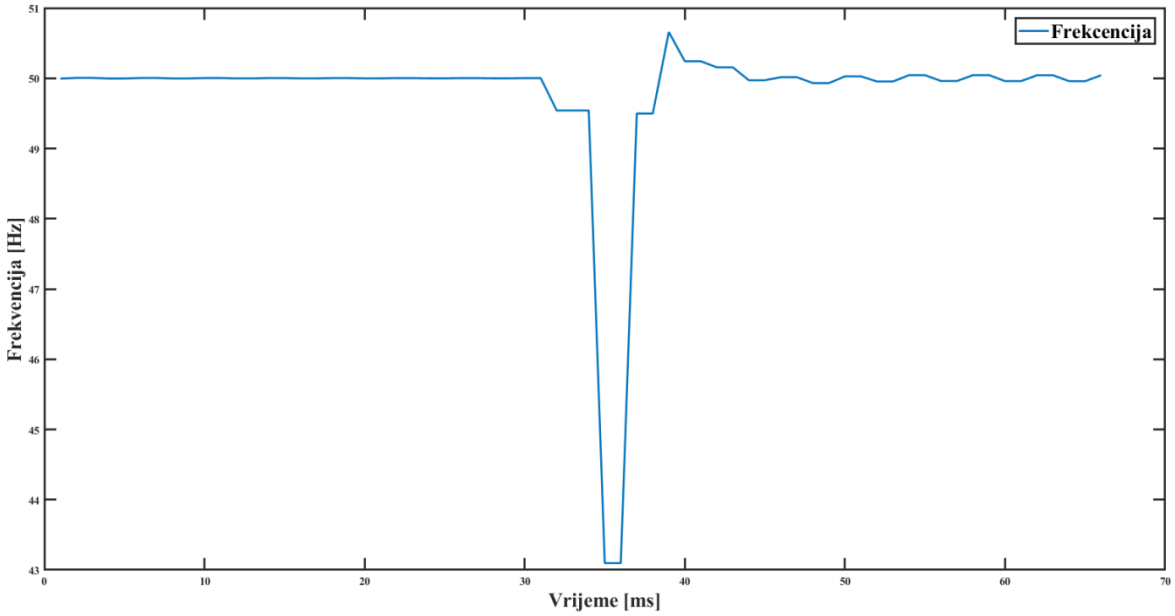
y'€ {-1, 1} - kernel binarni klasifikator predviđen za parametar x',

k: X x X → ℝ - funkcija jezgre koja čini segregaciju između para ulaza x, x '€ X,

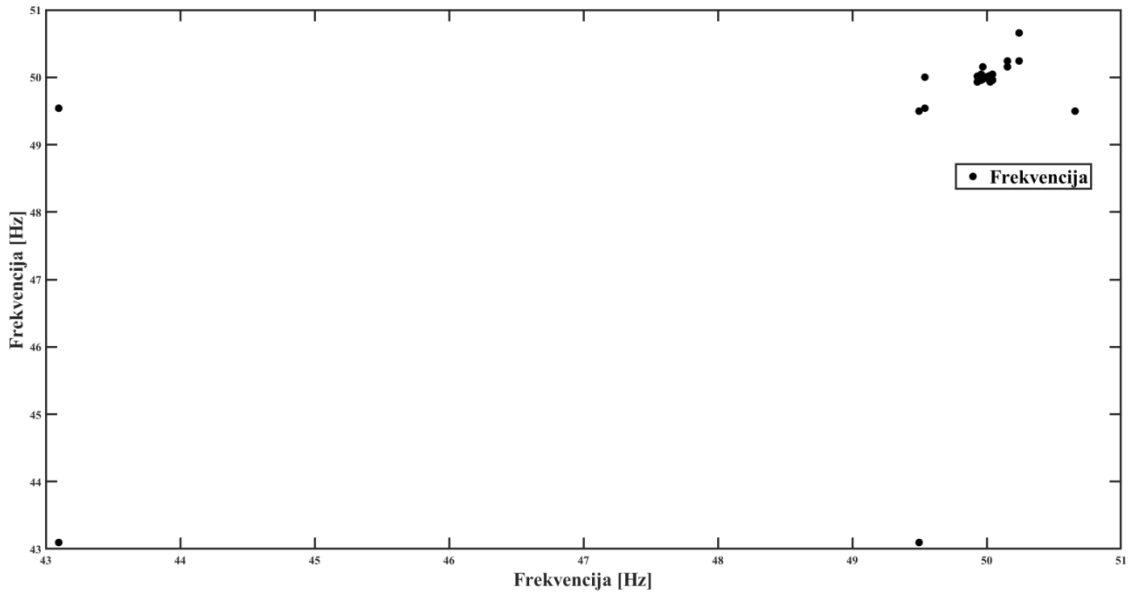
N - dimenzija jezgre i rasponi suma nad svim od njih s y_i € {-1, 1},

ω_i - težina za uzorke treninga,

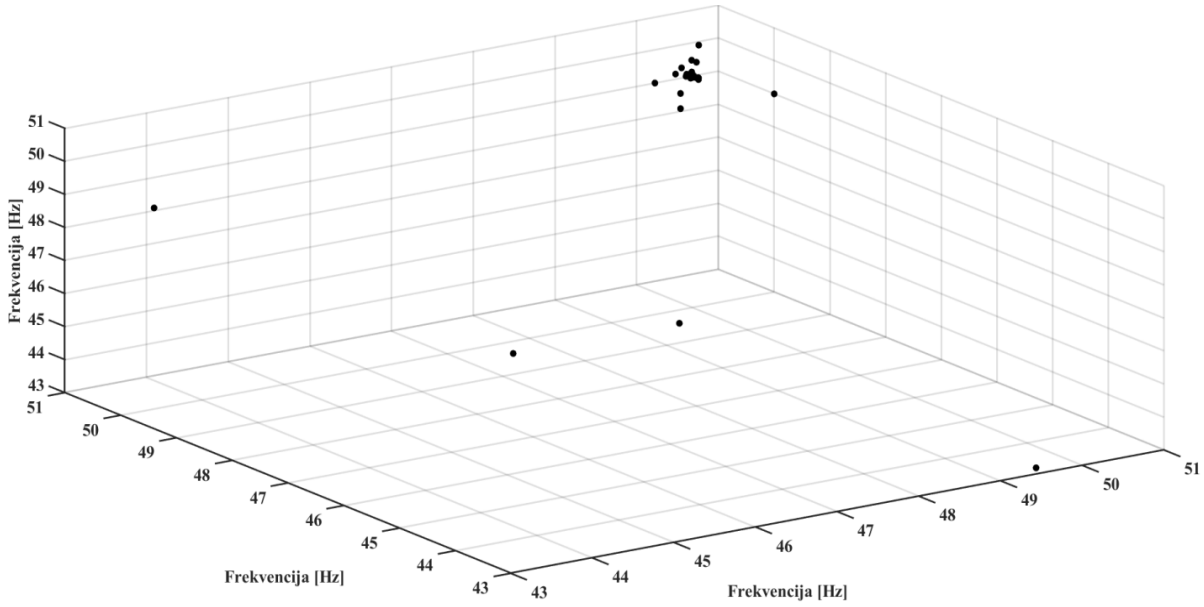
Funkcija znaka (eng. sign) određuje predznak funkcije y ', pozitivna ili negativna. U ovom slučaju N je 8, ako izraz (93) zadovoljava klasifikaciju na temelju ulaznih podataka. Ulazni podaci prikazani su na slici 6.16, 6.17 i 6.18. Sve navedene brojke prikazuju isti ulazni signal, samo razlika je dimenzija ulaznog niza. Iako je nemoguće prezentirati do dimenzije 8, slika 41 predstavlja do treće dimenzije ulaznog niza podataka.



Slika.6.16. Ulazni podaci tijeka frekvencije za jednu dimenziju.



Slika 6.17. Ulazni podaci tijeka frekvencije za dvije dimenzije.



Slika 6.18. Ulazni podaci tijeka frekvencije za tri dimenzije.

Podaci su ograničeni na frekvenciju, jer je prezentacija slična za svih 7 signala. Iz podataka je jasno pozicija da: većina normalnog radnog stanja mreže je grupirana oko 50 Hz na sve tri dimenzije. Stoga se razdvajanje između sinkronog i otočnog rada distribuiranog izvora s mrežom dijeli preko globalnog maksimuma od 50 Hz, što je najbolje opisano Gaussovom funkcijom i argumentima prikladnim za frekvenciju kao:

$$K\left(x, x'\right) = e^{\left(-\gamma\left\|x-x'\right\|^2\right)} \tag{6-15}$$

gdje su:

x € X: {50,50,50,50,50,50,50} - ulazni vektor veličine 8;

x '€X - izmjereni slog podataka za klasifikaciju;

γ - parametar skale kernela koji se koristi za dijeljenje svih elemenata u Gram matrici kernela.

Određivanje γ prepušteno je softveru, jer je napravljeno generatorom slučajnih brojeva, ali uključuje optimalno rješenje na temelju uzoraka iz obuke.

Hiperpovršina može biti opisana kao:

$$\vec{\omega}\vec{x} - b = 0 \tag{6-16}$$

gdje su:

ω - normalni vektor ortogonalni na hiperpovršinu i jedinični vektor za odgovarajući euklidski prostor $\mathbb{R}^n$,

x - zadan skup podataka za jednu situaciju, tako da se iz (6-16) margine može opisati kao:

za sve situacije iznad hiperpovršine: : $\vec{\omega}\vec{x} - b = -1$ (6-17)

za sve situacije ispod hiperpovršine: : $\vec{\omega}\vec{x} - b = 1$ (6-18)

ako je x = {x1, x2, x3,… xn}, onda je udaljenost od x do hiperpovršine:

$$k = \frac{\vec{x}\omega - b}{\sqrt{\omega^2}} \tag{6-19}$$

U kartezijanskom obliku:

$$\left|k\right| = \frac{\left|\omega_1 x_1 + \omega_2 x_2 + \ldots \omega_n x_n - b\right|}{\left|\omega\right|} \tag{6-20}$$

U našem slučaju n = 8, tako da je:

$$k = \frac{\left|\omega_1 x_1 + \omega_2 x_2 + \ldots \omega_8 x_8 - b\right|}{\sqrt{\omega_1^2 + \omega_2^2 + \ldots + \omega_8^2}} \tag{6-21}$$

To se može riješiti na različite načine, jedan od njih je postupak optimizacije, gdje se ω i b pretražuju kao:

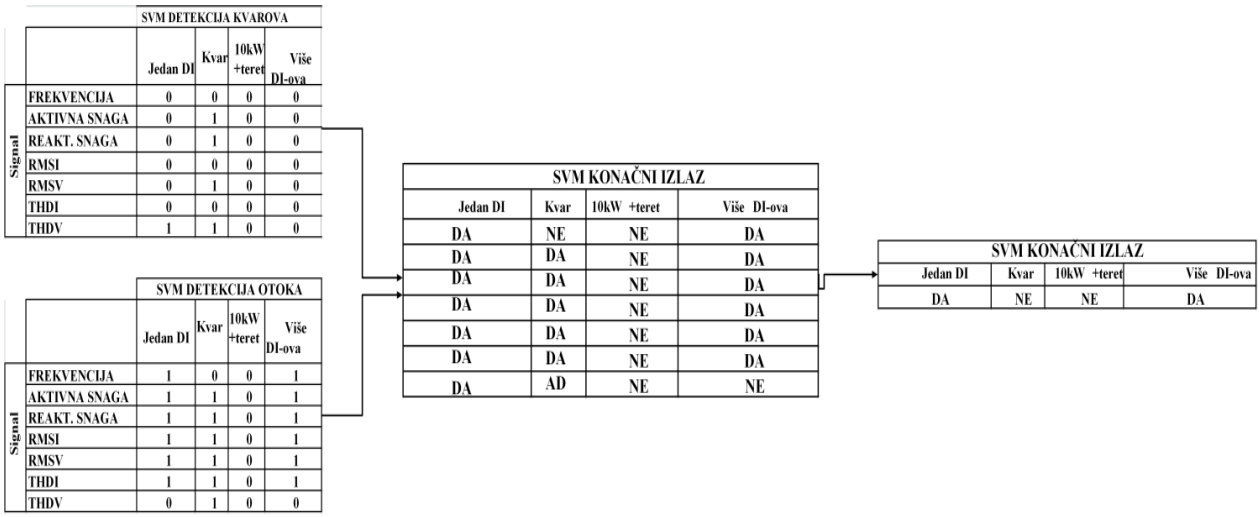
$$y_i\left(\vec{\omega}\vec{x}_i - b\right) \geq 1 gdje\ je i = 1,2,\ldots,8 \tag{6-22}$$

Optimizacija se provodi pomoću softverskog alata za svih 7 signala prema slogovima podataka obuke. Nakon provedene obuke rezultati treniranja za svih 7 signala prikazani su u tablici 6.4.

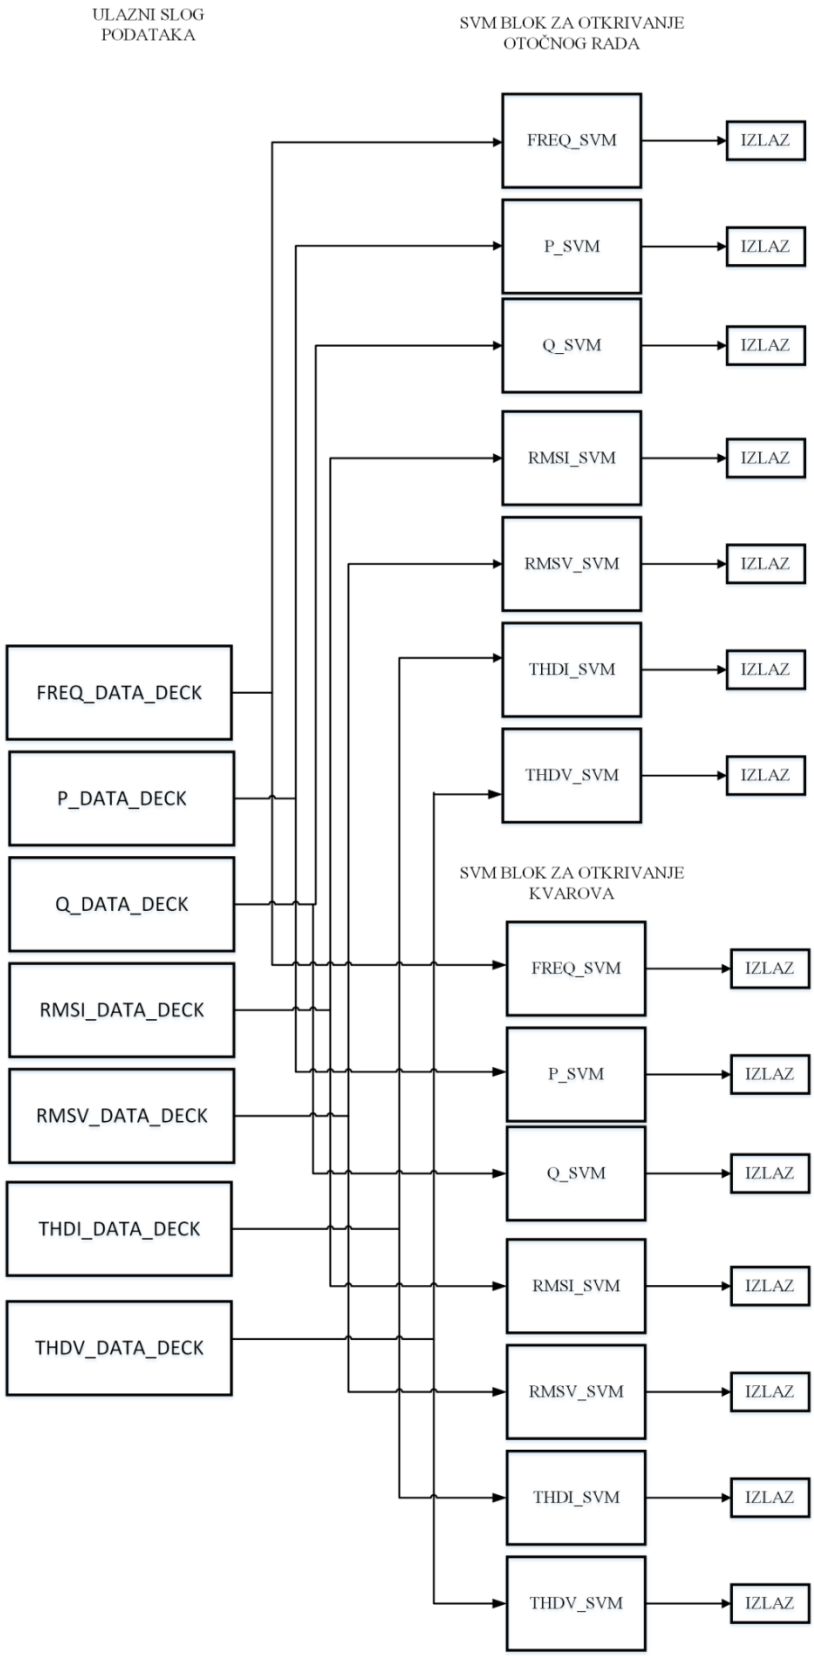
Tablica 6.4. Detalji treninga MPV algoritma za otkrivanje otočnog rada distribuiranog izvora.

Rezultati treniranja za detekciju otočnog rada							
	Frekvencija	*P*	*Q*	RMS_I	RMS_V	THD_I	THD_V
Kernel funkcija	Gausijan	Kubna	Gausijan	Kubna	Kubna	Kubna	Kubna
Kernel skala	0,71	1	2,8	0,38	0,71	2,26	1,68
Broj promatranja (promatrano vs predviđeno: 0:0, 0:1, 1:0, 1:1)	8,1,0,45	6,3,0,45	3,6,0,45	4,5,1,44	2,7,0,45	9,0,1,44	8,1,0,45
Efikasnost (promatrano / predviđeno)	0,99	0,89	0,86	0,93	0,74	0,98	0,91
Analiza glavnih komponenti (95 %)	da	da	da	da	da	da	da

Različite funkcije za pojedine mjerene veličine su automatski ponuđene kao moguće za rješavanje oblika razdvojenog prostora (kernela). Na osnovu rezultata testiranja prema podacima koji su korišteni za treniranje odabrana je ona koja je bila sa najmanjom greško i ta je prikazana u tabeli 6.4 kao kernel funkcija odabrana da predstavlja oblika kernela Ulazni podaci za određeni MPV algoritam i njegovo pozicioniranje u prikazanom na slici 6.19, prikazani su na slici 6.20. Podaci se prosljeđuju na dva MPV klasifikacijska podskupa: otočni rad i detekcija kvara na mreži.

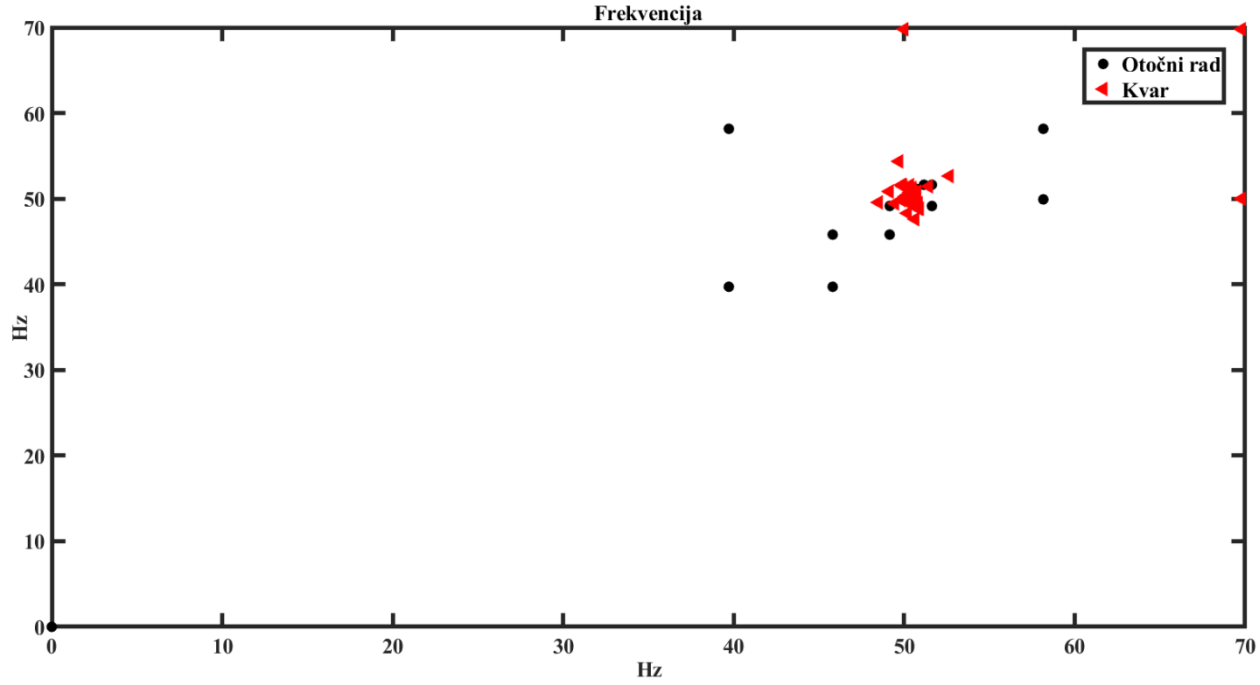


Slika 6.19. Opći algoritam za otkrivanje otočnog rada distribuiranog izvora na temelju otočnih i za kvarove definiranih podloga u MPV .



Slika 6.20. Unošenje podataka u dvije MPV klasifikacijske skupine: otkrivanje otočnog rada i otkrivanje kvarova.

Tijek rada opisan u metodologiji otkrivanja otočnog rada provodi se na različitim skupovima podataka za obuku, koji su izrađeni isključivo za otkrivanje kvarova. Skup podataka se dobiva iz modela ispitivanja opisanog u Poglavlju 6 za 5 situacija kvarova: 1P-T, 2P-T, 2P-P, 3P-T, 3P-P. Potreba za algoritmom klasifikacije kvarova, nastala je zbog nesposobnosti MPV-a da razlikuje događaj otočnog rada od događaja pogreške. Problem s diskriminacijom dolazi s istog ili sličnog otočnog položaja i mjesta kvara u istom odgovarajućem euklidskom prostoru. Kod otočnog rada kao i na događajima s kvarovima šalju se slične scene na slog podataka prikupljenog za trening MPV-a. U nekim slučajevima (mala strujna promjena u mreži) oni su isti skup podataka. Da bi se postigla uspješna razdioba između ta dva skupa podataka, novi MPV klasifikacijski blok se formira samo da bi se prepoznale posebni slučajevi kvarova mreže.



Slika 6.21. Podaci o frekvenciji dobiveni tijekom otočnog rada i kvara u mreži (crveno otočni rad, crno kvar).

Na slici 6.21 je označen crnim okruglim točkama događaj otočnog rada, a sa crvenim trokutastim oznakama kvar. Oba skupa grupiraju se oko 50 Hz, ali se i otočni rad i kvar ponekad razbacuju bez jasnog uzorka da bi ih se razlikovalo s jednim MPV algoritmom.

Nakon postavljanja novih podataka i provedene obuke, MPV algoritmi kvarova prikazani su s parametrima u tablici 6.5 istrenirani prema slici 6.19.

Tablica 6.5. Rezultati treniranja MPV algoritma za detekciju kvara na distribucijskoj mreži-i.

Rezultati treniranja za otkrivanje kvarova							
	Frekvencija	*P*	*Q*	RMS_I	RMS_V	THD_I	THD_V
Kernel funkcija	Linearna	Gausijan	Gausijan	Gausijan	Gausijan	Gausijan	Gausijan
Kernel skala	4,16	0,71	0,71	0,71	0,71	0,71	2,8
Broj promatranja (Promatrano vs Predviđeno: 0:0, 0:1, 1:0, 1:1)	137,1,3,5	175,0,6,0	188, 0,10,0	203,0,9,0	145,0,2,35	207,0,10,0	196,4,5,11
Efikasnost (Promatrano / Predviđeno)	0,88	0,91	0,56	0,99	1,00	0,94	0,95
Analiza glavnih komponenti (95 %)	yes	yes	yes	yes	Yes	yes	yes

Vidljivo je iz tablice 14, različita je funkcija kernela za isti signal i za reaktivnu snagu (Q), ista jezgra s različitom skalom kernela koja čini Gramianovu matricu manjom zbog veće disperzije podataka za treniranje MPV-a. Gramianova matrica (ili matrica skalarnih proizvoda) za uređeni skup vektora (članova vektorskog prostora) koji su skalarni vektorski proizvodi iz danog skupa. Važno je izračunati linearnu neovisnost: skup vektora je linearno neovisan ako i samo ako Gramianova determinanta nije jednaka nuli.

7. ISPITNI MODEL, STANDARDI, MODELI ISPITIVANJA

U prethodnom poglavlju su predstavljene metode umjetne inteligencije, koje su bit detekcije otočnog rada distribuiranih izvora na distribucijskoj mreži. Predstavljeni su detaljno sa aspekta matematskog aparata kojeg koriste u svojem treniranju čvorova, definiranju trenda funkcija pripadnosti, određivanju aktivacijskih slojeva neuronske mreže, te određivanju debljine i oblika površine za diskriminaciju skupova podataka. Trening navedenih metoda je napravljen na temelju podataka koji su izmjereni sa stvarne fotonaponske elektrane, kod koje se u točki spajanja sa distribucijskom mrežom parametri uzimali pomoću uređaja koji je predstavljen u poglavlju 5. Da bi se što bolje razumjela predstavljena metodologija treniranja i na kraju detekcije otočnog rada, bitno je upoznati se sa foto naponskim sustavom sa kojeg su se vrijednosti snimale. Također, u slijedećem pod poglavlju je predstavljen standard koji propisuje pravila mjerenja i testiranja metoda za detekciju otočnog rada, a također je predstavljen model na osnovu kojeg su simulirane pojave pod kojim su se metode testirale: kvarovi na niskonaponskoj mreži, brzo punjenje električnih/hibridnih automobila, te situacija još jedne fotonaponske elektrane na točci zajedničkog spajanja sa distribucijskoj mreži. U slijedećim poglavljima je predstavljen fotonaponski sustav koji je poslužio kao uzorak modelu u softverskom paketu Matlab/Simulink za testiranje metoda.

7.1. Ispitni model niskonaponske distribucijske mreže

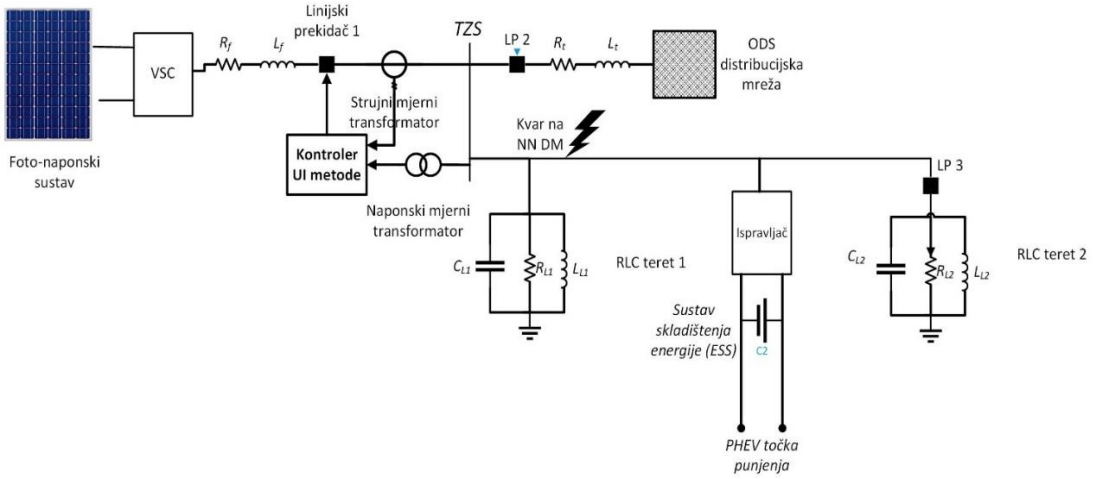
Ovo pod poglavlje predstavlja realni sustav koji se koristio kao model, za uzorkovanje, za algoritme treniranja i za modeliranje u softwaru za potrebe testiranja metoda umjetne inteligencije za detekciju otočnog rada. Poznato je da kada je uzorak dovoljno mali na vremenskoj skali, obrada podataka i provođenje analize su mnogo bliže dostizanju željene preciznosti i praga dopuštene greške. Ti su uzorci temelj za ispravan zaključak o analiziranom pitanju. U ovom istraživanju uzorci se dobivaju elektroničkim uređajem (IED) u ulozi mrežnog analizatora, koji preuzima ulogu uređaja za mjerenje napona i struje. Na slici 26, prikazana je oprema za mjerenje napona i struje na licu mjesta, u točki zajedničkog spajanja (TZS) za foto naponski sustav i distribucijsku mrežu.

Model sustava za potrebe ovog istraživanja, prikazan je na slici 46. Foto naponski sustav je snage 20 kWp i ima vanjsku RLC impedanciju za podešavanje napona i struje prema niskonaponskoj distribucijskoj mreži 0,4 kV mreže, osim RLC opterećenja, postoji i sustav skladištenja energije (ESS) s kapacitetom od 129 Ah. Krovni fiksni foto naponski sustav je izvor konstantne struje s naponom od 300 V DC na ulazu izmjenjivača. foto naponski niz je postavljen na maksimalnu točku snage, sunčevo zračenje 1000 kW/m2 i vanjsku temperaturu panela od 25 ^{o}C . Uloga

distribuiranog izvora se daje foto naponskom nizu 20 kW izlazne snage. DC/AC izmjenjivač je modeliran kao naponski izmjenjivač (VSC) koji koristi IGBT diode, generator pulsne modulacije (PWM), sa 6 impulsa, prikupljajući informacije o referentnom signalu od regulatora frekvencije i amplitude. Niskonaponska distribucijska mreža povezuje se s distribuiranim izvorom u točki zajedničkog spajanja preko linijskog prekidača (LP 1), za scenarij otočnog rada. RLC impedancija je unutarnja za napojenu mrežu kao izvor napajanja. Postoji i prekidač za razdvajanje distribuiranog izvora od distribucijskoj mreže (LP 2) kada je distribuirani izvor u otočnom radu. Mreža je modelirana prema podacima iz tablice 18. i tablice 19. Iz slike 45, energija koju troši opterećenje i mreža je zbroj energije isporučene iz mreže i proizvodnje distribuiranog izvora (5), gdje su P_{load} i jQ_{load} aktivna i jalova snaga koju troši RLC opterećenje u sinkronom rada distribuiranog izvora i mreže.

$$P_teret + jQ_teret + P_punjenje + jQ_punjenje = \left(P_PV + jQ_PV\right) + \left(\Delta P + j\Delta Q\right) \tag{7-1}$$

$P_{punjenje}$ i $jQ_{punjenje}$ su snaga punjenja mreže tijekom scenarija punjenja. P_{FN} i jQ_{FN} predstavljaju proizvedenu snagu iz foto naponskog sustava iz DC/AC izmjenjivača, a $\Delta P + j\Delta Q$ su aktivna i reaktivna energija koju isporučuje distribucijska mreža RLC teretu. Važno je spomenuti da $P_{punjenje}$ i $jQ_{punjenje}$ imaju različite vrijednosti u dva scenarija: punjenje mreže i brzo punjenje PHEV. Razlika je velika u vrijednosti $P_{punjenja}$ u slučaju brzog punjenja PHEV. Razlog tome je mala impedancija baterija samog električnog vozila. Kada se električno vozilo spoji na mrežu zbog brzog punjenja, dolazi do velikog protoka snage prema baterijama vozila. Više o tome u pod poglavlju o punjenju PHEV vozila.



Slika 7.1. Kreirani model u alatu koji predstavlja realnu mrežu koja je uzorkovana uz pomoć IED mjernog uređaja, te služi kao poligon za testiranje umjetne inteligencije metoda detekcije otočnog rada.

Foto naponski sustav nalazi se na krovu kuće i spojen je na Smart Meter i zaštitne osigurače, preko 1 kV izoliranog kabela PPOO-A NYY 4x16 mm. Ormarić u kojem se nalaze mjerna i zaštitna oprema je na betonskom stupu u blizini spomenute kuće. Odatle je elektrana ponovno spojena na distribucijsku mrežu sa 1 kV izoliranim kabelom tipa PPOO-A NYY 4x16 mm. Na slici 46, prikazani su paneli na krovu, izmjenjivač i DC ormarić, te AC ormarić. Instalirana snaga je 23,8 kWp u panelima i izmjenjivačima su Frontius-Symo 10,0-3-M, s maksimalnom izlaznom snagom od 10 kW. Navedeni podaci su prikazani u tablici 15.

Tablica 7.1. Parametri foto naponskih sustava koji je modeliran u Matlab alatu za testiranje metoda.

SPECIFIKACIJA FN SUSTAVA	
Snaga distribuiranog izvora	22,5 kW
Ulazni napon u DC izmjenjivač	300-310 V
Napon u točki zajedničkog spajanja-a (L-L)	390-400 V
Nominalna frekvencija	50 Hz
Otpor distribucijskoj mreži-e	0,89 Ohm
Impedancija distribucijske mreže	0,016 H
Impedancija distribuiranog izvora	0,01 H
Kapacitet distribuiranog izvora	12 kF

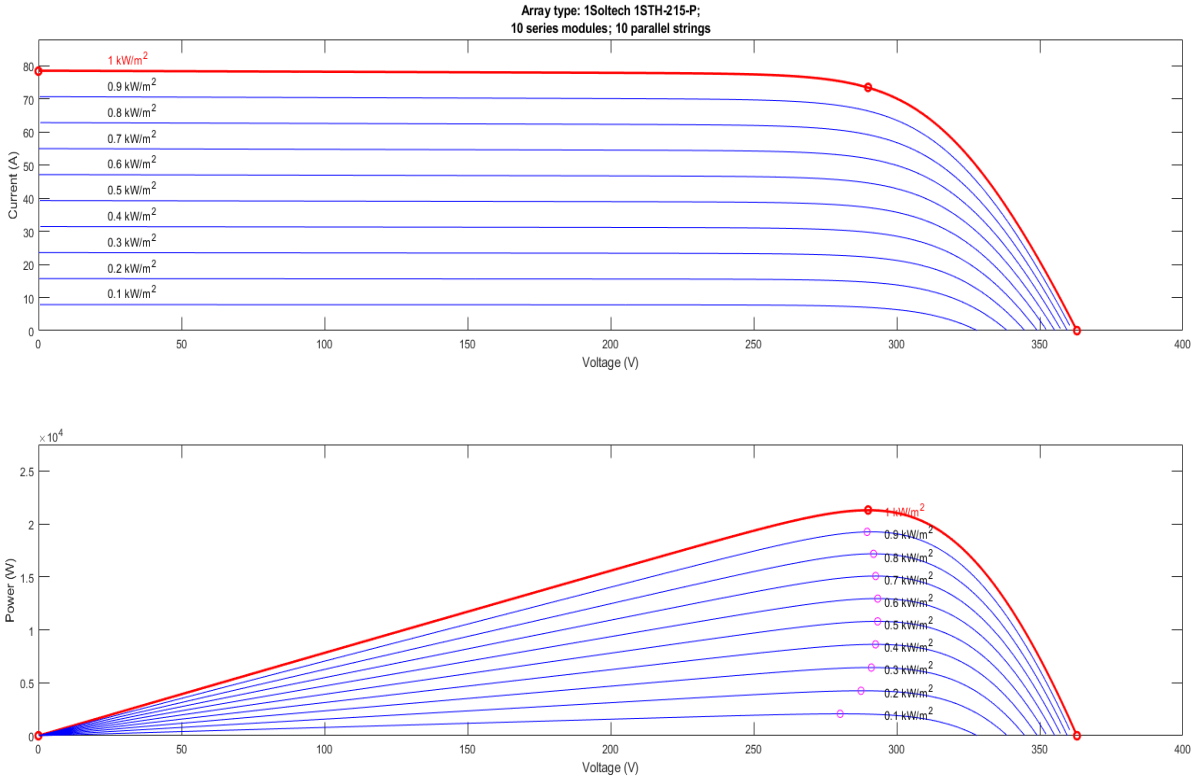


Slika 7.2. foto naponsko postrojenje i priključak na distribucijskoj mreži. Gore lijevo: AC ormar na stupu s mjernom i zaštitnom opremom. Gore desno: DC ormarić i izmjenjivači 2x10 kW. Dolje: foto naponski paneli na krovu snage 23,8 kWp.

Foto naponski paneli su tipa 1 Soltech 1STH-215-P sa specifikacijama danim u tablici 7.2 i MPPT karakteristikama prikazanim na Slici 7.3.

Tablica 7.2. Tehnička specifikacija foto naponskih panela koji su instalirani na foto naponska elektrana koja je modelirana i mjerena.

SPECIFIKACIJE SOLARNIH PANELA	
FN Model	1Soltech STH-215-P
Standardni testni uvjeti	1000 W/m2, 25 C
Maksimalni napon	29,0 V
Maksimalna struja	7,35 A
Maksimalna snaga	213,15 W
Broj ćelija u seriji	60
Struja kratkog spoja	7,84 A
Napon otvorenog kruga	36,3 V



Slika 7.3. Specifikacija P-V i I-V-a na foto naponskom panelu koristi se kao različiti uvjeti testiranja u simulaciji

7.2. Ul 1741 i IEEE 1547 Standardi

Proučavanje metoda detekcije otočnog rada uzimajući kao objekt distribuirani izvor u dijelu distribuirane mreže, poznato je pod različitim imenima: otkrivanje otočnog rada, otočni rad i nenamjerni otočni rad. Sva ta imena odnose se na događaje u kojima operateri distribuiranog izvora ne kontroliraju nastajanje otočnog rada gdje se fizički ostavlja distribuirani izvor u pogonu sa dijelom distribucijske mreže bez napajanja iz mreže. Događaj je nametnut neželjenim pojavama u distributivnoj mreži. Na primjer, veliki propadi napona i/ili frekvencije mogu prisiliti dio mreže na otočni rad. Drugi slučaj nenamjernog (prisilnog) otočnog rada je kontrolirani otočni rad, poznat i kao namjerni (ne prisilni) otočni rad ali on nije tema ove disertacije. Primjerice, mikro mreže se mogu isključiti iz mreže kad god se to želi naravno uz prethodno dogovorene standarde i procedure od strane operatera distribucijskog sustava, neovisno o električnim smetnjama. Četiri gore navedena imena su ista grupa imena vezano za zaštitu od otočnog rada koji je nametnut distribuiranom izvoru, a njime ne kontrolira operater distribucijskog sustava. Ti nazivi imaju dvije komponente. Prvo, uključuju metodu otkrivanja otočnog rada, koja koristi neku kombinaciju metoda koje jasno pokazuju da se otočni rad pojavio ili nije. Drugo, oni uključuju akciju isključenja koja rezultira odvajanjem distribuiranog izvora od lokalnog električne mreže (ODS) kako to zahtijeva IEEE 1547.

Ova dvije komponente su potrebne zajedno kako bi se ispunili svi zahtjevi zaštite od otočnog rada. Povijesno gledano, problematika otočnog rada distribuiranog izvora ima korijene u istraživanju foto naponskih izmjenjivača. Brojni izvještaji iz literature pokazuju napore istraživača koji imaju za cilj poticanje razvoja solarne industrije i uključuju istraživanje otočnog rada. U [118], otkrivanju otočnog rada je glavni cilj, prikazati i lokalne i komunikacijske, kao i pasivne i aktivne metode. Kao što je opisano u izvješću, provedeno je istraživanje, grupiranje i kategorizacija metoda detekcije otočnog rada, kako bi se industriji solarnih elektrana pomoglo u detekciji otočnog rada. IEEE 1547 standard, do sada, logičan je nastavak tih istraživanja s povezivanjem distribuiranih izvora na mrežu, koji su se prvi put pojavili u industriji solarnih foto naponskih izmjenjivača. IEEE 1547 je relativno novi standard, koji se još uvijek razvija do potpunog izdavanja kao standardiziranog skupa pravila.

Tablica 7.3. Popis svih IEEE 1547 standarda koji su objavljeni i koji se obrađuju

IEEE Standard br.	Ime standarda	Objavljen/ Obrađuje se	Godina	Datum objavljivanja
1547	IEEE standard za spajanje distribuiranih izvora energije sa energetskim sustavom distribucije	Objavljen	2003	28.7.2003
1547.1	IEEE standardne procedure ispitivanja sukladnosti za opremu koja povezuje distribuirane resurse s elektroenergetskim sustavima	Objavljen	2005	1.6.2005
1547.2	IEEE standard za povezivanje distribuiranih resursa s elektroenergetskim sustavima	Objavljen	2008	15.04.2009
1547.3	IEEE Vodič za praćenje, razmjenu informacija i kontrolu distribuiranih resursa povezanih s elektroenergetskim sustavima	Objavljen	2007	16.11.2007
1547.4	Nacrt vodiča za projektiranje, rad i integraciju distribuiranih sustava otočnih sustava s elektroenergetskim sustavima	Obrađuje se	-	-
1547.5	Nacrt tehničkih smjernica za međusobno povezivanje elektroenergetskih izvora veće od 10 MVA do prijenosne mreže	Obrađuje se	-	-
1547.6	Nacrt preporučene prakse za međusobno povezivanje distribuiranih resursa s distribucijskim mrežama za distribuciju električne energije	Obrađuje se	-	-
1547.7	Nacrt vodiča za provođenje studija utjecaja na distribuciju za Inter konekciju distribuiranih resursa	Obrađuje se	-	-
1547.8	Preporučena praksa za uspostavljanje metoda i postupaka koji pružaju dodatnu podršku za primjenu strategije za proširenu upotrebu standarda IEEE 1547	Obrađuje se	-	-

Rasprave o ovom standardu započele su na prijelazu tisućljeća, a broj objavljenih dijelova standarda proizveden je s više dodataka i izmjena. U tablici 7.3 dan je sveobuhvatan pregled standarda IEEE 1547. Do sada su objavljena četiri odjeljka standarda:

1) pregledni odjeljak 1547,

2) testni postupci, odjeljak 1547.1,

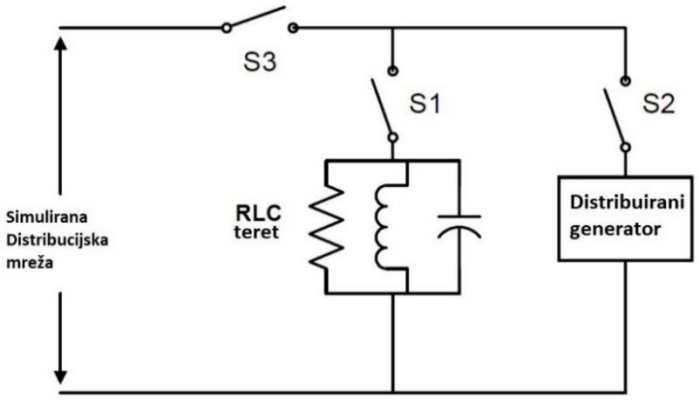
3) odjeljak o interkonekciji 1547.2, i

4) dio za nadzor, razmjenu informacija i kontrolu 1547.3.

Prva dva izvješća 1547 i 1547.1, objavljena su prije donošenja Zakona o energetskoj politici iz 2005. (EPAct05). Zatim, EPAct05 je ustanovio IEEE 1547, prema Odjeljku 1254 ovog saveznog zakona, kao nacionalni standard [6]. Sukladnost s IEEE 1547 je potrebna za sve slučajeve interkonekcije distribuiranog izvora u SAD-u. IEEE 1547 standard objavljen je 2003. godine, predstavlja otvorenu tablicu za sljedeće odjeljke i daje detalje o prirodi međusobnog povezivanja distribuiranog izvora, uključujući informacije za otkrivanje otočnog rada. U standardu je navedeno vrijeme za koje se distribuirani izvori mora isključiti sa distribucijskoj mreže u slučaju otočnog rada. Vrijeme isključenja je vrijeme koje je dopušteno distribuiranom izvoru da bude povezan s lokalnom mrežom bez isključenja. Ako je distribuirani izvor isključen jednako ili kraće od ovog vremena, to će biti u skladu s IEEE 1547 standardom, inače, nije u skladu s istim. U tablici 1 prikazane su informacije o vremenu isključenja distribuiranog izvora tijekom otočnog rada, a iznosi 2 sekunde. Sve metode detekcije otočnog rada moraju biti u skladu sa ovim vremenom. Ove granice napona, frekvencije i harmonika sada su nacionalni standard. Izrada tih standarda bila je važna, jer su za sve u SAD-u bila postavljena jedinstvena pravila. No, sve dok se ne objavi P1547.4, jedinstvene nacionalne norme neće biti dostupne za mikro mreže. Metode otkrivanja otočnog rada bile su u razvoju prije nego što je standard IEEE 1547 objavljen 2003. godine, i nastavljaju se razvijati do danas. Postoje brojne metode otkrivanja otočnog rada, od jednostavnih do složenih. Iscrpan popis osnovnih metode otkrivanja otočnog rada, prikazan je u poglavlju 3. Tijekom pregleda literature, pronađeno je takvih 35 metoda.

IEEE 1547 također dokumentira standardni postupak testiranja distribuiranih izvora, u čemu se poklapa sa standardom UL 1741. Ovaj standard završen je 2005. godine objavljivanjem 1547.1 dijela. Ispitivanje metode otočnog rada uključeno je u ovaj odjeljak standarda pod nenamjernim otočnim radom u dijelu 5.7.1. Ispitna metoda koristi strujni krug prikazan na slici 2.2 prema

referencama [181][182]. Jednadžbe za izračunavanje RLC opterećenja prikazane su ispod slike 7.4. Prekidači su označeni sa S1, S2 i S3.



Slika 7.4. Primjer modela otkrivanja otočnog rada za provjeru prikladne metode, gdje je Q_f faktor kvalitete, a napon i snaga su fazne veličine (poznate i kao nenamjerna konfiguracija testiranja otočnog rada) [181].

$$R = \frac{V2}{P} \tag{7-2}$$

$$L = \frac{V2}{(2\pi f)PQ_f} \tag{7-3}$$

$$C = \frac{PQ_f}{(2\pi f)V2} \tag{7-4}$$

Ovaj strujni krug koristi se za pronalaženje vremena isklopa distribuiranog izvora od lokalne mreže. Ovo vrijeme se zatim uspoređuje sa standardnim vremenima detekcije, postavljenim u IEEE 1547 kao mjera sukladnosti. Testiranje se radi tako što se S1 otvara, oponaša grešku mreže ili ometanje. Vrijeme detekcije je vrijeme potrebno da metoda detekcije otočnog rada otvori S2, odvajajući distribuirani izvor od lokalne mreže. Ako je to vrijeme detekcije jednako ili manje od vremena detekcije propisanog u IEEE 1547, tada je distribuiranog izvora sukladan standardu. Ovaj strujni krug je standard za sva ispitivanja sukladnosti metoda otkrivana otočnog rada. Tri jednadžbe navedene ispod slike 7.4 definiraju RLC krug ako je poznat faktor kvalitete mreže Q_f, a navedeni RLC krug predstavlja lokalnu potrošnju u distribucijskoj mreži. Te jednadžbe nisu važne samo zato što definiraju paralelni RLC sustav, već su također važne što eksplicitno uključuju definirajući parametar, "P". Ova "P" je predana radna snaga distribuiranog izvora. Otkrivanje otočnog rada uključen je kao obavezni dio u nepotpun ali stalno nadograđivan standard IEEE 1547. Postoje zajedničke metode ispitivanja i sklopovi za uspoređivanje metoda detekcije sa

standardima. Konačno, metode imaju povezane grafičke alate projektirane za razumijevanje prednosti i slabosti svake od metoda. Ovaj alat za testiranje otkrivanja otočnog rada, koji je sada dostupan, nije dovoljan pa je potreban sljedeći tehnološki iskorak. Ovaj iskorak uključuje proširivanje otkrivanja otočnog rada i njegove metode na sustave koji su složeniji od jednog distribuiranog izvora na mreži. Metode detekcije se sada moraju koristiti na području mikro mreža i to na niskonaponskoj strani, gdje postoje više distribuiranih izvora i opterećenja u istoj mreži, djelujući kao jedna cjelina. Ovo proširenje je u tijeku definiranja, kao što pokazuje opis nacrta IEEE P1547.4 („mikro mreža“ ili standard otočnog rada). Metode detekcije su vrlo uspješne za lokalne aplikacije sa sustavima sastavljenim od izmjenjivača, ili za udaljene izvore (vjetroelektrane) kao što je slučaj u prijenosnim sustavima. Područje niskonaponske mikro mreže u kojoj se nalazi distribuirani izvor je noviji izazov i stoga manje razumljiv, kao i manje testiran u literaturi.

U standardu UL1741 izmjenjivači, i oprema interkonekcijskog sustava za uporabu s distribuiranim izvorima, navedeno je da za opremu s međusobno povezanim dodatcima UL 1741, treba se koristiti zajedno s IEEE Std 1547 i IEEE Std 1547.1.

Testiranje predloženih metoda umjetne inteligencije za detekciju otočnog rada, provedi se prema izrazima (17), (18) i (19) a u sklopu standarda za zaštitu od otočnog rada UL1741. Opterećenje aktivne snage se mijenja u opsegu ispitivanja prema snazi distribuiranog izvora i to kao 25%, 50%, 100% i 125%, nominalne snage. Reaktivna snaga podešava se u rasponu od -5 do +5% nazivne snage u koracima od 1% za potrebe testiranja. Testiranjem predložene metode pod ovim uvjetima za sustav prikazan na slici 48, izvedeno ja za pet ispitnih slučajeva:

- Scenarij 1: aktivno opterećenje 100% proizvedene snage, reaktivno opterećenje 0%, faktor snage 1.
- Scenarij 2: aktivno opterećenje 50% proizvedene snage, reaktivno opterećenje 0%, faktor snage 1.
- Scenarij 3: aktivno opterećenje 125% proizvedene snage, reaktivno opterećenje 0%, faktor snage 1.
- Scenarij 4: aktivno opterećenje 100% proizvedene snage, reaktivno opterećenje je -1%.
- Scenarij 5: aktivno opterećenje 50% proizvedene snage, reaktivno opterećenje 1%.
- RLC opterećenje prema prikazanim slučajevima, nalazi se u tablici 18 sukladno navedenim slučajevima kreiranim u skladu sa UL1741.

Tablica 7.4. Konfiguracija aktivne i reaktivne snage mreže za testiranje metoda.

Scenarij	P [%]	Q [%]	R [Ohm]	L [H]	C [F]
1	100%	100%	0,011561	0,00345	0,002037
2	50%	100%	0,023121	0,00345	0,002037
3	125%	100%	0,009249	0,00345	0,002037
4	100%	99%	0,011561	0,003488	0,002037
5	100%	101%	0,011561	0,003419	0,002037

Ispitni uvjeti za različite vrijednosti faktora kvalitete (Q_f), uzeti su prema UL1741. RLC opterećenje za različite vrijednosti Q_f nalazi se u tablici 7.5.

Tablica 7.5. Vrijednosti Q_f za različite slučajeve kvalitete distribucijskoj mreži za koje su testirane metode detekcije otočnog

Scenarij	Q	R [Ohm]	L [H]	C [F]
1	1,002852	2,304	0,00607	0,00115
2	2,008407	2,304	0,00304	0,00231
3	2,503132	2,304	0,00244	0,00288
4	3,007963	2,304	0,00203	0,00346
5	4,012464	2,304	0,00152	0,00461
6	5,001917	2,304	0,00122	0,00575

Prikazani ispitni uvjeti za različite RLC vrijednosti izrađuju se u tri različita uvjeta opterećenja u odnosu na generiranu snagu: 2%, 100% i 200% nominalne snage generacije.

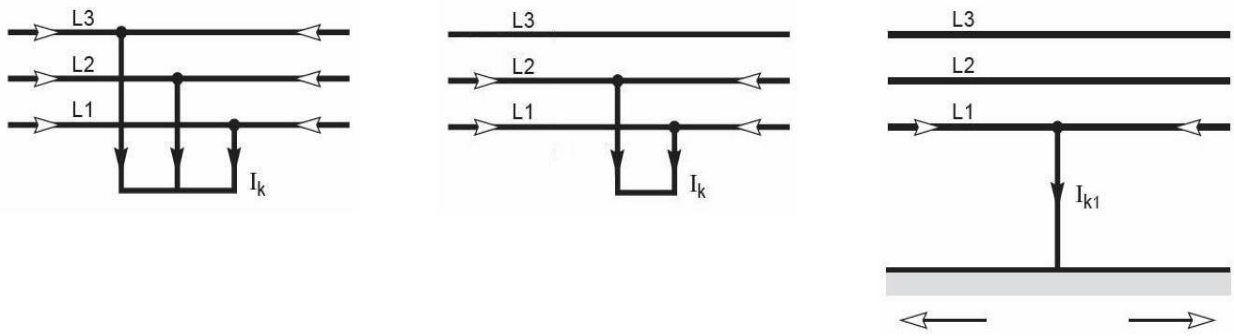
7.3. Modeliranje kvarova na mreži

Nakon testiranja metoda prema navedenim standardima, metode su testirane pod uvjetima kvarova na distribucijskoj mreži. Kvarovi koji su uključeni u testiranje su:

1) trofazni kratki spoj,
2) dvofazni kratki spoj,
3) monofazni spoj sa zemljom.

Na slici 5.4a je prikazano ponašanje niskonaponske distribucijskoj mreži, kada se desi trofazni kratki spoj, kako je prikazano na slici 45.

Na slici 7.5 su simbolično prikazani sva tri slučaja kvara na mreži koji su obrađeni kroz detekciju otočnog rada u ovoj disertaciji.

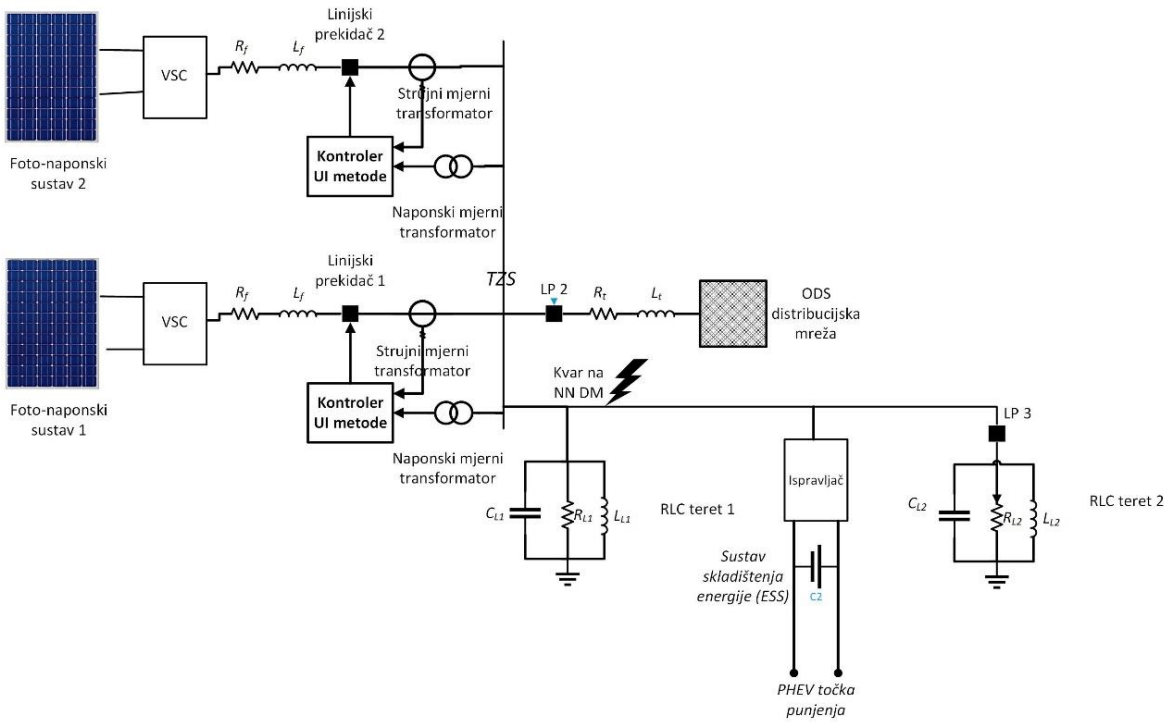


a) b) c)

Slika 7.5. Simbolički prikaz kvarova pod čijim su scenarijima testirane metode umjetne inteligencije, za detekciju otočnog rada distribuiranog izvora: a) trofazni kratki spoj, b) dvofazni kratki spoj, c) jednofazni kratki spoj sa zemljom.

7.4. Paralelni rad sa drugim distribuiranim izvorima energije

Slučaj višestrukih distribuiranih izvora u jednom točki zajedničkog spajanja je standardni test za metode otkrivanja otočnog rada. Osnovna shema jednog spoja za ovaj test, prikazana je na slici 7.6.



Slika 7.6. Standardna shema testnog scenarija sa još jednim distribuiranog izvora koji je priključen na istu točki zajedničkog spajanja sa distribucijskoj mreži-om.

U konkretnom slučaju je uzet identičan distribuirani izvor sa istom instaliranom snagom kao i originalni distribuirani izvor sa karakteristikama prikazanima u pod poglavlju 7.1., gdje je opisan jedan foto naponski sustav.

8. REZULTATI TESTIRANJA

U prethodnim poglavljima opisani su predloženi algoritmi metoda umjetne inteligencije, koji se koriste za detekciju otočnog rada distribuiranog izvora na mreži, uzimajući u obzir preciznost metode, zone ne detekcije, brzinu i sigurnost detekcije. Testiranje navedenih metoda se može promatrati sa tri aspekta: vrijeme detekcije otočnog rada distribuiranog izvora, veličina zone ne detekcije i preciznost same metode. U testiranju navedenih metoda su uključena sva tri slučaja za svaku metodu posebno, te su na kraju ovog poglavlja predstavljeni usporedni rezultati.

Testiranje metoda je urađeno tako da je u vremenskom periodu od 1 sekunde, gdje je u trenutku 0,2 ili 0,4 ms iniciran prekidač za odvajanje mreže i time je distribuirani izvor ostavljen da radi u otočnom radu, a isti je primijenjen na realni sustav snage 20 kWp. Svih sedam signala se mjeri u realnom vremenu, te se ti podaci pakiraju da budu ulaz u metode umjetne inteligencije. Na kraju se dobiva izlaz iz svake od metoda kao rezultat o pojavi u mreži, tj. Je li nastupio otočni rad ili nije. Isti način testiranja se radi ostalim navedenim slučajevima, gdje se u trenutcima 0,1, 0,2 ili 0,4 s, inicira otočni rad u distribucijskoj mreži i predložene metoda daju svoj konačni izlaz o otočnom radu.

Testiranje vremena detekcije se mjeri kao proteklo vrijeme od djelovanja linijskog prekidača između distribuiranog izvora i ostatka mreže, pa do odziva metode detekcije o pojavi otočnog rada. Vremenski rezultati su predstavljeni slikama i u tablicama uz rezultate testiranja.

Testiranje preciznosti se mjeri tako da se signalizacija detekcije otočnog rada metode kada se desi i time reagira na odvajanje distribuiranog izvora od ostatka mreže. Uvid u preciznost je u stvari jasan odgovor predložene metode dali uopće prepoznaje otočni rad kada se desi i da ne reagira pogrešno kada se ne desi, a dogodi se neka druga promjena u mreži. Također se rezultati mogu vidjeti preko slika koje zorno prikazuju odziv metoda.

Zone ne detekcije se testiraju na 2D površini definiranoj sa proizvedenom snagom iz distribuiranog izvora i naponom mreže, tj. *P i* RMS_V prema tablici 8.1. Korak kretanja po P-V površini je 5% za proizvedenu snagu, a 1% za mrežni napon.

Tablica 8.1. Testiranje zone ne detekcije se radi na 2D površini definiranoj sa *P i RMSV.*

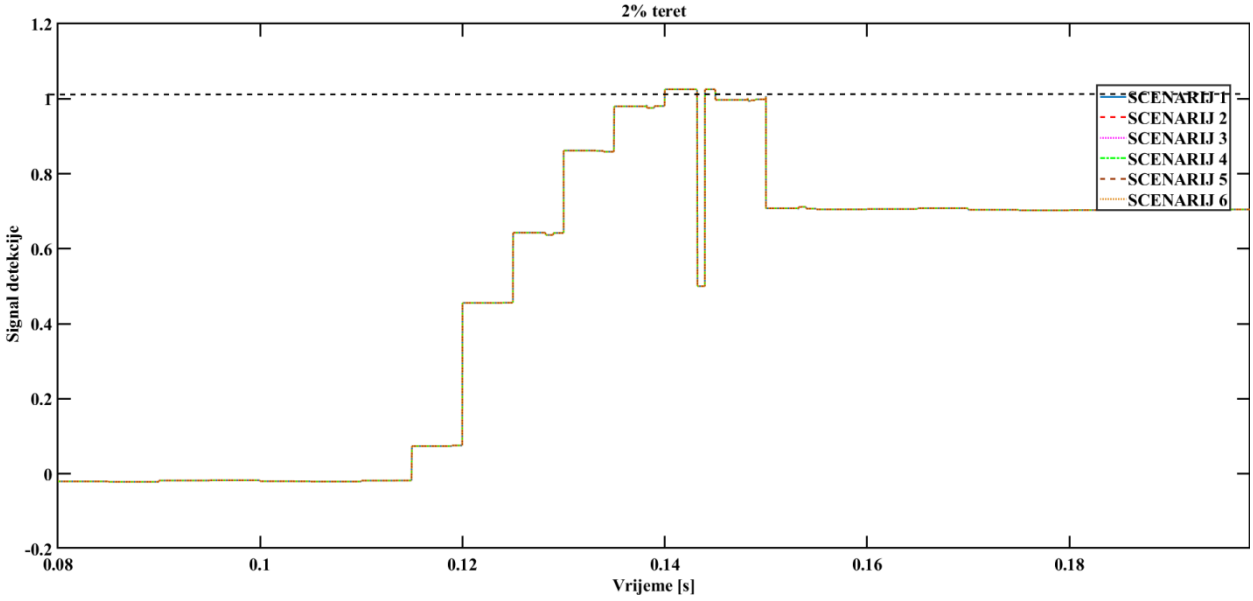
	Maksimum	**Minimum**	**Korak**
Proizvedene snaga [kW]	23	0	5%
Mrežni napon [kV]	0,437	0,358	1%

Rezultati simulacije se u nastavku prikazuju kao pojedinačni izlaz iz pojedine metode, vezano za određeni test. Prikaz je izveden u 2D dimenziji, u kojoj su na apscisi vremenski intervali u skali od nekoliko milisekundi, zavisno od metoda detekcije. Na ordinati je smještena vrijednost signala iz metode koja određuje da li metoda prepoznaje otočni rad ili ne u zadanim testnim uvjetima. Na kraju poglavlja će biti prikazana usporedba svih predloženih metoda sa svojim rezultatima testiranja. Slijedi i diskusija o dobivenim rezultatima testiranja, gdje će se autor osvrnuti na rezultate testiranja iz perspektive inženjera koji prikuplja podatke, trenira metode, testira ih i implementira.

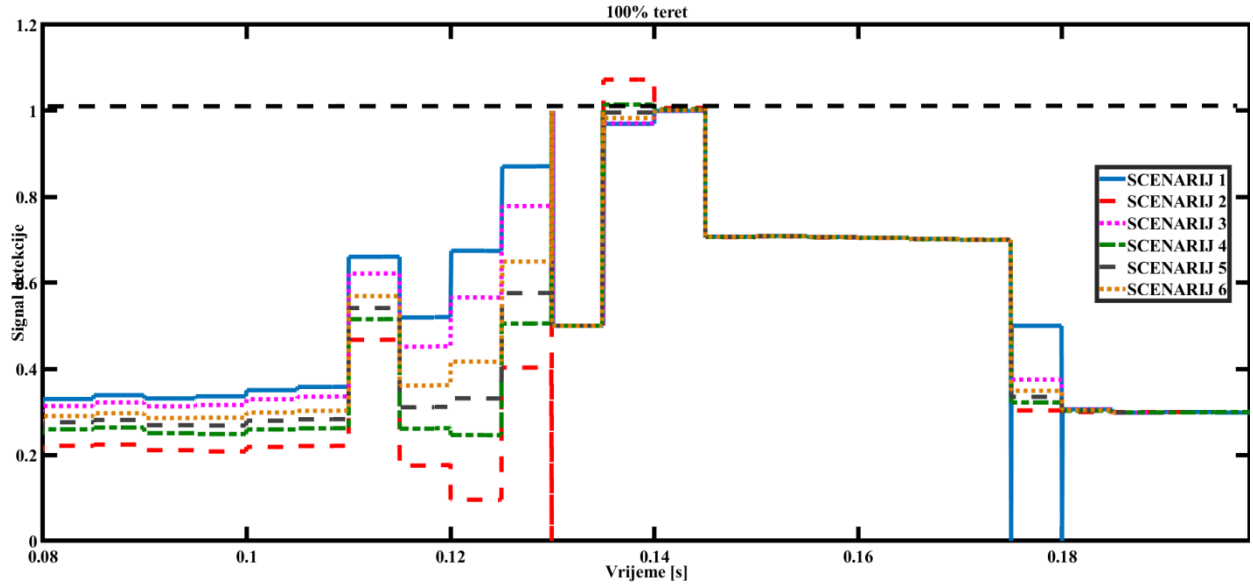
8.1. Sustav prilagodljivog neizravnog neuronskog zaključivanja (ANFIS)

Model sustava sa kojim se testira ANFIS metoda prikazan je na slici 7.1. i uključuje jedan distribuirani izvori u distribucijskoj mreži, te sa parametri mreže iz Tablica 15 i 16. Vrijednosti RLC kruga podliježu posebnim uvjetima ispitivanja navedenih u standardu IEEE 1547 / UL 1741, čiji su parametri za testiranu mrežu dani u Tablicama 18 i 19. Unutar mikro mreže sustava, postoje tri LP (linijska prekidača): jedan LP za iniciranje otočnih uvjeta, drugi za odvajanje distribuiranog izvora od mreže i treći prekidač za dodatno ubacivanje RLC opterećenja, simulirajući uklop dodatnog tereta na mikro mrežu. U svim testovima, otočni i drugi scenariji odvijaju se u trenutku 0,1 sekunde od početka simulacije. Da bi se potvrdilo postoji li otočni rad, signal mora zadržati vrijednost oko $0,9 \leq \text{SIGNAL} \leq 1,1$ najmanje 0,005 sekundi, kao signal za djelovanje na LP za odvajanje distribuiranog izvora od mikro mreže i time prestaje otočni rad sustava.

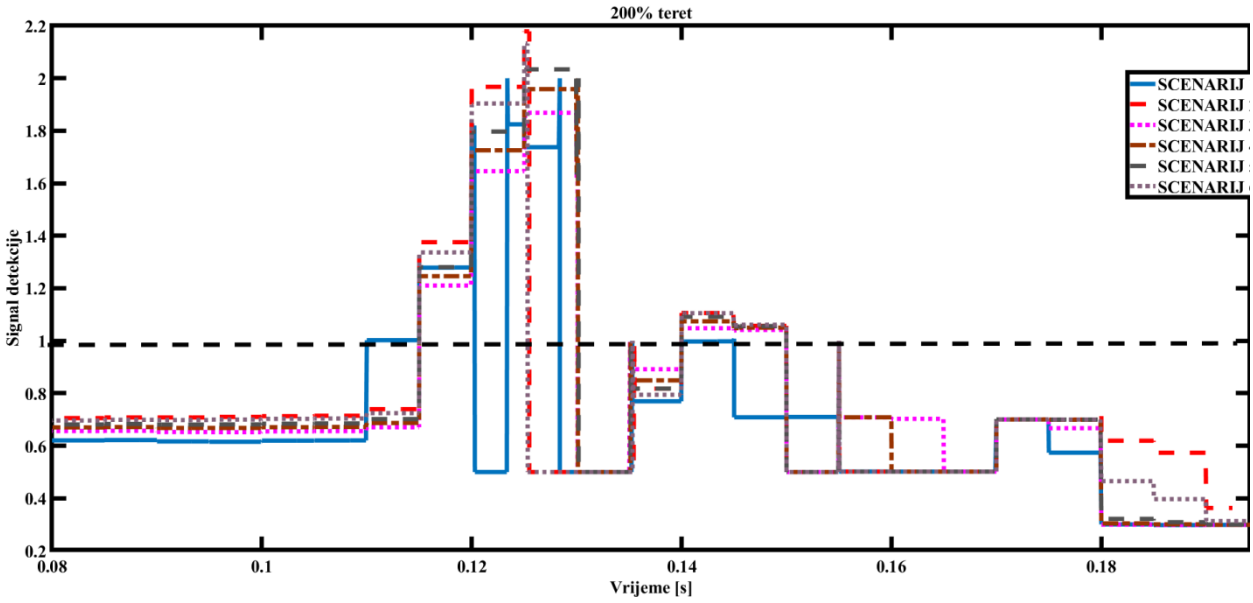
Prvi test koji je proveden jeste po parametrima UL 1741 standardu za rad izmjenjivača. Rezultati su prikazani na slici 52, 53 i 54 i tablici 22. Za svaki testni slučaj je urađeno mijenjanje parametara mreže po tablici 19. kako bi se uključila promjena 6 slučajeva kvalitete mreže Q_f. Za svaki od njih je izračunat izlaz iz ANFIS metoda.



Slika 8.1. Rezultati testiranja ANFIS metode detekcije otočnog rada prema različitim vrijednostima kvalitete mreže Q_f, pri 2% tereta mreže u odnosu na generiranu energiju sa distribuiranog izvora.



Slika 8.2. Rezultati testiranja ANFIS metode detekcije otočnog rada prema različitim vrijednostima kvalitete mreže Q_f, pri 100% tereta mreže u odnosu na generiranu energiju sa distribuiranog izvora.



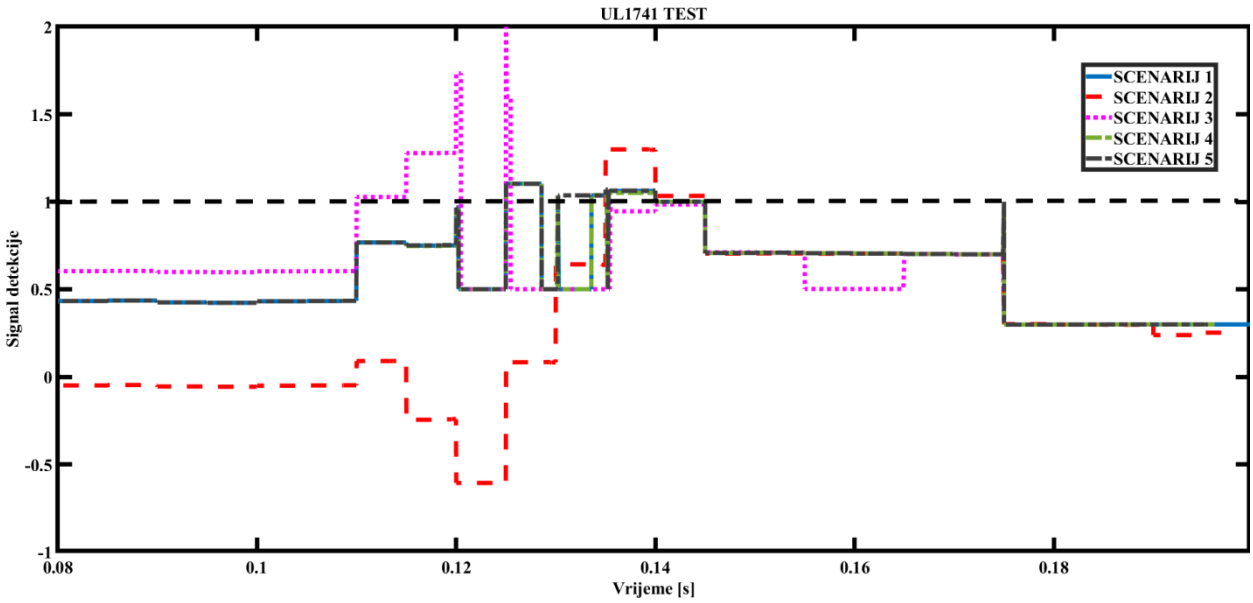
Slika 8.3. Rezultati testiranja ANFIS metode detekcije otočnog rada prema različitim vrijednostima kvalitete mreže Q_f, pri 200% tereta mreže u odnosu na generiranu energiju sa distribuiranog izvora.

Tablica 8.2. Rezultati testiranja ANFIS metode pod uvjetima propisanima standardom UL1741 za svih 6 kvaliteta distribucijskoj mreži-a.

Scenarij	Vrijeme [s]	Vrijeme [s]	Vrijeme [s]
	2% generacije	100% generacije	200% generacije
1	0,040	0,040	0,015
2	0,040	0,040	0,040
3	0,040	0,040	0,040
4	0,040	0,040	0,040
5	0,040	0,040	0,040
6	0,040	0,040	0,040

Rezultati prikazuju distribuirani izvor pri opterećenju koje je skaliran prema nominalnoj proizvedenoj snazi FN sustava od samo 2% potrošene proizveden snage pa sve do tereta koji je i do 200% proizvedene snage. Sva tri navedena slučaja su testirana kroz 6 scenarija za različite vrijednosti faktora kvalitete mreže Q_f.

Slijedeći test je pod uvjetima propisanim standardom UL1741 za svaki od 5 scenarija navedenih u pod poglavlju 7.2., gdje se opisuje standard UL1741 i IEEE1547. Rezultati su prikazani na slici 8.4 i tablici 8.5.

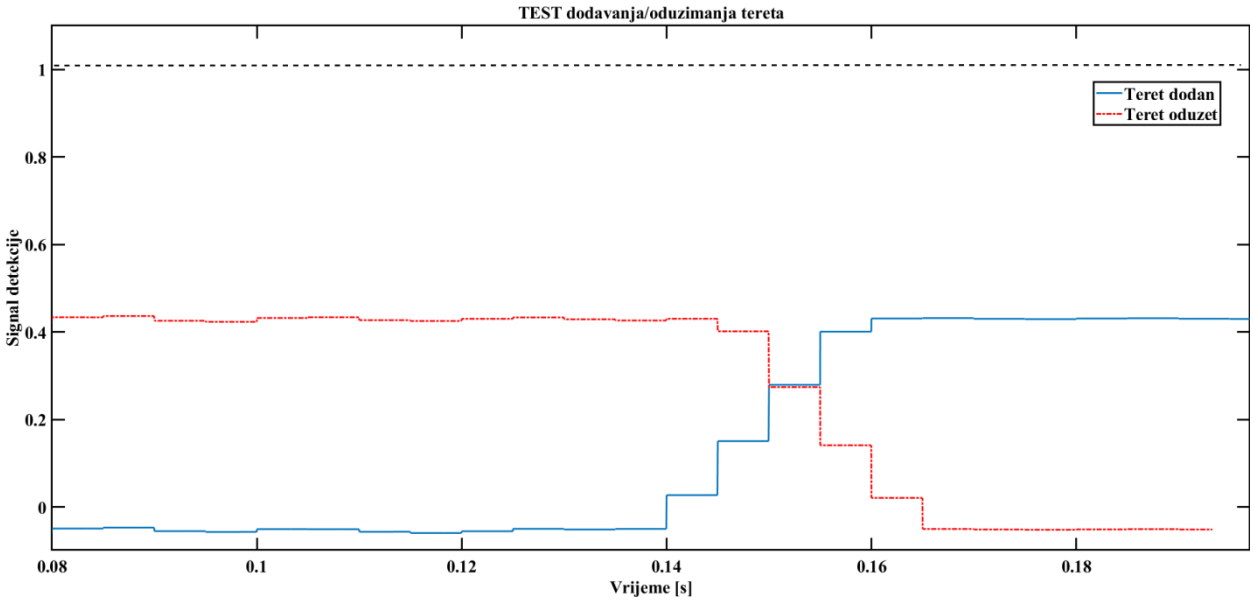


Slika 8.4. Rezultati testiranja ANFIS metode po standardu UL1741 za jednu foto naponsku elektranu na mikro mreži. Jasno se vidi u vremenu 0,14 sekundi da se svi signali sastave u točku blizu vrijednosti 1 što predstavlja uspješno detektiran otočni rad.

Tablica 8.3. Rezultati testiranja brzine ANFIS metode po standardu UL1741. Rezultati prikazuju da je metoda ANFIS veoma brza u svih 5 slučajeva.

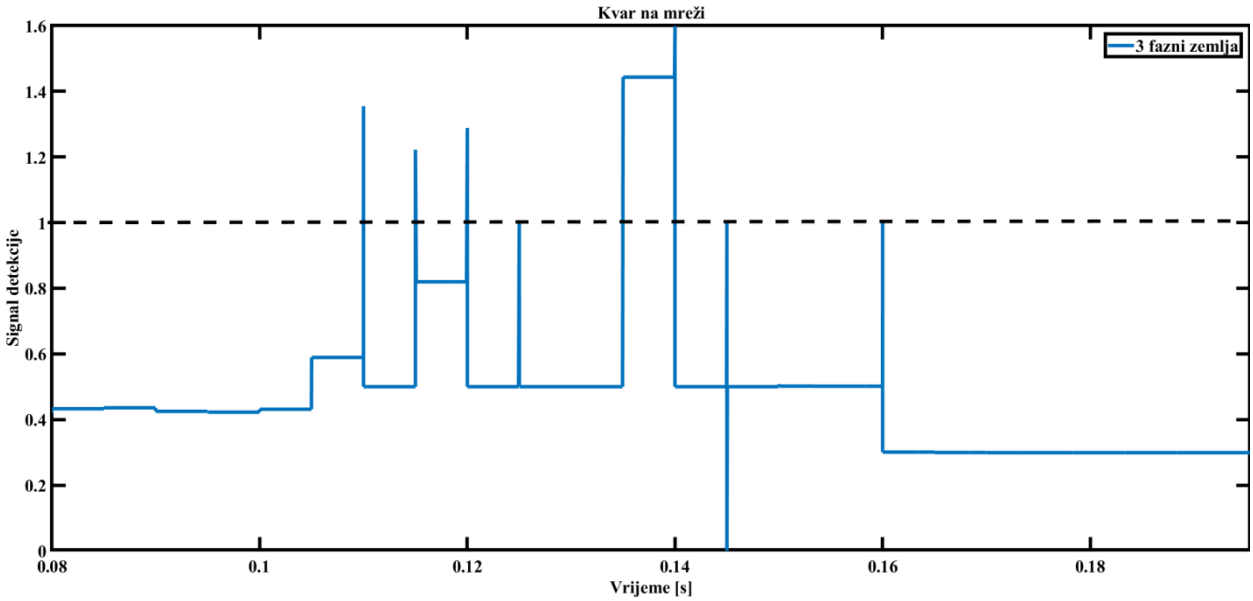
Scenarij	Vrijeme [s]
1	0,040
2	0,045
3	0,040
4	0,040
5	0,040

Rezultati testiranja kada se dodatni teret ubaci, te se izbaci iz mikro mreže je prikazan na slici 8.5.

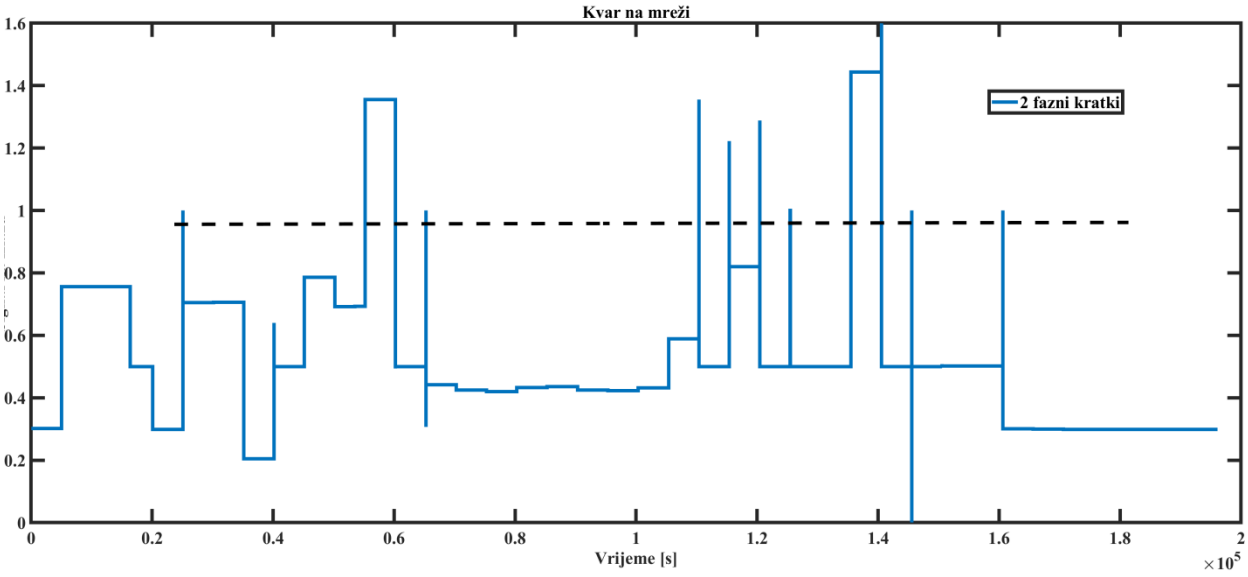


Slika 8.5. Rezultati testiranja ulaska i izlaska dodatnog tereta u mikro mrežu. Nijedna krivulja ne dodiruje zadani prag i time se ne prepoznaje ubacivanje dodatnog tereta kao otočni rad.

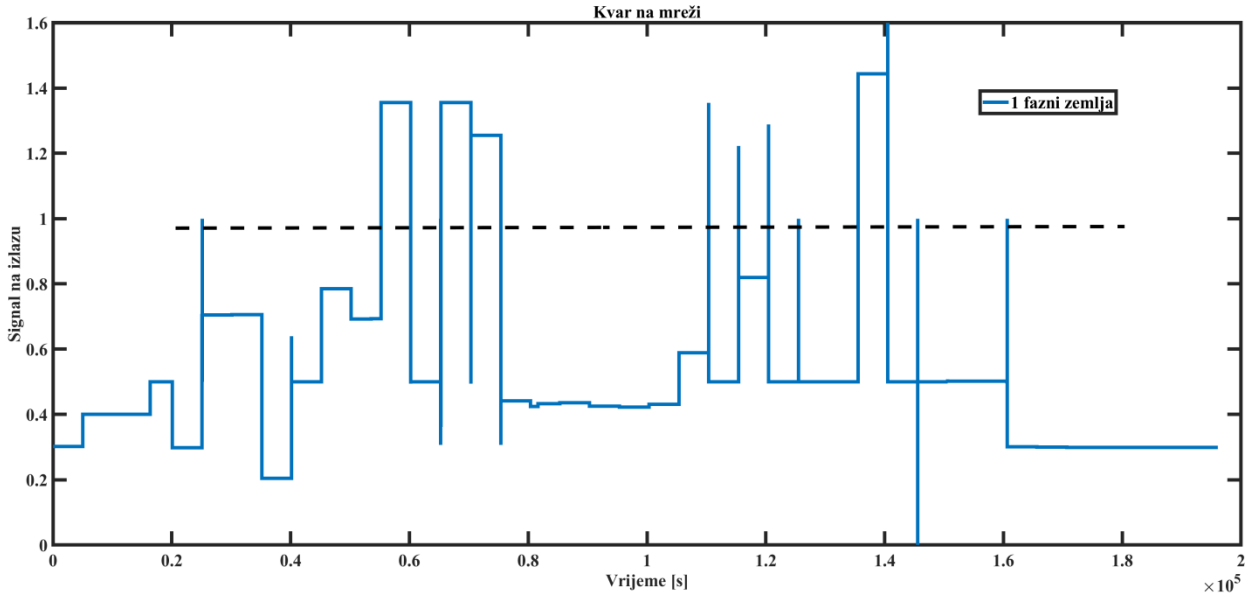
Rezultati testiranja kvarova na mreži je predstavljen na slici 8.6, 8.7 i 8.8.



Slika 8.6. Rezultati testiranja pri 3F-Z kvaru na nisko naponskoj distribucijskoj mreži. Iako se prag vrijednosti 1 prelazi ipak nema zadržavanja na njemu niti u jednom trenutku i time se ne daje signalizacija da je detektiran otočni rad na mreži.

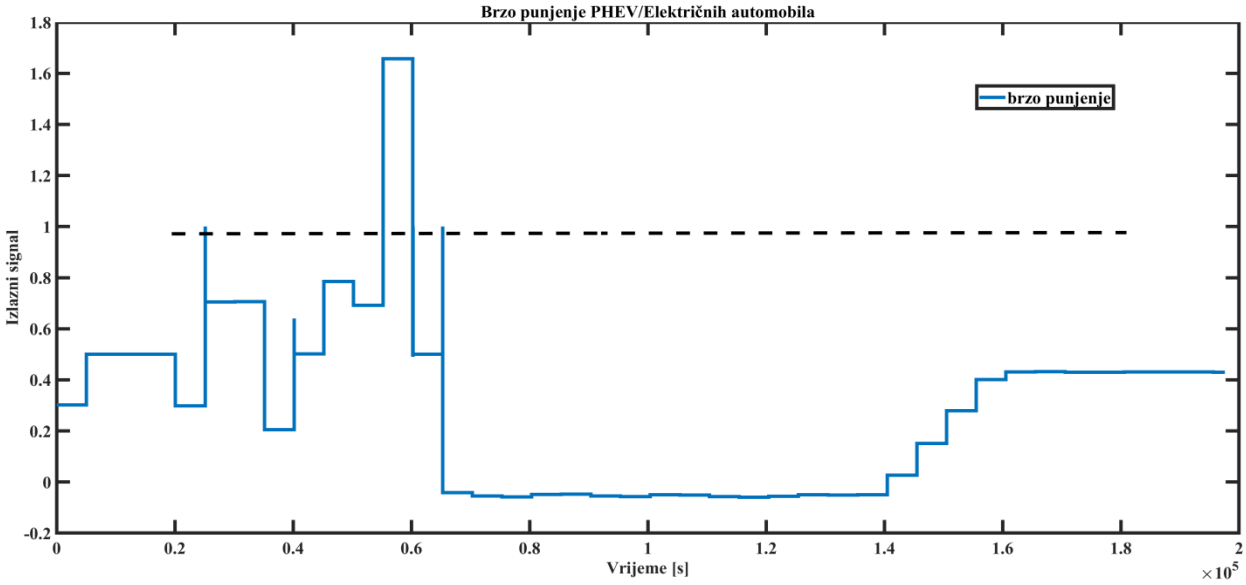


Slika 8.7. Rezultati testiranja pri 2F-F kvaru na nisko naponskoj distribucijskoj mreži. Također se ne zadržava krivulja na pragu vrijednosti 1 te time nije detektiran otočni rad.



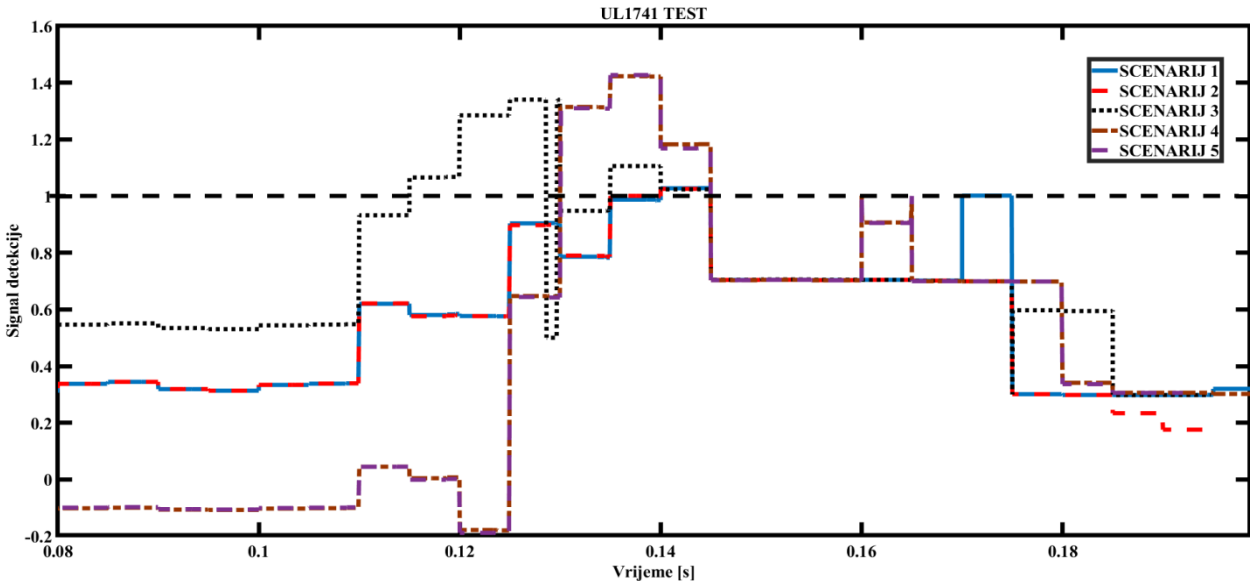
Slika 8.8. Rezultati testiranja pri 1F-Z kvaru na nisko naponskoj distribucijskoj mreži. Kao i u prethodnom scenariju, ne zadržava se krivulja na na pragu vrijednosti 1 te time nije detektiran otočni rad

Rezultati testiranja ANFIS metode pri brzom punjenju PHEV/električnih vozila je prikazan na slici 8.9.



Slika 8.9. Rezultat testiranja ANFIS metode pri iniciranom brzom punjenju PHEV/električnih automobila. Slično kao kod simulacije kvarova na mreži krivulja se ne zadržava na pragu vrijednosti 1 te time se ne prepoznaje punjenje automobila kao otočni rad.

Testiranje ANFIS metode za više distribuiranih izvora na istoj mikro mreži, je urađen prema slici 7.6, s tim da je dodatni sustav isti po karakteristikama kao i FN 1 a. Rezultati su dani na slici 8.10.



Slika 8.10. Rezultati testiranja ANFIS metode pri dodatnom FN sustavu kao distribuiranog izvora na istoj mikro mreži, pod uvjetima testiranja propisanima po standardu UL 1741. Primjetno je u trenutku 0,14 sekundi da su vrijednosti sastavljene na pragu vrijednosti 1 te time je detektiran otočni rad bez obzira na prisustvo još jednog distribuiranog izvora na istoj mikro mreže.

Na temelju rezultata sa slika i tablica, stabilnost mikro mreže nije narušena djelovanjem metode detekcije otočnog rada s ANFIS-om. Postoji nekoliko situacija koje treba razmotriti u skladu sa slikom 61. Distribuirani izvor i mikro mreža ostaju spojeni zajedno, dok linijski prekidači 4 ostaje zatvoren, tj. ostaje otočni rad samo za scenarij 1 i 2 propisanih standardom UL1741. U svim ostalim slučajevima predložena metoda otkrivanja otočnog rada vidi iste vrijednosti od distribuiranog izvora prema mreži i ne vidi drugu foto naponsku elektranu kao izvor napajanja.

Osim toga, distribuirani izvori povezani s izmjenjivačima se kontroliraju pomoću decentraliziranih i distribuiranih hijerarhijskih kontrolnih struktura koje se temelje na krovnoj izvedbi. Kao što se može naći u literaturi u nekim referencama [183], postupak projektiranja upravljačkog sustava nastoji osigurati glatki prijelaz između otočnog i mrežnog rada. Stoga je od primarne važnosti usredotočiti se na točnost i autentičnost predložene metode otkrivanja otočnog rada, a pitanja stabilnosti će se nositi s kontrolnom strukturom. Dodatni trening za sve slučajeve će više generalizirati ANFIS, stoga će se povećati stabilnost, tj. ako postoji veliki tok snage iz više distribuiranih izvora na mrežu.

Konačno, za pretpostavku neuspjeha predložene tehnike u praksi, umjesto kontinuirane obuke s ciljem bogatije baze znanja, koristi se stalno uključivanje dogradnje baze preko interneta. U tom slučaju, prvi utjecajni parametar je vrijeme detekcije. Svako drugo odstupanje potrošnje mreže može biti s malim postotkom, otkrivanjem otočnog rada prema sadašnjim uvjetima, jer svi oni ovise o energetskom tijeku distribuiranog izvora i povezat će se u detekciju otočnog rada zasnovanu na ANFIS-u. Stoga, postoji i pitanje vremena detekcije kada algoritam ne prepoznaje na vrijeme način rada distribuiranog izvora. Da bi predložena metoda temeljena na ANFIS-u postala općenitija, može se razmotriti online obuka ili kontinuirano ažuriranje postojećeg sustava. Postoji mogućnost da se provede tijekom noćnih sati kada je distribuirani izvori (FN) isključen. Osnovna arhitektura za online primjenu je robusna i uključuje više tehnika umjetne inteligencije-je. Ovo može biti tema budućih istraživanja autora ove disertacije.

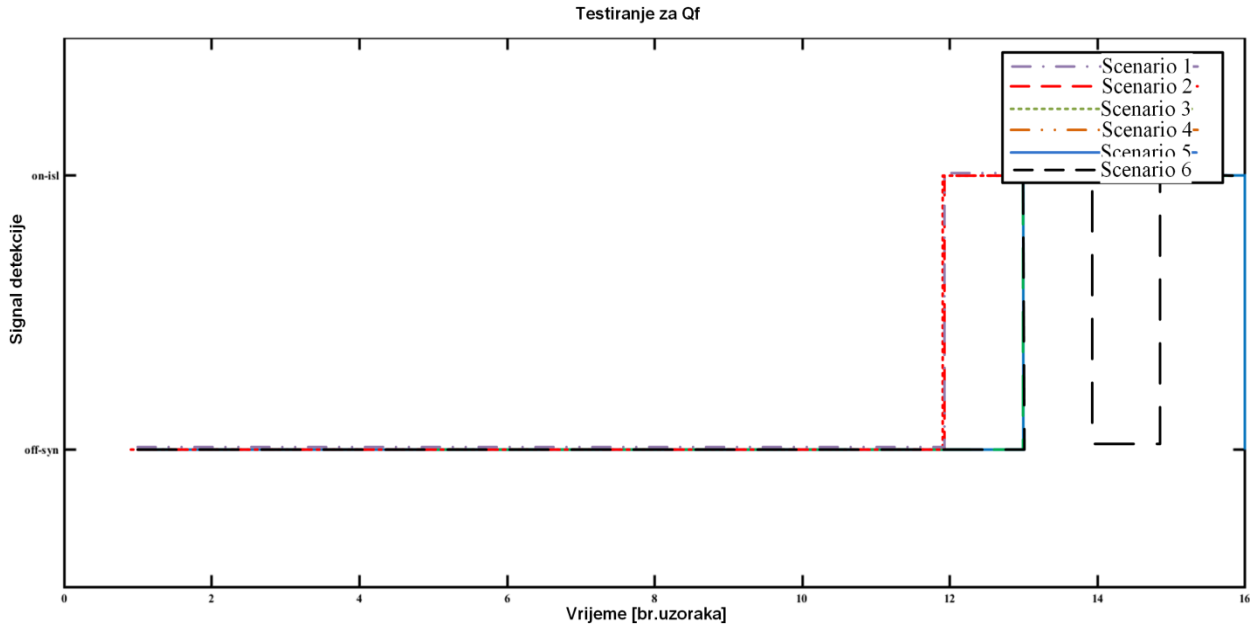
Budući je vlasnik foto naponskog sustava tvrtka iz privatnog sektora, nije nam dopušteno testirati konačni algoritam otkrivanja otočnog rada na njoj i samo su podaci izmjereni, uzeti i obrađeni u softverskom okruženju kako bi se razvile predložene metode. Međutim, ispitivanje u laboratorijskom okruženju je ključni faktor pri radu na terenu kod ove metode. U takvom režimu predložena metoda može biti testirana na mikro mreži s nekoliko foto naponskih jedinica.

Najvažnija značajka predložene metode je njezina generalizacija i fleksibilnost da se prilagodi bilo kojem distribuiranom izvoru s izmjenjivačem i osposobi ga prema okruženju da koristi podatke

dobivene iz praktičnih mjerenja. Postupak obuke za predloženu metodu je isti za sve načine otkrivanja otočnog rada, tako da nema dodatnih troškova za proces obuke. Još jedna značajka je brz odziv koji treba uzeti u obzir za tip senzora i hardvera za primjenu na terenu.

8.2. Metoda dubokog učenja (DU)

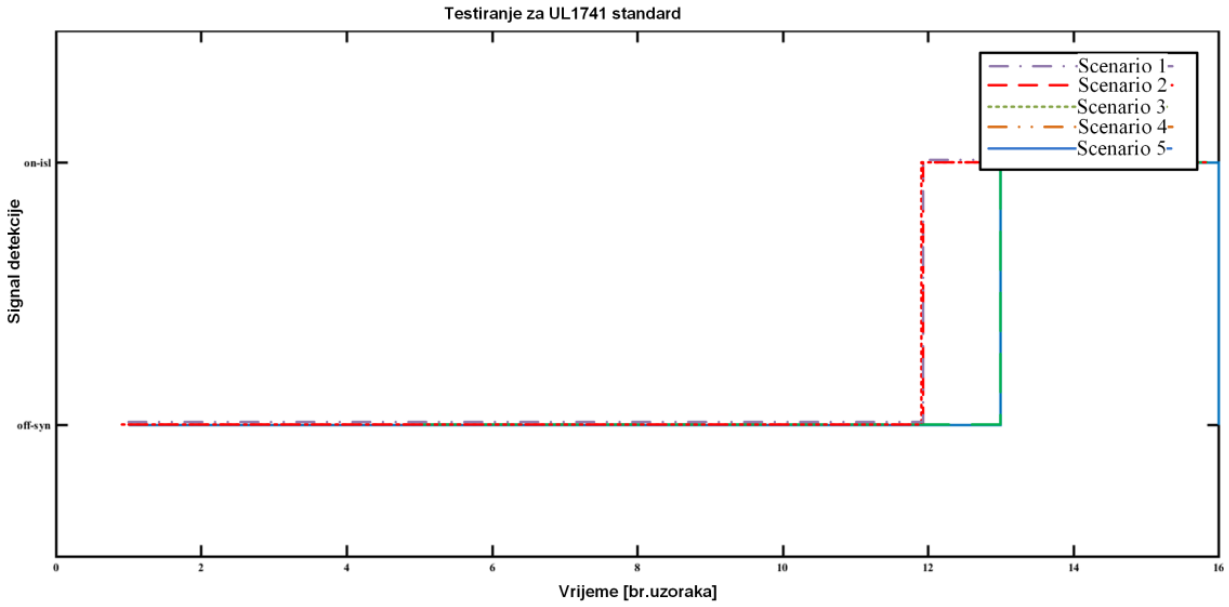
Prvi test koji je urađen za DU metodu jesu različiti Q_f faktori mreže, gdje se pod različitim kvalitetom mreže inicira otočni rad i provjerava detekcija uz pomoć predložene metode, a sve prema predloženim parametrima prema tablici 19. Rezultati su prikazani na slici 8.11 i tablici 8.4. Bitno je primijetiti da na apscisi slika nije vremenska dimenzija, nego redni broj uzorka koji se ispituje. Svaki uzorak je trenutak u vremenu uzorkovanja u razmaku od 5 milisekundi.



Slika 8.11. Rezultati testiranja DU metode pod različitim Q_f vrijednostima distribucijskoj mreži-a prema tablici 19. Na slici se vidi da signal prelazi iz „off-sync“ u „on-isl“ status te time signalizira prelazak u otočni režim rada distribuiranog izvora.

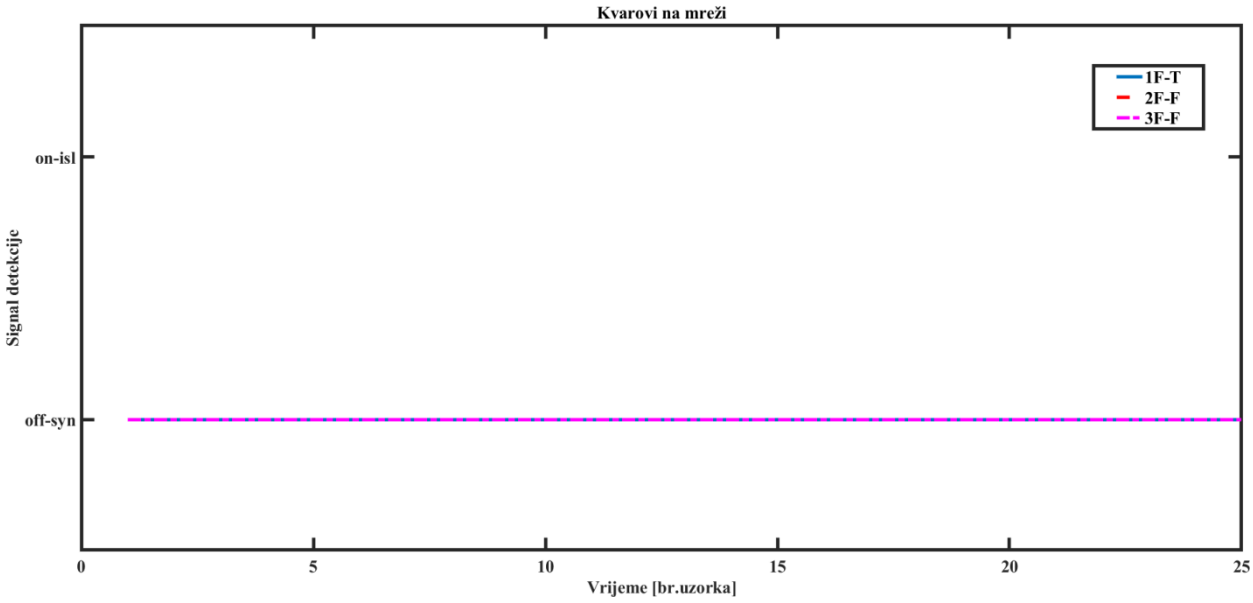
Tablica 8.4. Rezultati testiranja DU metode prema različitim Q_f vrijednostima distribucijske mreže. Prikazana su vremena detekcije otočnog rada od trenutka njegovog iniciranja na niskonaponskoj mreži.

	Vrijeme [ms]
Scenarij 1	35
Scenarij 2	35
Scenarij 3	35
Scenarij 4	40
Scenarij 5	40
Scenarij 6	40



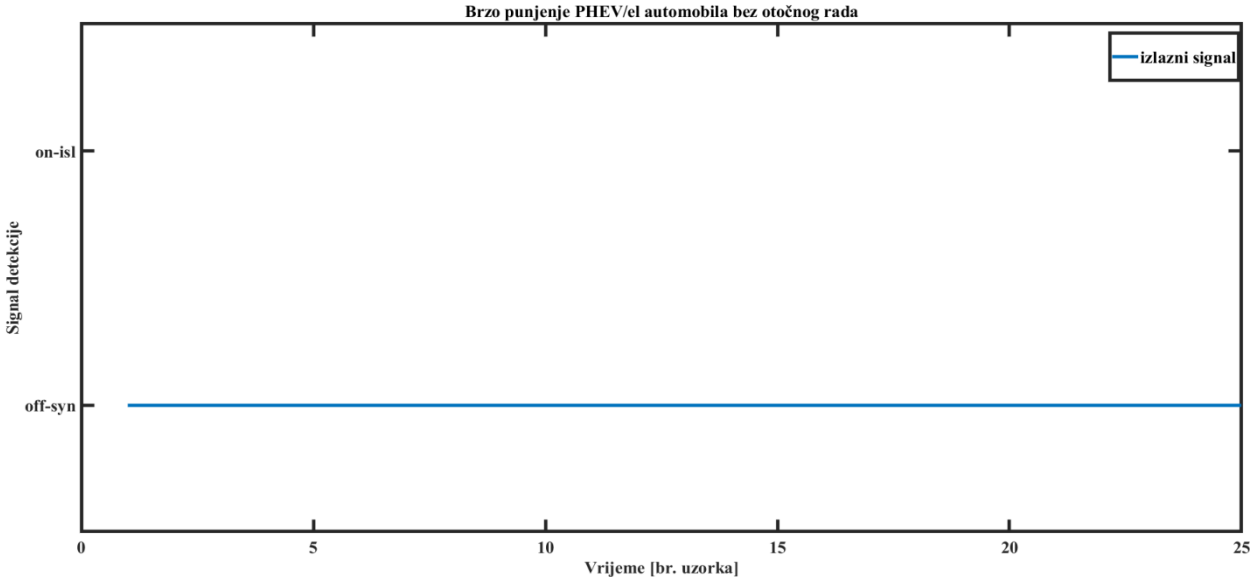
Slika 8.12. Rezultati testiranja DU metode pod parametrima UL 1741 standarda, prema tablici 7.3. Za svaki scenarij signal jasno prelazi u stanje „on-isl“ i time detektira otočni rad.

Testiranje pod uvjetima kvarova na mreži je urađeno prema opisu iz pod poglavlja 7.3. Rezultati su predstavljeni u na slici 8.13 za sve tri vrste kvarova.

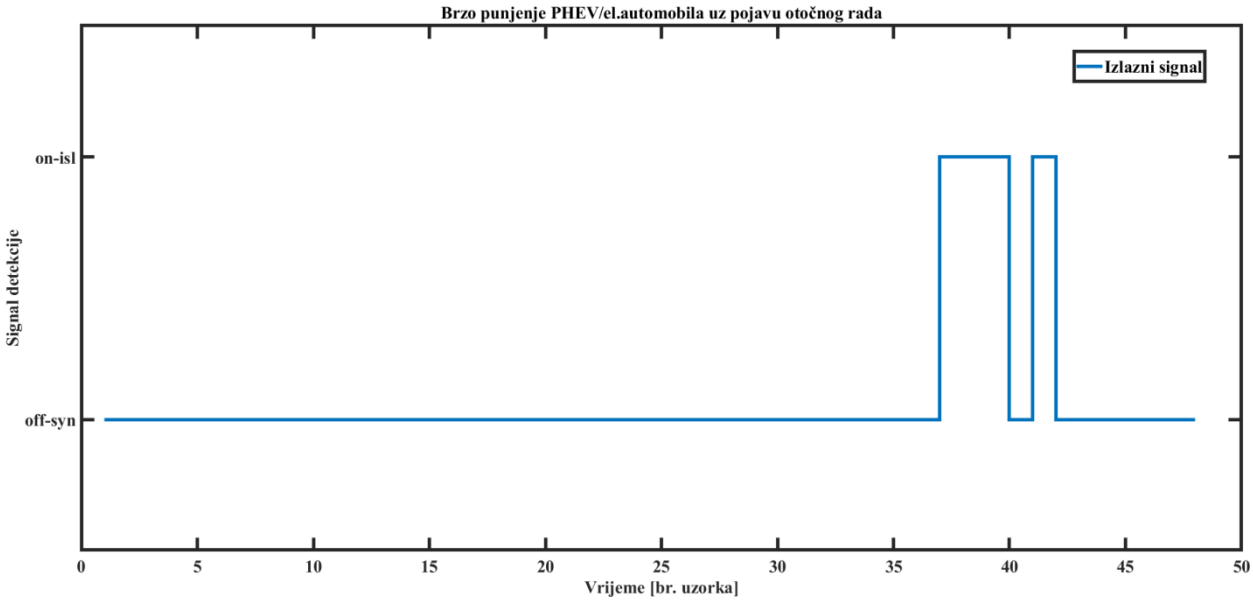


Slika 8.13. Rezultati za DU prema situacijama kvarova na nisko naponskoj distribucijskoj mreži. Signal ne mijenja status čak niti kada se desi kvar na mreži. Time metoda zadovoljava test gdje se kvar na mreži ne prepoznaje kao prelazak u otočni rad.

Testiranje brzog punjenja PHEV/električnih automobila je urađeno prema pod poglavlju 7.4, tako da su urađena dva scenarija: kada se uključi brzo punjenje bez pojave otočnog rada, kada se uključi brzo punjenje i pojavi otočni rad. Oba rezultata su dana na slikama 8.14 i 8.14.

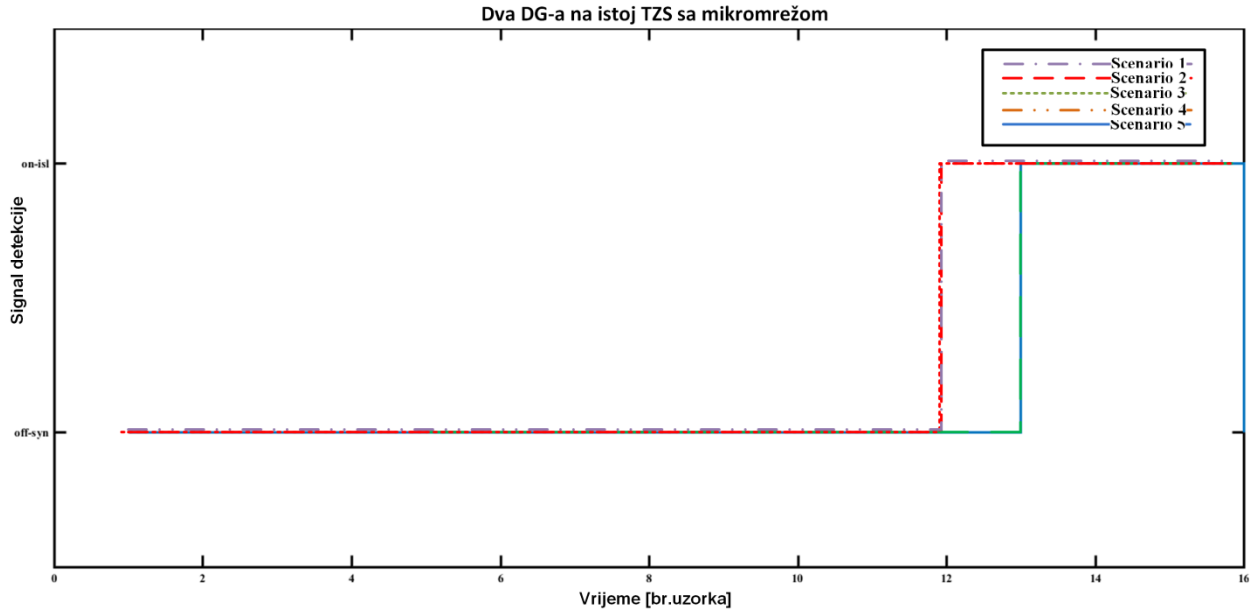


Slika 8.14. Rezultati DU detekcije otočnog rada pri uključivanju brzog punjenja PHEV /električnih automobila, bez pojave otočnog rada. Također punjenje električnog vozila ne predstavlja zabunu za metodu koja je signalizira da je došlo do prelaska u otočni rad kada se puni električno vozilo.



Slika 8.15. Rezultati DU detekcije otočnog rada pri uključivanju brzog punjenja PHEV /električnih automobila, uz pojavu otočnog rada. Isti režim punjenja ali ovog puta s iniciranim otočnim radom. Metoda prepoznaje prelazak u otočni režim rada DI.

Rezultati za dva distribuiranog izvora na istoj točki zajedničkog spajanja su prezentirani na slici 8.15, a urađen za svih 5 scenarija po standardu UL1741, navedenih u pod poglavlju 7.2.



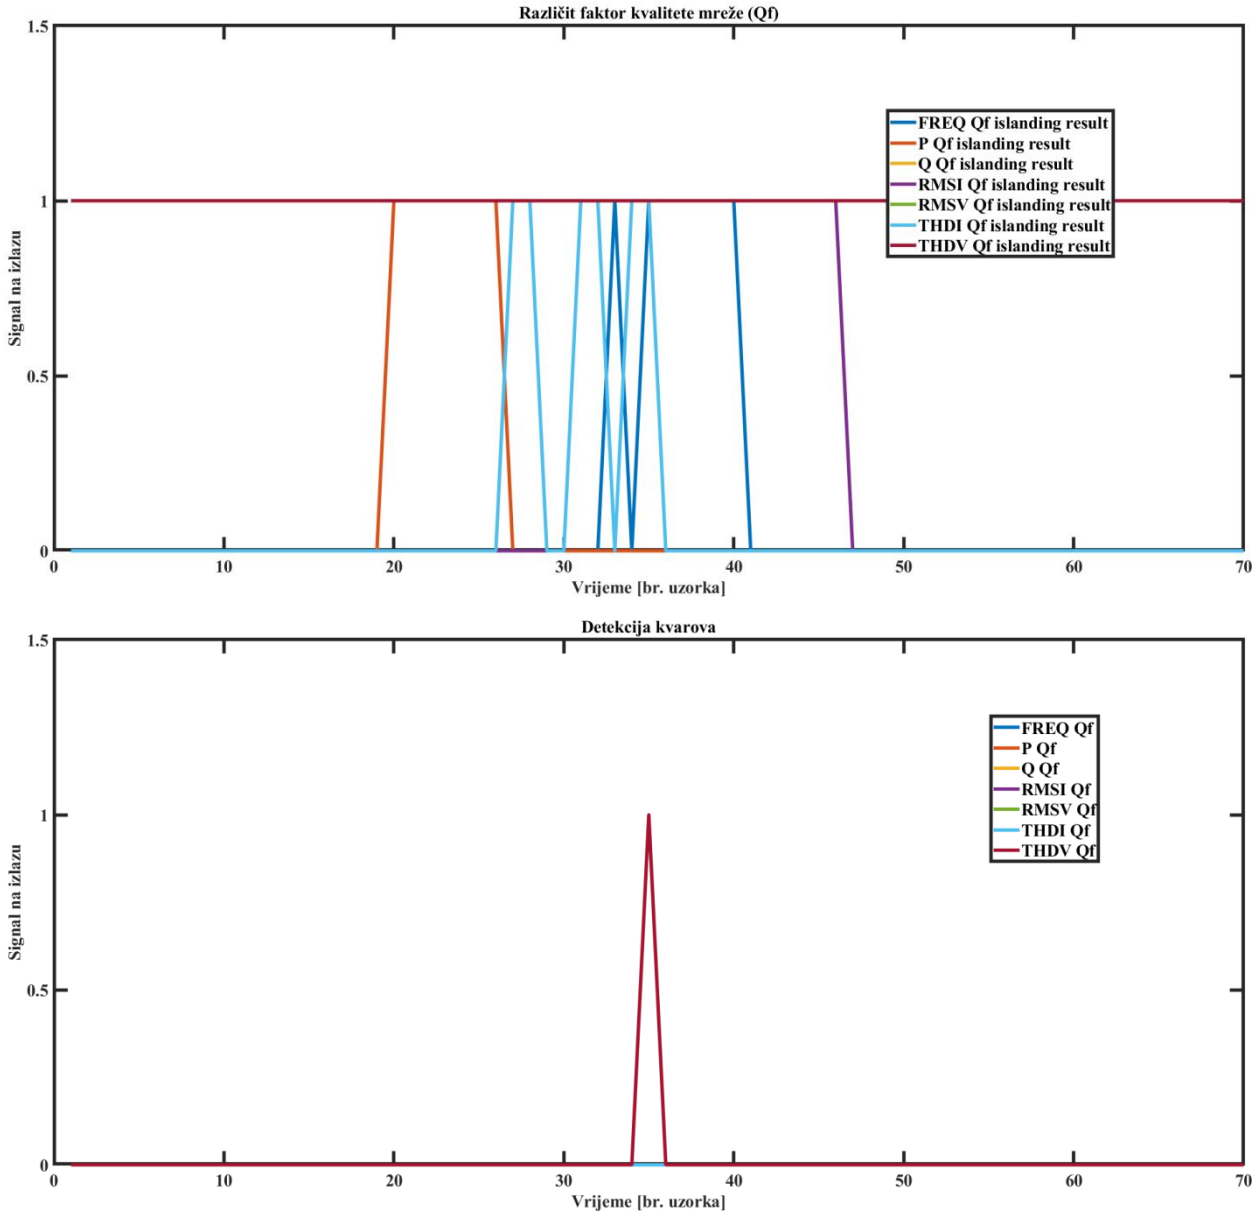
Slika 8.16. Rezultati testiranja DU metode u situaciji prisustva dva distribuiranog izvora u istoj točki zajedničkog spajanja, a pod uvjetima standarda UL 1741. Rezultati jasno prikazuju da metoda detektira otočni rad kada je on iniciran.

Iz slike 8.14, vidljiv je izlazni signal otočnog rada u točki 37, koja je t = 45 ms. Umjesto prijavljivanja momenta brzog punjenja pri točki 8 (0,100 s) kao prelazak u otočni rad, izlazni signali se generiraju samo kada se pojavljuje otočni rad koji čini predloženu DU metodu selektivnom detekcijom otočnog rada.

Sa slike 8.15, DU metoda pokazuje iste rezultate kao u konfiguraciji sa jednim distribuiranim izvorom na distribucijskoj mreži-u. Prema dobivenim rezultatima zaključak je isti, DU metoda je selektivna i pravodobna za otkrivanje otočnog rada distribuiranog izvora. Usporedni rezultati pokazuju sposobnost predložene metode DU -a koja se temelji na CNN, kao jedne od najbržih metoda otkrivanja otočnog rada. Osim prikazanih usporednih faktora, mogu se uzeti u obzir i drugi parametri koji nisu ograničeni na: vrijeme treninga metode, broj nadziranih signala, broj uzoraka, troškove mjerenja.

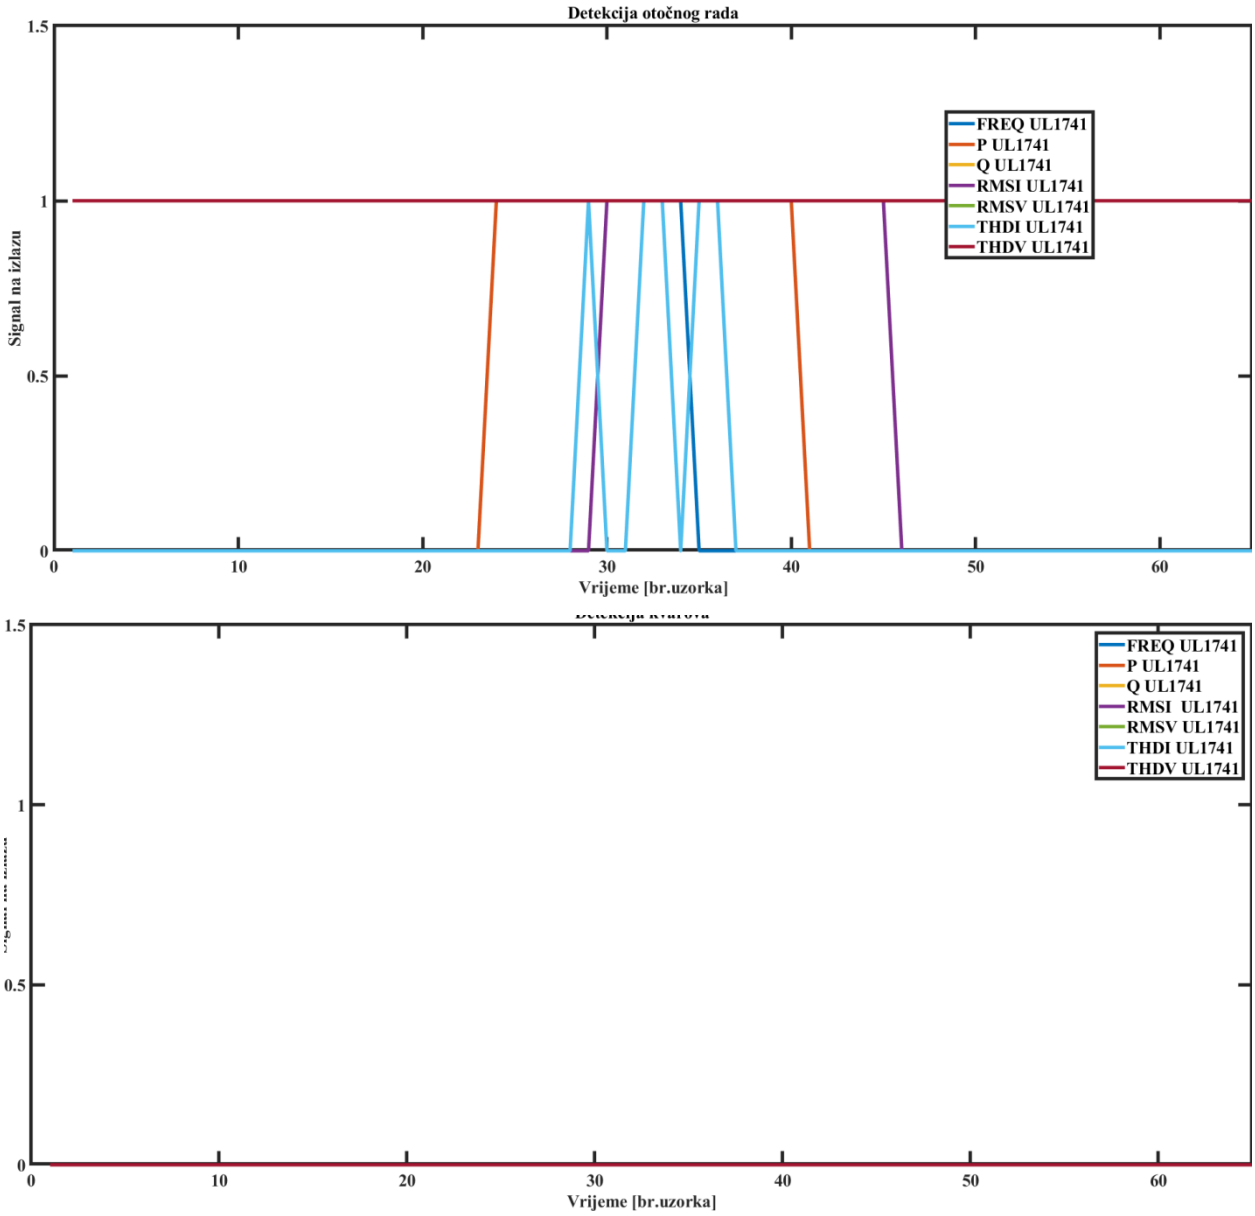
8.3. Metoda potpornih vektora (MPV)

Kao i kod prethodnih metoda prvi test je za različite Q_f faktore nisko naponskoj distribucijskoj mreži prema tablici 19. Rezultati su prikazani na slici 8.16. Ono što je bitno napomenuti jeste da apscisa predstavlja broj uzorka, a ordinata signal na izlazu iz MPV kontrolora. Pored toga kod MPV metode postoje dva izlaza: jedan za detekciju otočnog rada, a drugi za detekciju kvarova na mreži.



Slika 8.17. Rezultati testiranja metode MPV za detekciju otočnog rada distribuiranog izvora, pri različitim faktorima kvalitete mreže. Gore detekcija otočnog rada, dolje detekcija kvarova na mreži. Kao što se može vidjeti sa slike, otočni rad se prepoznaje od svih sedam MPV kontrolora dok se kvar na kratko prepoznaje od strane THD_V

Slijedeći rezultati su od testiranja pod UL1741 propisima iz pod poglavlja 7.2., a prikazani su na slici 8.17. Zbirni rezultat za navedena dva testa je prikazan u tablici 25.



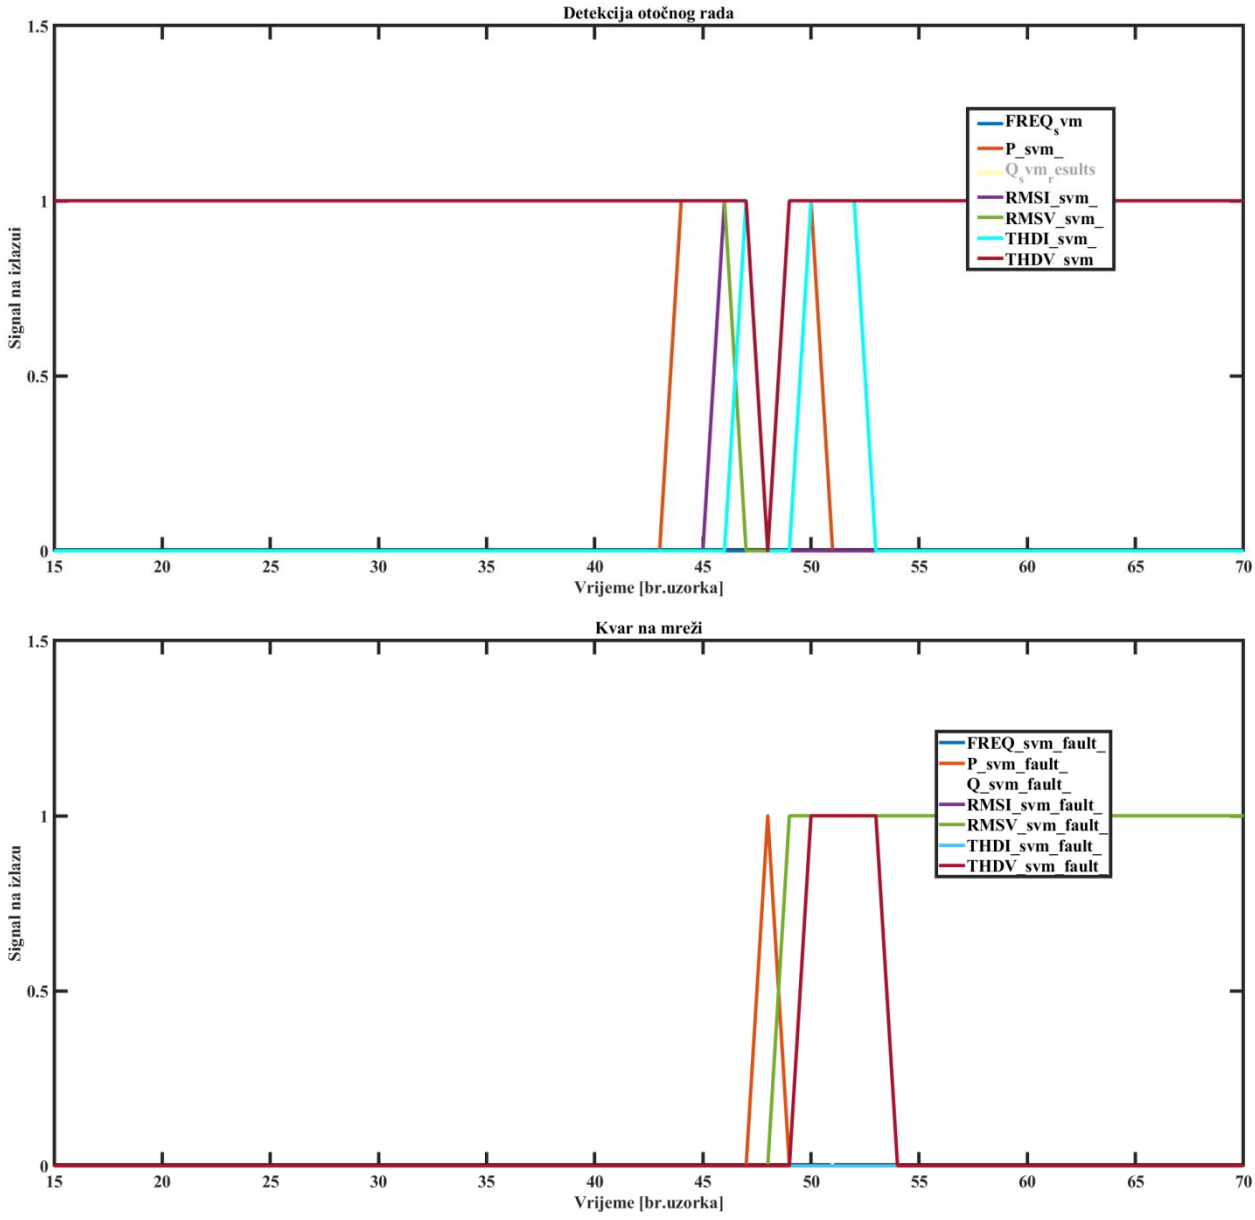
Slika 8.18. Rezultati testiranja MPV metode pri standardu UL1741. Pod uvjetima različitih faktora kvalitete mreže se vidi da MPV prepoznaje prelazak u otočni rad dok MPV dežurna za kvarove se ne aktivira.

Tablica 8.5. Rezultati vremena detekcije otočnog rada, pri različitim Q_f faktorima i standardom UL 1741.

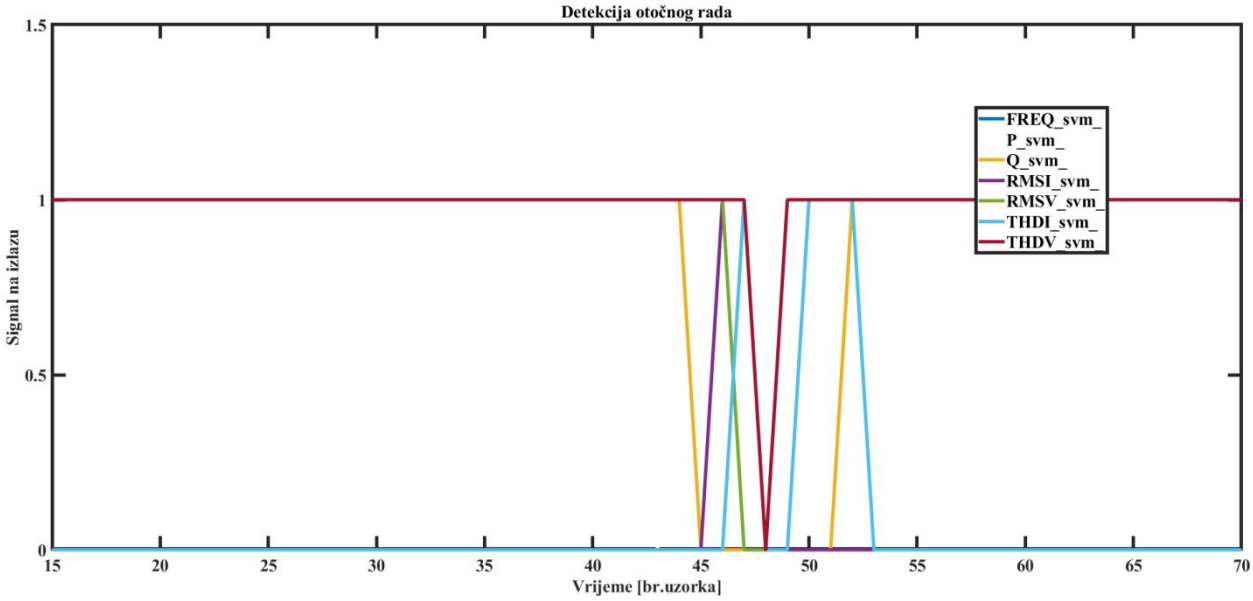
	Slika 65: Q_f	**Slika 66: UL 1741**
Scenarij 1	50 ms	55 ms
Scenarij 2	50 ms	55 ms

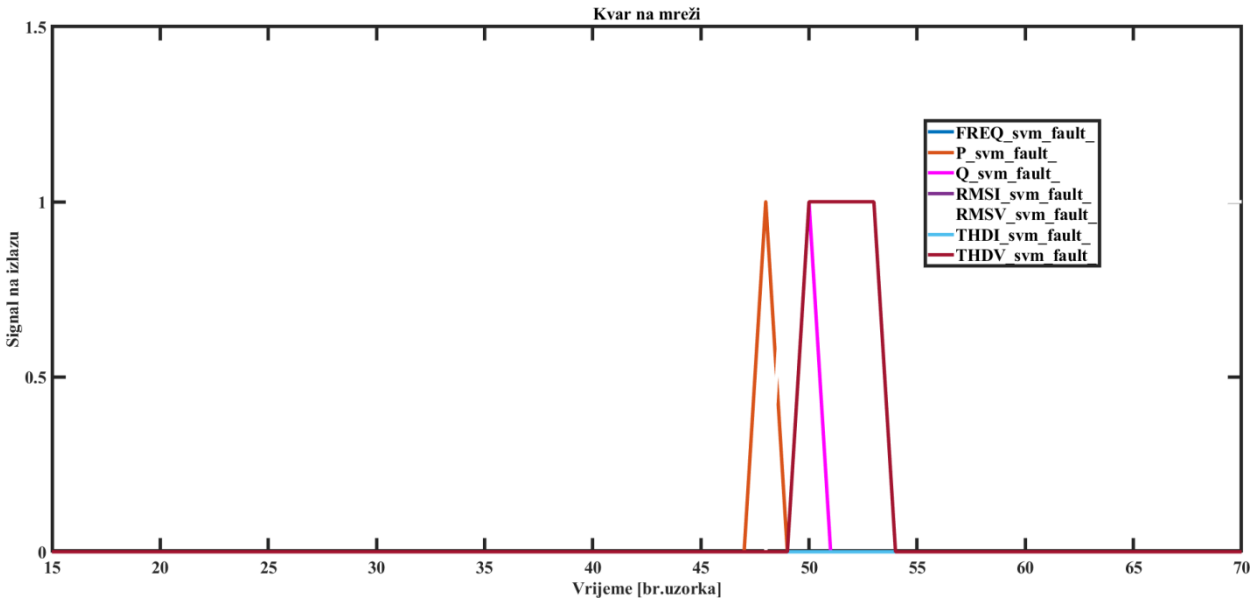
Scenarij 3	50 ms	55 ms
Scenarij 4	50 ms	55 ms
Scenarij 5	50 ms	55 ms
Scenarij 6	55 ms	/

Rezultati testiranja detekcije otočnog rada, pri kvarovima na mreži je predstavljen na slikama 8.18, 8.19 i 8.20, te u tablici 8.6.

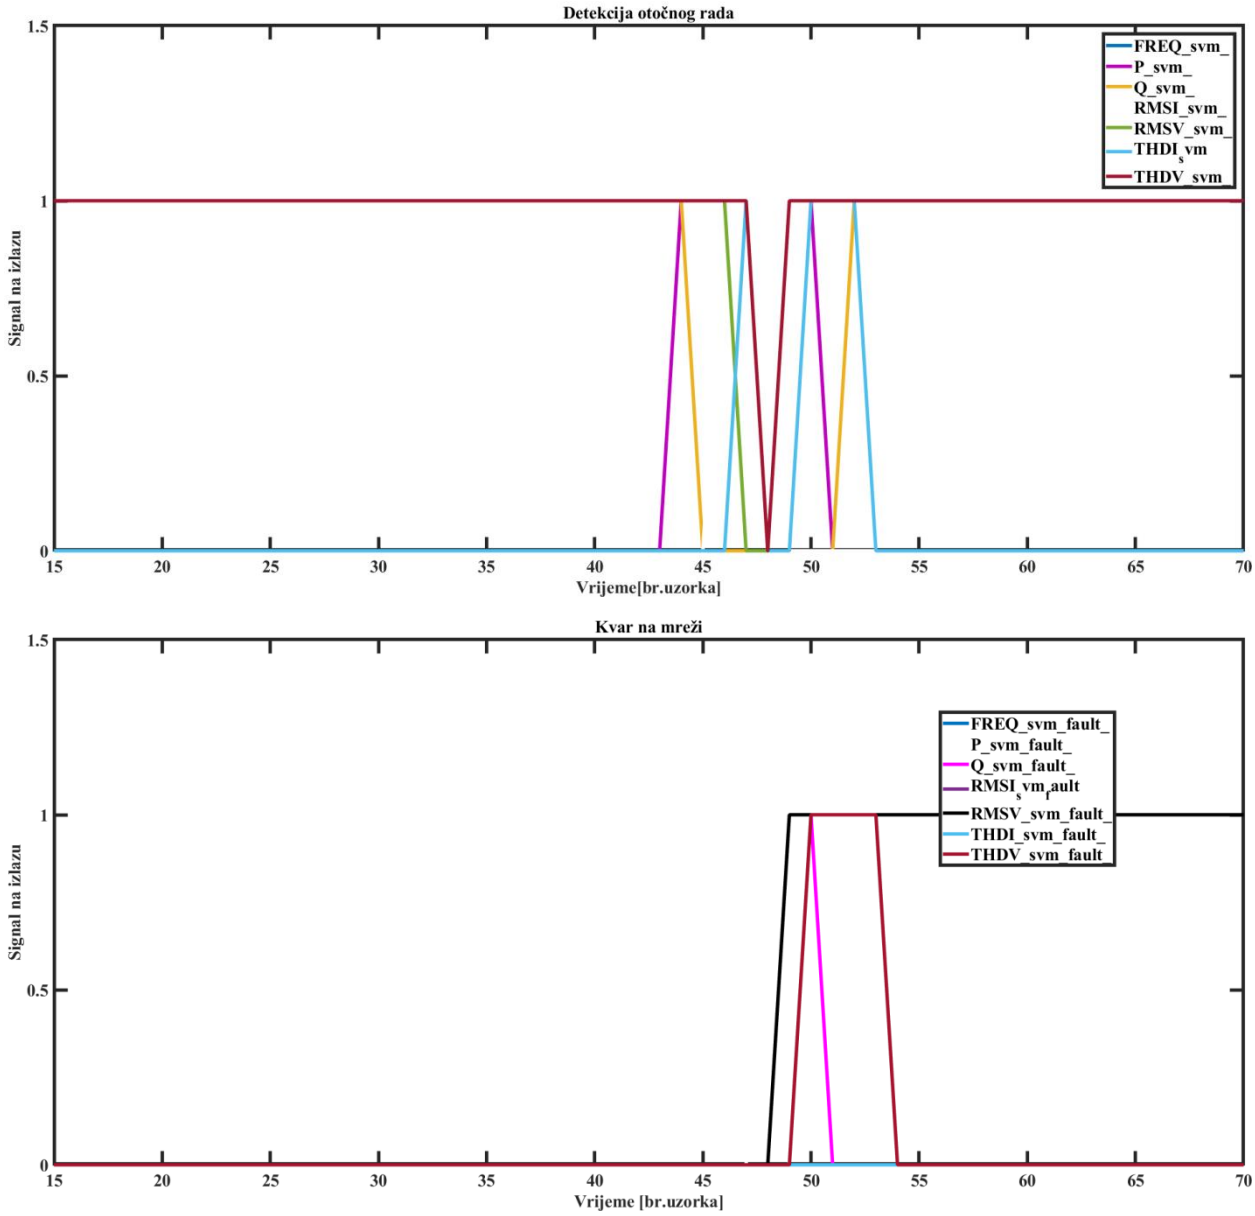


Slika 8.19. Rezultati pri 3F-Z kvaru na mreži. Vidljivo je sa slike da MPV zadužena za otočni rad također se aktivira što je očekivano ali se također aktivira i MPV zaduženi za detekciju kvarova. Ovo upotpunjuje cjelokupnu metodu detekcije kvarova koji su podskup otočnog rada.





Slika 8.20. Rezultati pri 2F-F kvaru na mreži. Jasno detektiran otočni rad kao i kvar na mreži. Signala da postoji kvar na mreži

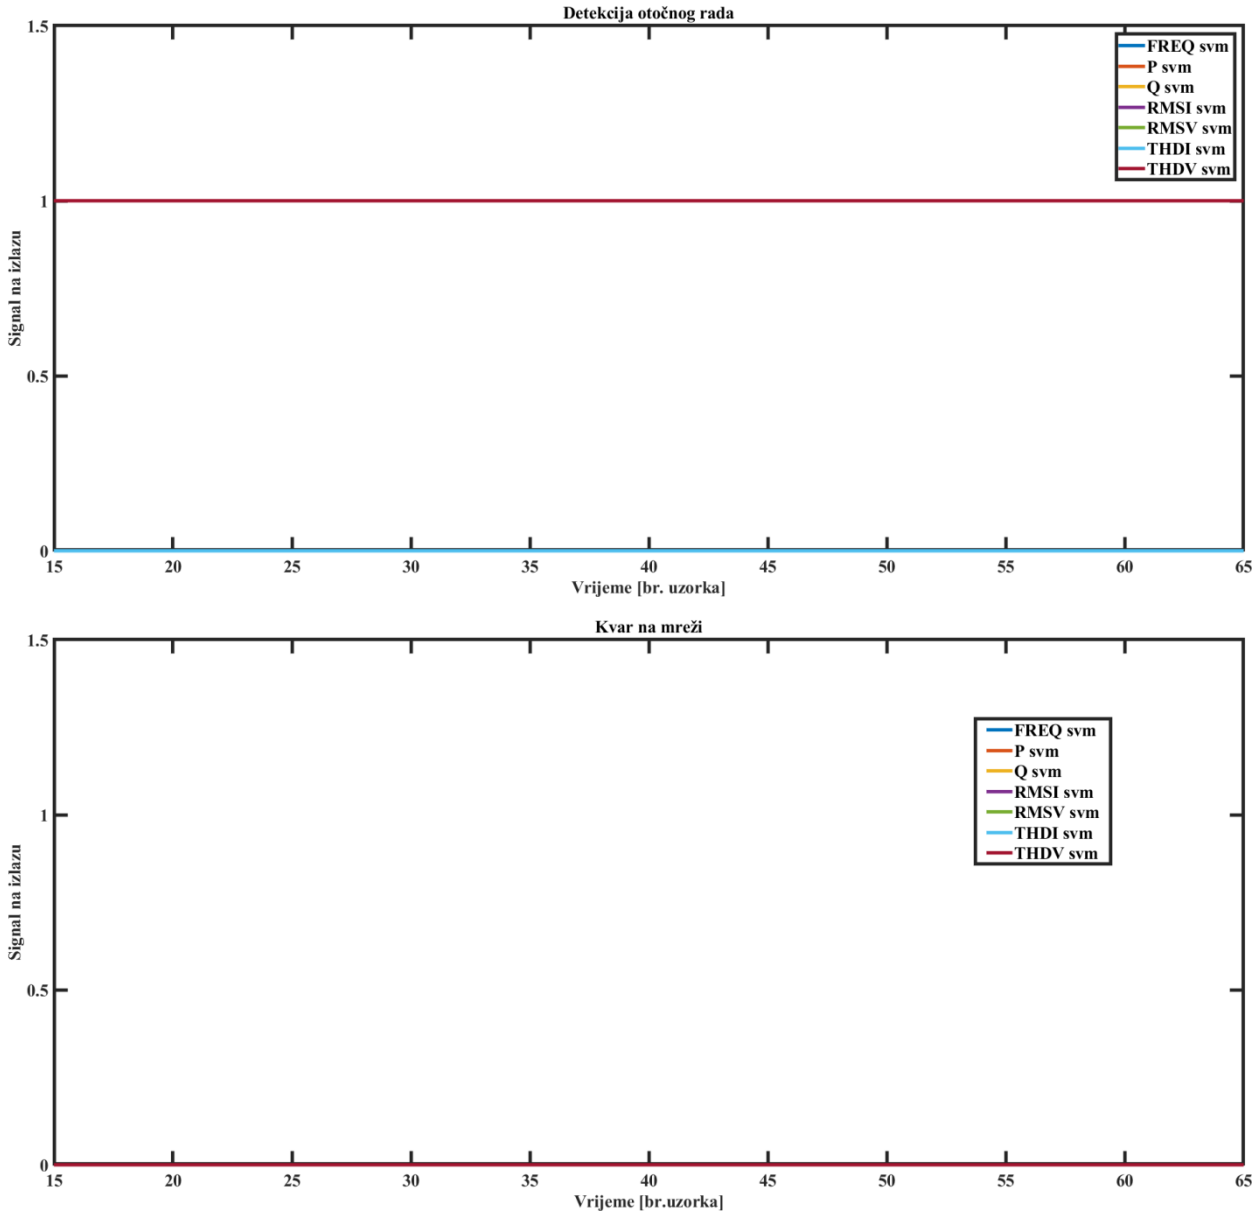


Slika 8.21. Rezultati pri 1F-T kvaru na mreži. Signalizacija kvara na mreži jasno pokazuje da je kvar prisutan na mreži iako je aktiviran i MPV koji je zadužen za detekciju otočnog rada čime upotpunjuje detekciju kvara.

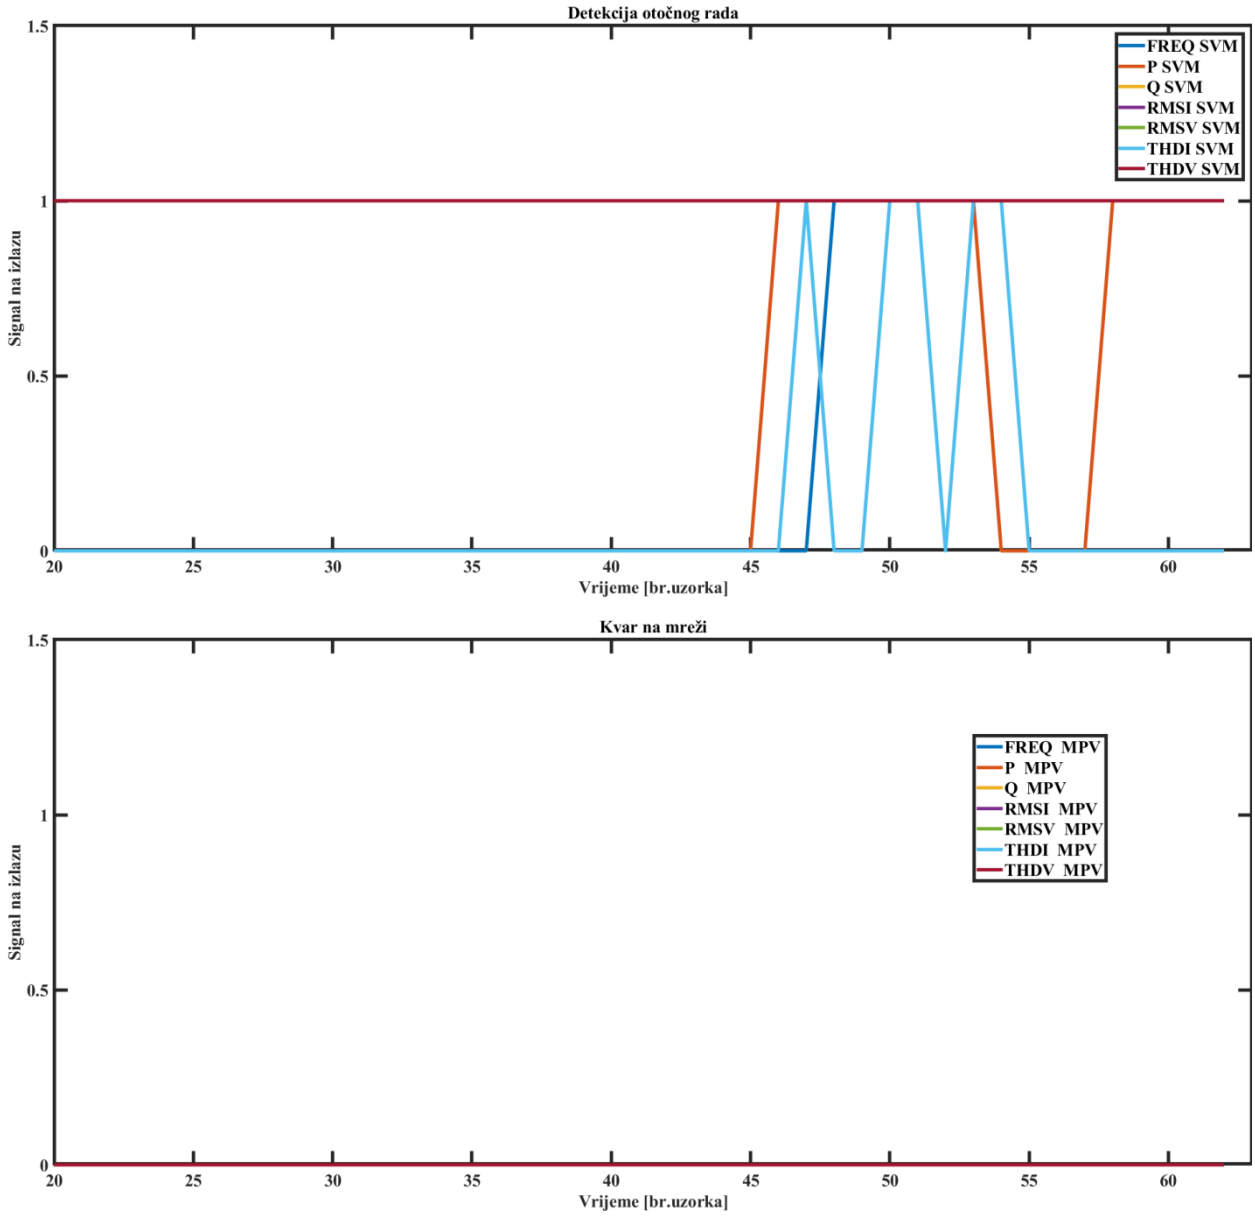
Tablica 8.6. Rezultati testiranja pri kvarovima na distribucijskoj mreži. Prikazani su izlazi iz pojedinih MPV tako da je uz potvrdan izlaz napisano i vrijeme za koje se kontrolor odaziva.

	3F-F kvar				**2F-F kvar**				**1F-T kvar**			
	Otočni pogon		**Kvar**		**Otočni pogon**		**Kvar**		**Otočni pogon**		**Kvar**	
	Izlaz	Vrijeme detekcije [ms]	Izlaz	Vrijeme detekcije [ms]	Izlaz	Vrijeme detekcije [ms]	Izlaz	Vrijeme detekcije [ms]	Izlaz	Vrijeme detekcije [ms]	Izlaz	Vrijeme detekcije [ms]
f	NE	/	DA	40	NE	/	DA	40	NE	/	DA	40
P	DA	20	DA	30	NE	/	DA	30	DA	20	DA	30
Q	NE	/	DA	50	NE	/	DA	50	NE	/	DA	50
RMS_I	DA	25	DA	40	DA	25	DA	40	DA	25	NE	/
RMS_V	NE	/	DA	40	NE	/	DA	40	NE	/	DA	40
THD_I	DA	40	NE	/	NE	/	NE	/	NE	/	NE	/
THD_V	NE	/	DA	40	NE	/	DA	40	NE	/	DA	40

Rezultati testiranja pri brzom punjenju PHEV/električnih automobila su predstavljeni na slici 8.21.

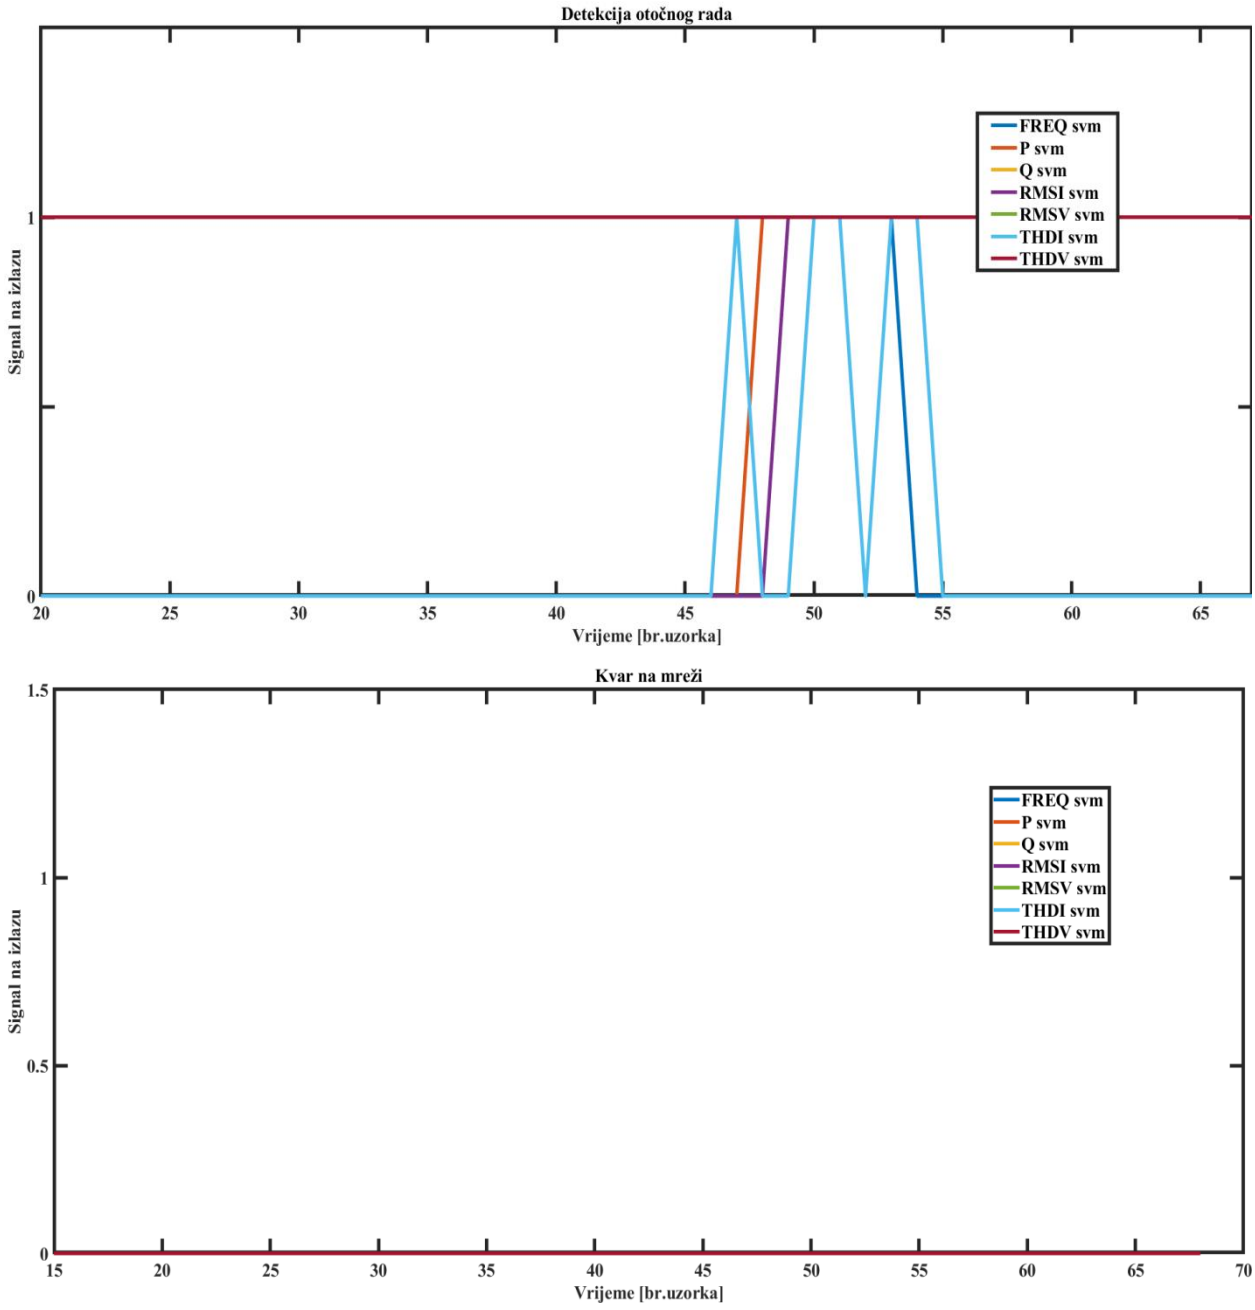


Slika 8.22. Rezultati testiranja MPV metoda pri brzom punjenju PHEV/el. automobila bez pojave otočnog rada. Kako se može vidjeti sa slike nema detekcije kvarova na mreži kao ni prelaska u otočni rad pri brzom punjenju električnog automobila.



Slika 8.23. Rezultati testiranja MPV metoda pri brzom punjenju PHEV/el. automobila s pojavom otočnog rada. Međutim kada je prelazak u otočni rad prisutan za vrijeme brzog punjenja električnog automobila, MPV jasno detektira tu pojavu bez dvojbe da li je to možda kvar na mreži.

Zadnji test jeste sa još jednim distribuiranim izvorom u istoj točki zajedničkog spajanja sa mikro mrežom. Rezultati su predstavljeni na slici 8.23 i tablice 8.24.



Slika 8.24. Rezultat detekcije otočnog rada pri prisustvu još jednog distribuiranog izvora u istoj točki zajedničkog spajanja sa mikro mrežom. Prisustvo još jednog distribuiranog izvora na mreži ne remeti MPV kontrolor da jasno detektira prelazak u otočni rad.

Tablica 8.7. Rezultati vremena detekcije, pri dodatnom distribuiranom izvoru u istoj točki zajedničkog spajanja sa mikro mrežom. Prikazani su izlazi iz pojedinih MPV tako da je uz potvrdan izlaz napisano i vrijeme za koje se kontrolor odaziva

	Dva distribuirana izvora spojena na istu točki zajedničkog spajanja			
	Otočni pogon		**Kvar**	
	Izlaz	Vrijeme detekcije [ms]	Izlaz	Vrijeme detekcije [ms]
Frekvencija	DA	25	NE	/
P	DA	40	NE	/
Q	NE	0	NE	/
RMS_I	DA	40	NE	/
RMS_V	NE	0	NE	/
THD_I	DA	30	NE	/
THD_V	NE	0	NE	/

Iz prikazanih rezultata vidljivo je da se detektira otočni pogon prema prvim rezultatima na slici 8.23. Događaj otočnog rada se javlja u 0,200 s, a to je 40 na apscisi skali na slici 8.22. Detekcija vremena i izlazni signal dani su u tablici 8.7.

Na temelju prikazanih rezultata na slici 8.23, predložena MPV metoda je uspješno otkrila otočni rad kada su u paralelni dva distribuirana izvora spojena na istoj točki zajedničkog spajanja.

Prema rezultatima sa slika 8.18, 8.19 i 8.20, te rezultata iz tablice 8.7, kvar na mreži je prepoznat kao podskup otočnog rada. Otočni MPV blok djelomično prepoznaje kvar kao otočni rad, a MPV blok za detekciju kvara mijenja stanje od DA do NE i to se smatra promjenom stanja. Jednostavnom linearnom konverzijom se može promijeniti da sva stanja kreću od NE prema DA, kada je u pitanju detekcija otočnog rada ili detekcija kvara.

Scenarij otočnog rada za slučaj brzog punjenja PHEV/el. automobila, pojavljuje se na 0,200 s od početka simulacije na vremenskoj crti. Od broja do broja na apscisi, vremenski razmak je 5 ms.

Prema slici 8.22, otočni rad se pojavljuje u 0,100 s i detektira se svim signalima 45-60 ms od trenutka djelovanja linijskog prekidača 2. Izlazni signali koriste se za otkrivanje otočnog rada i jasno je da svih 7 signala mijenjaju svoje stanje nakon otočnog događaja. Prema izlaznim podacima, otkrivanje otočnog rada se postiže prema scenariju standarda UL1741. Iz slike 8.17, može se vidjeti da signal THDV otkriva kvar na 40 ms, ali u cjelokupnom algoritmu za donošenje odluka koji ne djeluje kao otkrivanje. Takvo ponašanje je prihvatljivo i ne pokreće postupak otkrivanja kvara.

8.4. Usporedba rezultata

U ovom radu predložene su tri nove strategije zasnovane na metodama umjetne inteligencije za otkrivanje otočnog rada, a to su:

1) Adaptivni sustav neuro-neizrazitog zaključivanja (eng. Adaptive Neuro-Fuzzy Inference System -ANFIS),
2) Duboko učenje (eng. Deep Learning - DL),
3) Metoda potpornih vektora (eng. Support Vector Machine -MPV).

Predložene metode uvode algoritme zatvorene petlje koji konstantno promatraju i mjere sedam veličina na točki zajedničkog spajanja-u, te veličine su ujedno parametri kvalitete energije:

a) Frekvencija (f),
b) Efektivna vrijednost napona (RMS_U),
c) Efektivna vrijednost struje (RMS_I),
d) Ukupno harmonijsko izobličenje napona (THD_U),
e) Ukupno harmonijsko izobličenje struje (THD_I),
f) Aktivna snaga koju proizvodi distribuirani izvor (P_G),
g) Reaktivna snaga koju proizvodi distribuirani izvor (Q_G).

Izvedba predloženih metoda ovisi o kvaliteti uzoraka uzetih s mjerenja, kao baza za treniranje i testiranje metoda, i još važnije, uzorkovanom vremenu i broju uzoraka, radi optimizacije predložene metode. Sukladno tome, uzeto je vrijeme uzorkovanja od 5 ms, za svaku od 7 veličina. Navedeno vrijeme uzorkovanja je odabrano imajući na umu da uzorak mora biti dovoljno malen da bi se promjena na signalu primijetila, a ne ići u dublje razlagane sinusoidnog signala što bi dodatno opterećivalo analizu pojave. Navedenih 5 milisekundi je optimalan iznos u navedenim okvirima (odabran prema mišljenju autora disertacije). Ulazni podaci za trening sve tri metode dobiveni su eksperimentalnim mjerenjem na točki zajedničkog spajanja stvarnog foto naponskog

sustava, koji koristi uređaj napravljen za tu svrhu za automatsko mjerenje navedenih veličina. Predložena metoda zaštite otočnog rada testirana je u scenarijima temeljenim na standardu UL1741 za različita opterećenja i različite faktore kvalitete Q_f, dva paralelna distribuirana izvora, kvar na mreži i brzo punjenje električnih i hibridnih vozila (eng. Plug in Hybrid Electric Vehicle - PHEV). Usporedba sve tri metode kako bi dokazali učinkovitost, brzinu rada, točnost i autentičnost je prikazana na slici 8.15 i tablicama 8.5 i 8.6. Na temelju ove usporedbe, autor ove doktorske disertacije zaključuje da su predložene metode generalno brze i točne, te imaju malu zonu ne detekcije otočnog rada, prvenstveno zbog kombinacije sedam mjerenih parametara mreže. Pored toga, ove metode ne utječu na kvalitetu električne energije zbog uporabe pasivnih tehnika mjerenja i obrađivanja ulaznih informacija na temelju kojih se prepoznaje otočni rad.

Na temelju usporedbe rezultata, predložene metode dokazuju svoju učinkovitost kroz brzinu otkrivanja, točnost i pokrivenost situacija u kojima se otočni rad može desiti. Na temelju ove usporedbe, zaključak je da je predložena metoda zasnovana na metodi dubokog učenja brza i točna, uz najmanju zone ne detekcije.

Kroz testiranje su postignute slijedeće spoznaje:

1) Za prepoznavanje otočnog rada i grešaka koristi se sedam signala: frekvencija, aktivna snaga, reaktivna snaga, RMS_I, RMS_V, THD_I i THD_V. Koriste kao skup za obuku i testiranje za konačni algoritam umjetne inteligencije. Predložena metoda jako ovisi o načinu i kvaliteti uzorkovanja parametara mreže.
2) Predložena osjetljivost metoda detekcije otočnog rada distribuiranog izvora, na kvarove se može riješiti uključivanjem dodatne metode otkrivanja kvarova zasnovane na istom ili različitom metodu umjetne inteligencije, pomoću pod-podešavanja otkrivanja prvenstveno kvarova na mikro mreži.
3) Zbog pasivne prirode predloženih metoda, ovim postupkom detekcije se ne utječe na kvalitetu energije i druge mjere zaštite elektroenergetskog sustava.
4) Rezultati pokazuju da predložene metode ukazuje na visoki stupanj točnosti, uz istovremeno otkrivanje kvarova.
5) Predložene metode su jako brze u odnosu na predloženi vremenski faktor zatezanja od strane standarda IEEE 1547 zbog visoke frekvencije uzorkovanja, male cijene proračuna kada je metoda online i male cijene prilagođenih IED-a koji se koriste kao mjerna oprema.

Nakon ovih spoznaja zaključuje se da su metode umjetne inteligencije korištene za detekciju otočnog rada i MPV algoritmi za otkrivanje kvarova prikladni i sposobni za otkrivanje otočnog rada distribuiranih izvora i otkrivanju kvarova.

METODA POTPORNIH VEKTORA (eng. SUPPORT VECTOR MACHINE-SVM) DETEKCIJA OTOČNOG RADA

		Distributivni napon u TZS-a																				
	[p.u.]	0,9	0,91	0,92	0,93	0,94	0,95	0,96	0,97	0,98	0,99	1,00	1,01	1,02	1,03	1,04	1,05	1,06	1,07	1,08	1,09	1,1
Generirana aktivna snaga	0.1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.1	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	0	0	1	1	1	1
	0.2	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1
	0.2	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.3	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.3	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.6	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.6	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.7	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.7	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.9	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.9	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.2	1	0	0	0	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1

DUBOKO UČENJE (eng. DEEP LEARNING -DL) DETEKCIJA OTOČNOG RADA

		Distributivni napon u TZS-a																				
	[p.u.]	0,9	0,91	0,92	0,93	0,94	0,95	0,96	0,97	0,98	0,99	1,00	1,01	1,02	1,03	1,04	1,05	1,06	1,07	1,08	1,09	1,1
Generirana aktivna snaga	0.1	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.1	0	0	0	0	0	1	1	1	1	1	1	1	1	1	0	0	0	0	0	1	1
	0.2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.3	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.3	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.6	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.6	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.7	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.7	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.9	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.9	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.1	1	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.1	1	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.2	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	1	1	0	0	1

ADAPTIVNI SUSTAV NEURO-NEIZRAVNOG ZAKLJUČIVANJA (eng. ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM-ANFIS) DETEKCIJA OTOČNOG RADA

		Distributivni napon u TZS-a																				
	[p.u.]	0,9	0,91	0,92	0,93	0,94	0,95	0,96	0,97	0,98	0,99	1,00	1,01	1,02	1,03	1,04	1,05	1,06	1,07	1,08	1,09	1,1
Generirana aktivna snaga	0.1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1
	0.1	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1
	0.2	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1
	0.2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.3	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.3	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.4	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.6	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.6	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.7	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.7	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.9	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	0.9	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.1	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.1	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1
	1.2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1

Slika 8.25. Usporedba zone ne detekcije za sve tri metode umjetne inteligencije za parametre proizveden aktivne snage i napona u točki zajedničkog spajanja.

Tablica 8.8. Sumarni rezultati zone ne detekcije za sve tri metode.

	Zona ne detekcije		
	ANFIS	**DL**	**MPV**
Neuspješna detekcija	73	37	46
Uspješnost [%]	84.88	92.33	90.47

Tablica 8.9. Usporedba vremena detekcije otočnog rada pri testiranju prema standardu IEEE 1547/UL 1741 za slučaj jednog distribuiranog izvora na distribucijskoj mreži-u.

	Vrijeme detektiranja otočnog rada		
	ANFIS	**DL**	**MPV**
Vrijeme [ms]	40	40	55

Prema slici 8.24 i Tablicama 8.8 i 8.9, jasno je vidljivo da prednost ima metoda DU. Iako su svi mjereni parametri mreže isti za sve tri predložene metode i samim time ulazni set podataka je isti, međutim nije isti blok podataka koji metode uzimaju kao ulaznu jedinicu. To znači da DU metoda ima jednu ulaznu jedinicu, a to je slika dok druge dvije metode imaju ulaz kreiran od niza brojeva dimenzije 8. Međutim, do konačnog izlaza se dolazi preko 7 pojedinačnih ANFIS i MPV kontrolora za svaki parametar posebno i onda opet na glavni ANFIS, koji prosuđuje o prisustvu otočnog rada i sustava glasanja kod MPV metode, gdje se mora čekati na svaki pojedinačni MPV kontrolor da se donese konačni izlaz. U ovom segmentu DU metoda prednjači, jer je vrijeme koje protekne od trenutka iniciranja otočnog rada do krajnjeg izlaza iz kontrolora je kraće zbog proračuna, koji se odrađuje unutar algoritma metode. DU metoda provlači samo jedan ulaz (sliku) kroz niz skrivenih slojeva konvolucijske neuronske mreže, čime ne upošljava nijedan drugi isti ili različit algoritam, i time daje izlaz jako brzo.

Međutim, DU metoda da bi radila efikasno kako je prikazano na slici usporedbe i tablicama, mora se potrošiti dodatno vrijeme i vrijeme pripreme ulaza za navedenu metodu. To znači da uspješnost

DU metode ovisi od pred-procesiranja izmjerenih veličina u točki zajedničkog spajanja u jedinstven paket spreman za analizu, tj. prebacivanje brojeva u jednu sliku.

Optimalno rješenje između navedenih metoda je teško pronaći zbog različitosti zadatka detekcije otočnog rada i zahtjeva koji su postavljeni pred metode. Svaki distribuirani izvor nije isti, iako im je način rada, pa čak i oprema koja se koristi ista. Međutim, generaliziranjem metoda, ne samo DL, može se postići prihvatljiv nivo optimizacije metode sa dodatnim smanjenjem preciznosti, brzine rada i zone ne detekcije. Ono što je potrebno imati na umu pri traženju optimalnog rješenja jeste da po svojoj prirodi, kognitivne metode umjetne inteligencije imaju veći nivo efikasnosti, ako se skup podataka za treniranje povećava sa što većim brojem različitih uzoraka. Time se povećava generalizacija metode, prepoznaju kritične situacije, te optimizira mehanizam proračuna metode umjetne inteligencije.

Time je jasan put budućeg pravca istraživanja autora ove disertacije a moguće i drugih. Uz uvođenje učenja on-line i mogućnosti primjene sporednog metoda umjetne inteligencije koji bi punio bazu znanja, može se postići da se metoda za detekciju otočnog rada ne mora prethodno trenirati, da bi bila efikasna za postavljeni cilj. Time se može zaključiti da budućnost metoda umjetne inteligencije u zaštitama elektroenergetskih sustava, pa čak i u energetici je tek počela i novi izazovi se svakodnevno otvaraju.

Redukcijom ulaznih parametara bi se dobilo na brzini, ali izgubilo na selektivnosti, a samim time povećala zone ne detekcije. Da bi se reducirao paket ulaznih informacija a zadržala efikasnost navedenih metoda, mora se pribjeći drugačijoj pripremi podataka sa mjesta mjerenja u slog ulaznih podataka. Buduće istraživanje će biti usmjereno na uvođenju dodatnih algebarskih alata, koji se mogu koristiti za dekompresiju podataka sa manje mjerenih veličina, u isti slog informacija za metodu umjetne inteligencije. Time se dobije na vremenu proračuna, jer bi se reducirao broj ulaznih parametara, a zadržala zone ne detekcije kakva jeste, jer je kvaliteta ulaznog sloga ostala ista.

9. ZAKLJUČAK

Integracija metoda umjetne inteligencije u sustav zaštite od otočnog rada ne zahtjeva veliku promjenu postojećih pravila i metoda, pri čemu je presudno brzo, precizno i nedvojbeno odrediti status distribuiranog izvora energije u mreži. Temeljna pretpostavka ovog znanstveno-istraživačkog rada je visoka primjenjivost naprednih metoda umjetne inteligencije za područje detekcije otočnog rada distribuiranog izvora, u budućoj aktivnoj distributivnoj mreži. Provjera navedene pretpostavke ostvarena je sa tri algoritma umjetne inteligencije kognitivnog tipa, s ciljem neagresivnog pristupa prikupljanju podataka sa točke zajedničkog spajanja, tj. zadržavanje pasivne prirode metode, a u cilju značajnog smanjenja vremena detekcije, povećanjem preciznosti i smanjenjem zone ne detekcije.

Krajnji rezultat znanstveno-istraživačkog rada ove doktorske disertacije su tri testirana algoritma detekcije otočnog rada, koji sadrži tri funkcionalne cjeline, međusobno povezane u jedinstven proces.

Prva cjelina je primjer mjerenja ulaznih parametara u točki zajedničkog spajanja, te pakiranje dobivenih informacija u jedinstven slog podataka, a realizirano je modeliranjem elektroničkog uređaja od strane autora, koji mjeri potrebne veličine u točki zajedničkog spajanja distribuiranog izvora i distribucijske mreže. Model pametnog brojila zasniva se na komponentama koje se mogu nabaviti bez većih ulaganja, te samo brojilo sastaviti uz određeno prethodno znanje. Podaci koji su snimljeni se koriste za modeliranje okruženja za testiranje metoda u programskom paketu MATLAB/Simulink, zadržavajući sve parametre distribuiranog izvora koji su izmjereni. Rezultati prve cjeline predstavljaju dio ulaznih podataka druge cjeline.

Druga cjelina algoritma je jedinstveno modeliranje sloga podataka i treniranje metoda umjetne inteligencije. Naime, znanstveno istraživanje doktorske disertacije započelo je primjenom izmjerenih podataka na jednu od metoda, to je ANFIS, te na osnovu dobivenih rezultata se nastavilo dalje sa naprednim metodama, ali zadržavajući isti slog ulaznih podataka. Uspješna primjena navedenog algoritma u detekciji otočnog rada distribuiranog izvora, popraćena objavom znanstvenih radova iz rezultata navedenog istraživanja, postavila je smjer daljnjeg razvoja i primjene metodologije rješavanja detekcije pojave otočnog rada na mikro mreži. Međutim, operatori karakteristični za pravilno izvođenje ANFIS-a, značajno utječu na njegovu primjenu u predloženoj metodologiji detekcije otočnog rada. Proučavanjem znanstvene literature, istraživanje je usmjereno ka primjeni mjerenih podataka na druge metode umjetne inteligencije, koje su svojim parametrima obećavale bolje rezultate, s ciljem isticanja primjenjivosti u detekciji otočnog rada.

Nove metode umjetne inteligencije, koje su usvojene, u daljnjem istraživanju su pokazale veliku fleksibilnost i jedinstvenost pri treniranju, a samim time i drugačiji pristup kada je u pitanju rješavanje problema otočnog rada.

Treća cjelina je proistekla iz rezultata testiranja. Rezultati dobiveni pomoću drugih metoda umjetne inteligencije su zahtijevali standardizaciju i kategoriziranje rezultata, što je sa sobom zahtijevalo dodatni uvid u dostupnu literaturu, s ciljem pronalaska standarda i protokola ispitivanja metoda detekcije otočnog rada. Cilj je dodatno promatran iz perspektive zadržavanja pasivne prirode metodologije, što omogućava korištenje u svakoj situaciji, ali također zahtjeva potrebnu vještinu treniranja predloženih metoda s ciljem smanjenja zone ne detekcije, povećanja preciznosti i smanjenja vremena detekcije otočnog rada. Navedene provjere su obavljene sukladno standardima IEEE 1547/ UL 1741, te su rezultati objavljeni u znanstvenim časopisima IEEE kategorizacije, čime se dobila potvrda ispravnosti ovih istraživanja.

Navedene metode korištene u detekciji otočnog rada su otvorile nova poglavlja u istraživanju autoru disertacije i time otvorila nova pitanja koja će biti tema budućih istraživanja. Ocjena prihvatljivosti ponuđenih optimalnih rješenja je brojčana vrijednosti nastala kao rezultat testiranja navedena u poglavlju 7, a sažeta u poglavlju 8. Konačno, brojčana vrijednosti ocjene metode korištena je kao usporedba i dio konačne ocjene pojedinih metoda. Konačno, uspješnom primjenom metoda na modelu realnog foto naponskog sustava, potvrđene su temeljne pretpostavke znanstvenog istraživanja ove disertacije

10. LITERATURA

[1] Karan Sareen, Bhavesh R. Bhalja, Rudra Prakash Maheshwari. “A Hybrid Multi-feature based Islanding Detection Technique for Grid Connected Distributed Generation”, International Journal of Emerging Electric Power Systems. 2016; 20160042, DOI: /10.1515/ijeeps-2016-0042.

[2] Fabio Bignucolo, Antonino Raciti, Roberto Caldon. “Coordinating active and reactive energy balances in islanded networks supported by renewables and BESS”, 3rd Renewable Power Generation Conference (RPG™), September 2014, DOI 10.1049/cp.2014.0822

[3] Hesan Vahedi, Mehdi Karrari. “Adaptive Fuzzy Sandia Frequency-Shift Method for Islanding Protection of inverter-Based Distributed Generation”, IEEE Transactions on Power Delivery, January 2013, DOI: 10.1109/TPWRD.2012.2219628.

[4] Mahdiyeh Khodaparastan, Hesan Vahedi, Farid Khazaeli. “A novel hybrid islanding detection method for inverter-based DGs using SFS and ROCOF”, IEEE Transactions on Power Delivery, February 2015, DOI: 10.1109/TPWRD.2015.2406577.

[5] Hesan Vahedi, Gevork B. Gharehpetian, Mehdi Karrari. “Application of Duffing Oscillators for Passive Islanding Detection of Inverter-Based Distributed Generation Units”, IEEE Transactions on Power Delivery, October 2012, DOI: 10.1109/TPWRD.2012.2212251.

[6] H.H. Zeineldin, S. Kennedy. “Sandia Frequency Shift Parameter Selection to Eliminate Non-Detection Zones”, IEEE Transactions on Power Delivery 24(1):486 – 487, February 2009, DOI 10.1109/TPWRD.2008.2005362.

[7] Abbineni Sai Subhadra, P.Linga Reddy, Shailesh B. Modi. “Islanding Detection in a Distribution System with Modified DG Interface Controller “, International Journal of Applied Power Engineering (IJAPE), Vol.6, No.3, December 2017, pp. 135~143, DOI: 10.11591/ijape.v6i3.pp135-143.

[8] Rahul Somalwar, Sumant Kadwane, Dusmanta Kumar Mohanta. “Harmonics-Based Enhanced Passive Islanding Method for Grid-Connected System”, Electric Power Components and Systems, December 2017, DOI 10.1080/15325008.2017.1361485.

[9] Abbineni Subhadra, P.Linga Reddy, Shailesh B.Modi. “Islanding Detection in a Distribution System with Photovoltaic (FN) System as Distributed Generation”, Indian Journal of Science and Technology, November 2015, DOI 10.17485/ijst/2015/v8i27/71874.

[10] Yeong-Min Jo, Ju-Yeop Choi, Seung-Ho Song, Ick Choy, Young-Kwoun Lee. "Detection Performance and THD Analysis of Active Frequency Drift for Anti-Islanding", Journal of the Korean Solar Energy Society, Volume 35, Issue 2, 2015, pp.11-19, DOI : 10.7836/kses.2015.35.2.011.

[11] Hesan Vahedi, Mehdi Karrari, Gevork B. Gharehpetian. "Accurate SFS Parameter Design Criterion for Izmjenjivač-Based Distributed Generation", IEEE Transactions on Power Delivery, January 2015, DOI: 10.1109/TPWRD.2015.2391193.

[12] Xiaoying Zhang, Bin Wang, Kun Wang, Labao Zhang. "Probability assessment for power system voltage stability margin with renewable energy source using slice sampling", International Transactions on Electrical Energy Systems 27(2):e2366, September 2017, DOI 10.1002/etep.2366.

[13] Dibyendu Dana, Satishkumar Gadhiya, Luce G. St. Surin, David Li, Farha Naaz, Quaisar Ali, Latha Paka, Michael A. Yamin, Mahesh Narayan, Itzhak Goldberg, Prakash Narayan. „Deep Learning in Drug Discovery and Medicine; Scratching the Surface", September 2018, Molecules 23(9):2384, DOI:10.3390/molecules23092384

[14] Ahmed M. Abed, Muzhir Al-Ani. „Analysis and classification of brain signals using DWT and MPV", May 2018 Journal of Theoretical and Applied Information Technology 96(10):2989-3001

[15] Dale Williston, Dale Finney." Consequences of Out-of-Phase Reclosing on Feeders With Distributed Generators", SEL Journal of Reliable Power, Volume 3, Number 1, Mart 2012

[16] Ye, Z., Walling, R., Garces, L., Zhou, R., Li, L., Wang, T. „Study and Development of Anti-Islanding Control for Grid-Connected Izmjenjivačs", United States: N. p., 2004. Web. doi:10.2172/15007704.

[17] IEEE Std. 1547-2003, "IEEE Standard for Interconnecting Distributed Resources with Electric Power Systems", IEEE Standards Coordinating Committee 21, srpanj 2003.

[18] Hajir Pourbabak, Ahad Kazemi. „A new technique for islanding detection using voltage phase angle of izmjenjivač-based DGs", International Journal of Electrical Power & Energy Systems, Volume 57, svibanj 2014, str. 198-205, doi.org/10.1016/j.ijepes.2013.12.008

[19] John Mulhausen, Joe Schaefer, Mangapathirao Mynam, Armando Guzmán, Marcos Donolo. „Anti-islanding today, successful islanding in the future“, 2010 63rd Annual Conference for Protective Relay Engineers, 20 Svibanj 2010, DOI: 10.1109/CPRE.2010.5469490

[20] Sung-Il Jang, Kwang-Ho Kim.“ An Islanding Detection Method for Distributed Generations Using Voltage Unbalance and Total Harmonic Distortion of Current“, IEEE Transactions on Power Delivery 19(2):745 – 752, May 2004, DOI: 10.1109/TPWRD.2003.822964

[21] M. R. Alam, K. M. Muttaqi, A. Bouzerdoum. „A Multifeature-Based Approach for Islanding Detection of Diistrubuted Generation in the Subcritical Region of Vector Surge Relays“, IEEE Transactions on Power Delivery, vol. 29, No. 5, Listopad 2014, DOI: 10.1109/TPWRD.2014.2315839

[22] D. Bejmert and T. S. Sidhu. „Investigation Into Islanding Detection With Capacitor Insertion-Based Method“, IEEE Transactions On Power Delivery, Vol. 29, No. 6, Prosinac 2014, DOI:10.1109/TPWRD.2014.2347032

[23] S. A. Saleh, A. S. Aljankawey, Ryan Meng, J. Meng, L. Chang, C. P. Diduch.“ Apparent Power-Based Anti-Islanding Protection for Distributed Cogeneration Systems“, IEEE Transactions On Industry Applications, Vol. 52, No. 1, Siječanj 2016, DOI: 10.1109/TIA.2015.2464307

[24] Daniel Motter, Fabricio A. Mourinho i José Carlos M. Vieira.“ Impact of Load Variation on the Synchronous Distributed Generation Frequency-based Anti-Islanding Protection“, 2015 IEEE Power & Energy Society General Meeting, Listopad 2015, DOI: 10.1109/PESGM.2015.7286287

[25] Ontrei Raipala, Sami Repo, Pertti Järventausta.“ Performance Analysis of Q-f droop Anti-Islanding Protection in the Presence of Mixed Types of Distribution Generation“, 2015 IEEE Innovative Smart Grid Technologies - Asia (ISGT ASIA), Siječanj 2016, DOI: 10.1109/ISGT-Asia.2015.7387060

[26] S. Khanbabapour, M. E. Hamedani Golshan.“ Synchronous Distribution Generation Planning for Simultaneous Improvement of Technical, Overcurrent, and Timely Anti-Islanding Protection Indices of the Network to Preserve Protection Coordination“, IEEE Transactions on Power Delivery, Vol. 32 , izdanje 1 , veljača 2017, DOI: 10.1109/TPWRD.2016.2538799

[27] Ontrei Raipala, Anssi Mäkinen, Sami Repo, Pertti Järventausta.“ An Anti-Islanding Protection Method Based on Reactive Power Injection and ROCOF“, IEEE Transactions on Power Delivery, Vol. 32 , izdanje 1 , veljača 2017, DOI: 10.1109/TPWRD.2016.2543503

[28] Ali M. Tayebi, M. Akhbari. „A Comparison between Frequency Relays and Vector Surge Relays for Synchronous Distribution Generation Anti-islanding Protection“, Eurocon 2013, Zagreb, Croatia, lipanj 2013, DOI: 10.1109/EUROCON.2013.6625059

[29] J.C.M. Vieira, W. Freitas, Wilsun Xu, A. Morelato. “Performance of Frequency Relays for Distributed Generation Protection”, IEEE Transaction on Power Delivery, vol. 21, br. 3, lipanj 2006, DOI: 10.1109/TPWRD.2005.858751

[30] Walmir Freitas, Wilsun Xu, Carolina M. Affonso i Zhenyu Huang.“ Comparative Analysis Between ROCOF and Vector Surge Relays for Distributed Generation Applications“, IEEE Transactions on Power Delivery , Vol. 20 , izdanje 2 , travanj 2005, DOI: 10.1109/TPWRD.2004.834869

[31] Bohan Liu, David Thomas, Ke Jia i Malcolm Woolfson.“ Advanced ROCOF Protection Of Synchronous Generator“, ISGT 2011, travanj 2011, DOI: 10.1109/ISGT.2011.5759125

[32] CF. Ten, PA Crossley, "Evaluation of Rocof Relay Performances on Networks with Distributed Generation", Developments in Power System Protection, stranice 523-528, svibanj 2008, DOI: 10.1049/cp:20080092

[33] A. Adrianti i A. Dyśko. „Risk assessment analysis to find optimum ROCOF protection settings“, 12th IET International Conference on Developments in Power System Protection (DPSP 2014), travanj 2014, DOI: 10.1049/cp.2014.0134.

[34] J. Stevens, R. Bonn, J. Ginn, i S. Gonzalez. „Development and testing of an approach to anti-islanding in utility-interconnected photovoltaic systems“, Technical Report SAND 2000-1939, Photovoltaic System Applications Department Sandia National Laboratories, 2000.

[35] D. P. Buse i Q. H. Wu. „IP Network-based Multi-agent Systems for Industrial Automation“ ISBN: 9781846286469. Springer London, 2007.

[36] J. M. Solanki, S. Khushalani, and N. N. Schulz. „A multi-agent solution to distribution systems restoration“ IEEE Transactions on Power Delivery, 22(3):1026–1034, listopad 2007.

[37] C. Ma, Z. Lu, W. H. Tang, Q. H. Wu, i J. Fitch.“ An agent brokering-based scheme for anti-islanding protection of distributed generation“, 2009 IEEE Power & Energy Society General Meeting, listopad 2009, DOI: 10.1109/PES.2009.5275632

[38] Xiao Li, Robert Balog.“ Analysis and comparison of two active antiislanding detection methods“, Midwest Symposium On Circuits And Systems, listopad 2014, DOI: 10.1109/MWSCAS.2014.6908447

[39] Yiding Jin, Qiang Song, Wenhua Liu.“ Anti-islanding Protection for Distributed Generation Systems Based on Reactive Power Drift“, 2009 35th Annual Conference of IEEE Industrial Electronics, studeni 2009, DOI: 10.1109/IECON.2009.5415331

[40] Yongli Li, Shengwei Li, Shibin Bai, Chongxuan Niu.“ Frequency-feedback based islanding detection algorithm for micro-grid“, Transactions of Tianjin University, vol. 14, izdanje 2, str. 85–91, https://doi.org/10.1007/s12209-008-0016-8

[41] Hajir Pourbabak, Ahad Kazemi.“ Improving voltage shift acceleration control methods for islanding detection considering reactive power“, 2013 Smart Grid Conference (SGC), prosinac 2013, DOI: 10.1109/SGC.2013.6733815

[42] Vaibhav Sule, Alexis Kwasinski.“ Active Anti-Islanding Method Based on Harmonic Content Detection from Overmodulating Izmjenjivačs“, 2011 Twenty-Sixth Annual IEEE Applied Power Electronics Conference and Exposition (APEC), ožujak 2011, DOI: 10.1109/APEC.2011.5744663

[43] M. Bakhshi, Reza Noroozian i G.B. Gharehpertian.“ Passive anti-islanding scheme based on reactive power in the smart grids“, Smart Grids (ICSG), 2012 2nd Iranian Conference, siječanj 2012

[44] Diogo Salles, Walmir Freitas, Jose C. M. Vieira i Wilsun Xu.“ Nondetection Index of Anti-Islanding Passive Protection of Synchronous Distributed Generators“, IEEE Transactions on Power Delivery (vol.: 27 , izdanje: 3 , lipanj 2012), DOI: 10.1109/TPWRD.2012.2190624

[45] Amin Helmzadeh, Javad Sadeh i Omid Alizadeh Musavi.“ Anti-Islanding Protection of Distributed Generation Resources Using Negative Sequence Component of Voltage“, 2007 International Conference on Power Engineering, Energy and Electrical Drives, travanj 2007, DOI: 10.1109/POWERENG.2007.4380097

[46] Mohsen Bakhshi, Reza Noroozian i G. B. Gharehpetian.“ Anti-Islanding Scheme for Synchronous Distribution Generation Units Based on Tufts–Kumaresan Signal Estimation Method“, IEEE Transactions on Power Delivery (vol.: 28 , izdanje: 4 , listopad 2013), DOI: 10.1109/TPWRD.2013.2271837

[47] Karan Sareen, Bhavesh R. Bhalja, Rudra Prakash Maheshwari.“ A Hybrid Multi-feature based Islanding Detection Technique for Grid Connected Distributed Generation“, International Journal of Emerging Electric Power Systems, vol. 18, izdanje 1, 24.01.2017.g., DOI: https://doi.org/10.1515/ijeeps-2016-0042

[48] M. Bakhshi, R. Noroozian i G. B. Gharehpetian.“ Islanding Detection of Synchronous Machine-Based DGs using Average Frequency Based Index“, Iranian Journal of Electrical and Electronic Engineering 9(2):94-106, lipanj 2013

[49] Abdghani Rasli, Mohamed Azah i Shareef Hussain. „A Sugeno-Type ANFIS Approach for Fast and Accurate Fault Diagnosis in a Distribution System 1“ , Australian Journal of Basic and Applied Sciences. 5. 128-138. rujan 2011

[50] Kamel Tamer, Moustafa Hassan Mohamed i El Morshedy Ahdab. „Advanced distance protection technique based on multiple classified ANFIS considering different loading conditions for long transmission lines in EPS“, International Journal of Modelling, Identification and Control. Vol. 16, br. 2, pp.108–121. listopad 2012, DOI:108-121. 10.1504/IJMIC.2012.047119

[51] Baxevanos I.S. i Labridis Dimitris. „20 KV power distribution grid protection: A multi-agent architecture for decentralized operation schemes“, lipanj 2005, IEEE Russia Power Tech, PowerTech, DOI:10.1109/PTC.2005.4524603.

[52] Hadi Abdulwahid Ali i Wang Shaorong. „A Novel Approach for Microgrid Protection Based upon Combined ANFIS and Hilbert Space-Based Power Setting“, Energies, prosinac 2016. 9. 1042. DOI:10.3390/en9121042.

[53] Azriyenni Azriyenni, Mohd Wazir Mustafa.“ Application of ANFIS for Distance Relay Protection in Transmission Line“, International Journal of Electrical and Computer Engineering (IJECE), Vol 5, br. 6, prosinac 2015, DOI: http://doi.org/10.11591/ijece.v5i6.pp1311-1318

[54]Mohamed A. Ali, Sayed A. Ward, Mohamed S. Elkhalafy. „Smart Busbar Protection Based ANFIS Technique for Substations and Power Plants“, International Electrical Engineering Journal (IEEJ), Vol. 7 (2016) Br.8, pp. 2331-2338, ISSN 2078-2365

[55] W. Yuill, R. Kgokong, S. Chowdhury, S.P. Chowdhury. „Application of Adaptive Neuro Fuzzy Inference System (ANFIS) based short term load forecasting in South African power networks“, 45th International Universities Power Engineering Conference UPEC2010, Rujan 2010, INSPEC: 11679109.

[56] Sivakoti, Karthik. „Load Prediction in Smart Grid Networks“, International Journal of Computing and Digital Systems. 2015, Vol. 4. Stranice 245-250. DOI:10.12785/ijcds/040403.

[57] Lal Avisekh, Kumar Ravitesh, Mehta Utkal i Vachkov Gancho. „Fuzzy energy distribution to a variable consumer load“, The South Pacific Journal of Natural and Applied Sciences. , 2015 Vol.32. stranice 37-42. DOI:10.1071/SP14006.

[58] Fayaz Muhammad i Kim DoHyeun. „A Prediction Methodology of Energy Consumption Based on Deep Extreme Learning Machine and Comparative Analysis in Residential Buildings“, Electronics, 2018. Vol.7. str. DOI:222. 10.3390/electronics7100222.

[59] Khalid Rabiya, Javaid Nadeem, Rahim Muhammad, Aslam Sheraz i Sher Arshad. „Fuzzy Energy Management Controller and Scheduler for Smart Homes“. Sustainable Computing: Informatics and Systems. Studeni 2018, DOI:21. 10.1016/j.suscom.2018.11.010.

[60] Farhat Mayssa i Lassâad Sbita.“ Advanced ANFIS-MPPT control algorithm for sunshine photovoltaic pumping systems“, 2012 First International Conference on Renewable Energies and Vehicular Technology, svibanj 2012, DOI: 10.1109/REVET.2012.6195265

[61] Ammar Hussain Mutlag, Azah Mohamed, Hussain Shareef.“ A comparative study of artificial intelligent-based maximum power point tracking for photovoltaic systems“, International Conference on Advances in Renewable Energy and Technologies (ICARET 2016), IOP Conf. Series: Earth and Environmental Science 32 (2016) 012014, travanj 2016, DOI:10.1088/1755-1315/32/1/012014

[62] Pulkit Singh, Rajendra Singh.“ A Comparative Study of ANFIS Based MPPT Techniques“, SSRG International Journal of Electrical and Electronics Engineering (SSRG-IJEEE) – Vol. 3 , br.5 svibanj 2016, ISSN: 2348 – 8379

[63] Saravana Selvan, Pratap Nair i Umayal.“ A Review on Photo Voltaic MPPT Algorithms“, International Journal of Electrical and Computer Engineering (IJECE), Vol. 6, br. 2, travanj 2016, str. 567-582, ISSN: 2088-8708, DOI: 10.11591/ijece.v6i2.9204

[64] Yahyaoui Imene, Chaabene Maher i Tadeo Fernando. „Fuzzy Energy Management for Photovoltaic Water Pumping System“, International Journal of Computer Applications. Vol. 110. Str.29-36. DOI:10.5120/19346-1049.

[65] YANG Jibin, ZHANG Jiye, i SONG Pengyun.“ Fuzzy Energy Management for a Catenary-Battery-Ultracapacitor based Hybrid Tramway“, 2017 2nd Asia Conference on Power and Electrical Engineering (ACPEE 2017), IOP Conf. Series: Materials Science and Engineering 199 (2017) 012140, DOI:10.1088/1757-899X/199/1/012140

[66] Abduladhem A. Ali i Taqwa Odey Fahad. „Fuzzy Energy based Routing Protocol for MANET“, International Journal of Computer Applications 46(1):38-40, svibanj 2012, DOI: 10.5120/6875-8988

[67] Qi Song, Lingfeng Hu, Chenghong Li i Guanzheng Wen.“Neural Network Energy Management Strategy for Series Hybrid Electric Car“, Universe Scientific Publishing, Vol 4, br. 1, 2017, DOI: http://dx.doi.org/10.18686/esta.v4i1.37

[68] Pliego Marugán Alberto, García Márquez Fausto Pedro, Pinar Pérez Jesús María i Ruiz-Hernández Diego. „A survey of artificial neural network in wind energy systems“. Applied Energy. 228. 1822-1836. Listopad 2018, DOI: 10.1016/j.apenergy.2018.07.084.

[69] Mohamed Abdel-Nasser, Karar Mahmoud, Heba Kashef. „A Novel Smart Grid State Estimation Method Based on Neural Networks“, International Journal of Interactive Multimedia and Artificial Intelligence, (2018), DOI: http://dx.doi.org/10.9781/ijimai.2018.01.004

[70] Bipul Luitel, Ganesh K. Venayagamoorthy. „Wide area monitoring in power systems using cellular neural networks“, 2011 IEEE Symposium on Computational Intelligence Applications In Smart Grid (CIASG), Travanj 2011, DOI: 10.1109/CIASG.2011.5953343

[71] He Youbiao, Mendis Gihan i Wei Jin. „Real-Time Detection of False Data Injection Attacks in Smart Grid: A Deep Learning-Based Intelligent Mechanism“. IEEE Transactions on Smart Grid. PP. 1-1. Svibanj 2011, DOI:10.1109/TSG.2017.2703842.

[72] Abbas Mardani, Dalia Streimikiene, Mehrbakhsh Nilashi, Daniel Arias Aranda, Nanthakumar Loganathan, i Ahmad Jusoh.“ Energy Consumption, Economic Growth, and CO2 Emissions in G20 Countries: Application of Adaptive Neuro-Fuzzy Inference System“, Energies 2018, vol. 11, br. 2771; DOI:10.3390/en11102771

[73] Iman Almomani, Maha Saadeh.“ S-FEAR: Secure-Fuzzy Energy Aware Routing Protocol for Wireless Sensor Networks“, KSII Transactions On Internet And Information Systems Vol. 12, br. 4, travanj 2018, http://doi.org/10.3837/tiis.2018.04.003

[74] Shaun K. Howell , Hendro Wicaksono, Baris Yuce , Kris McGlinn i Yacine Rezgui.“ User Centered Neuro-Fuzzy Energy Management Through Semantic-Based Optimization“, IEEE Transactions On Cybernetics, svibanj 2018, DOI: 10.1109/TCYB.2018.2839700

[75] Ali Shemshadi, Hossein Shirazi, Mehran Toreihi, M.J. Tarokh.“ A fuzzy VIKOR method for supplier selection based on entropy measure for objective weighting“, Expert Systems with Applications, listopad 2011, DOI: 10.1016/j.eswa.2011.03.027

[76] Mohammad Hossein Fazel Zarandi, Milad Avazbeigi, Mohammad Hassan Anssari i Behnam Ganji.“ A Multi-Agent Expert System for Steel Grade Classification Using Adaptive Neuro-fuzzy Systems“, Expert Systems, ISBN 978-953-307-032-2, pp. 238, siječanj 2010, INTECH, DOI: 10.5772/7077

[77] Pedro Ponce, Arturo Molina, Israel Cayetano, Jose Gallardo, Hugo Salcedo, Jose Rodriguez.“ Experimental Fuzzy Logic Controller Type 2 for a Quadrotor Optimized by ANFIS“, Information Control Problems in Manufacturing (INCOM), svibanj, 2015. https://doi.org/10.1016/j.ifacol.2015.06.453

[78] Omar N. Faqhruldin, Ehab F. El-Saadany, i Hatem H. Zeineldin.“ A Universal Islanding Detection Technique for Distributed Generation Using Pattern Recognition“, IEEE Transactions On Smart Grid, Vol. 5, br. 4, lipanj 2014, DOI: 10.1109/TSG.2014.2302439

[79] V. L. Merlin, R. C. Santos, A. P. Grilo, J. C. M. Vieira, D. V. Coury i M.Oleskovicz.“ A new artificial neural network based method for islanding detection of distributed generators“, International Journal of Electrical Power & Energy Systems, vol. 75, str. 139-151, veljača 2016, DOI: 10.1016/j.ijepes.2015.08.016

[80] Basanta K. Panigrahi, Prakash K. Ray, Pravat K. Rout, Asit Mohanty, Dillip K. Mishra i Sibapriya Mohapatra.“ Advanced Signal Processing and Soft Computing Techniques Based Islanding Detection: A Review“, International Journal of Control Theory and Applications, ISSN: 0974-5572, vol.10, br. 6, lipanj 2017,

[81] Rosolowski, Eugeniusz, Arkadiusz Burek and Leszek Jedut. “A New Method for Islanding Detection in Distributed Generation”, Wroclaw University of Technology, Poljska, 2007.

[82] Himanshu Jyoti Saikia.“ Development of a Passive Islanding Detection Method based Fuzzy Controller for a Grid Connected Distributed Generator“, International Journal of Engineering Research & Technology (IJERT), ISSN:2278:0181, vol.5, br.12, prosinac 2016, DOI: IJERTV5IS120242

[83] Haidar Samet, Farid Hashemi i Teymoor Ghanbari.“ Minimum non detection zone for islanding detection using an optimal Artificial Neural Network algorithm based on PSO“, Renewable and Sustainable Energy Reviews , prosinac 2015, DOI: 10.1016/j.rser.2015.07.080

[84] Fuangfoo P., Meenual T., Lee W. I Chompooinwai C.. „PEA guidelines for impact study and operation of distribution generation for islanding operation“, IEEETransactions on industry applications, vol. 44, br.5, svibanj 2008.

[85] Dewadasa M., Ghosh A. I Ledwich G.. „Protection of distributed generation connected networks with coordination of overcurrent relays“, ECON2011–37th Annual Conference on IEEE Industrial Electronics Society, Queensland University of Technology, Australia, 2011.

[86] Fuangfoo P., Lee W. I Nigim K.. „Intentional islanding operation to improve the service reliability of Thailand electric power system“, IEEE Power Engineering Society General Meeting, 2007.

[87] Funmilayo H., Silva J. i Butler-Purry K.. „Overcurrent protection for the IEEE 34-Node radial test feeder“, IEEE Transactions on Power Delivery, vol. 27, br. 2, 2012.

[88] Alejandro Pedraza, David Reyes i Carlos Gómez.“ Islanding operation’s effects of distributed generation on distribution networks“, Revista Tecnura, 19 (CITIE), 145-150. DOI:http://dx.doi.org/10.14483/udistrital.jour.tecnura. srpanj 2015.

[89] Mohamad H., Mazaher H. I Abu Bakar A.. „Feasibility study of an intentional islanding operation with a new adaptive load shedding“, 3rd International Conference on Electric Power and Energy Conversion Systems,Istanbul: Turkey

[90] Walling R. i Miller N.. „Distributed generation islanding implications on power system dynamic performance“, Power Engineering Society Summer Meeting, IEEE, vol.3, 2002

[91] European Committee for Electrotechnical Standardization. Requirements for Generating Plants to Be Connected in Parallel with Distribution Networks—Part 1: Connection to a LV

Distribution Network above 16 A; Technical Specification CENELEC TS 50549-1; European Committee for Electrotechnical Standardization (CENELEC):Brussels, Belgium, 2015.

[92] European Committee for Electrotechnical Standardization. Requirements for Generating Plants to Be Connected in Parallel with Distribution Networks–Part 2: Connection to a MV Distribution System; Technical Specification CENELEC TS 50549-2; CENELEC: Brussels, Belgium, 2015.

[93] European Committee for Electrotechnical Standardization. Requirements for Micro-Generating Plants to Be Connected in Parallel with Public Low-Voltage Distribution Networks; European Standard CENELEC EN 50438; CENELEC: Brussels, Belgium, 2013.

[94] Comitato Elettrotecnico Italiano. Reference Technical Rules for the Connection of Active and Passive Consumers to the HV and MV Electrical Networks of Distribution Company; CEI 0-16; CEI: Milan, Italy, 2016.

[95] Comitato Elettrotecnico Italiano. Reference Technical Rules for the Connection of Active and Passive Users to the LV Electrical Utilities; CEI 0-21; CEI: Milan, Italy, 2016.

[96] Hou X., Sun Y., Yuan W., Han H., Zhong C., Guerrero J.M. „Conventional P-ω/Q-V droop control in highly resistive line of low-voltage converter-based ac microgrid“. Energies 2016, 9, 943.

[97] Blazic B., Papic I. „Voltage profile support in distribution networks—Influence of the network R/X ratio“, In Proceedings of the 13th Power Electronics and Motion Control (EPE-PEMC) Conference, Poznan, Poland, 1–3 September 2008; pp. 2510–2515.

[98] Caldon R., Coppo M., Turri R. „Voltage unbalance compensation in LV networks with izmjenjivač interfaced distributed energy resources“ In Proceedings of the IEEE International Energy Conference and Exhibition (ENERGYCON), Florence, Italy, 9–12 September 2012; pp. 527–532.

[99] Fabio Bignucolo, Alberto Cerretti, Massimiliano Coppo, Andrea Savio i Roberto Turri.“ Impact of Distributed Generation Grid Code Requirements on Islanding Detection in LV Networks“, Energies, siječanj 2017, 10, 156; DOI:10.3390/en10020156

[100] Bignucolo F., Caldon R., Frigo M., Morini A., Pitto A., Silvestro F. „Impact of distributed generation on network security: Effects on loss-of-main protection reliability“. In Proceedings of the Universities Power Engineering Conference (UPEC), Padova, Italy, 1–4 September 2008.

[101] Pukar Mahat, Zhe Chen i Birgitte Bak-Jensen.“ Review on Islanding Operation of Distribution System with Distributed Generation“, 2011 IEEE Power and Energy Society General Meeting, srpanj 2011, DOI: 10.1109/PES.2011.6039299

[102] T. W. Eberly i R. C. Schaefer, “Voltage versus VAr/power-factor regulation on synchronous generators,” IEEE Trans. Ind. Appl., vol. 38, br. 6, str. 1682-1686, 2002.

[103] J. D. Hurley, L. N. Bize i C. R. Mummert, “The adverse effects of excitation system VAr and power factor controllers,” IEEE Trans. Energy Convers., vol. 14, br. 4, str. 1636-1641, prosinac 1999.

[104] J. Selvaraj i N. A. Rahim, “Multilevel izmjenjivač for grid-connected PV system employing digital PI controller,” IEEE Trans. Ind. Electron., vol.56, str. 149-158, siječanj 2009.

[105] J. M. Espi Huerta. "A synchronous reference frame robust predictive current control for three-phase grid-connected izmjenjivačs," IEEE Trans. Ind. Electron., vol. 57, str. 954-962, ožujak 2010.

[106] H. Zeineldin, M. I. Marei, E. F. El-Saadany i M. M. A. Salama, “Safe controlled islanding of izmjenjivač based distributed generation,” IEEE Power Electron. Specialists Conf., Aachen, Germany, vol. 4, lipanj 2004,str. 2515-2520.

[107]T. C. Green and M. Prodanovic, “Control of izmjenjivač-based microgrids,”Electr. Power Syst. Res., vol. 77, str. 1204-1213, lipanj 2007.

[108] P. Mahat, Z. Chen and B. Bak-Jensen, “Control strategies for gas turbine generators for grid connected and islanding operations,” in IEEE PESTransmission and Distribution Conf. and Exposition, New Orleans, LA,USA, Apr. 2010.

[109] M. Bollen, J. Zhong, O. Samuelsson, and J. Björnstedt. “Performance indicators for microgrids during grid-connected and island operation,” in IEEE Bucharest Power Tech Conf., Bucharest, Romania, lipanj 2009.

[110] Eltawil, M. A., & Zhao, Z. „Grid-connected photovoltaic power systems: Technical and potential problems—A review“, Renew Sust. Energ Rev, 14(1), 112–129, studeni 2010.

[111] Soham Dutta, Pradip Kumar Sadhu, M. Jaya Bharata Reddy i Dusmanta Kumar Mohanta.“ Shifting of research trends in islanding detection method - a comprehensive survey“, Dutta et al. Protection and Control of Modern Power Systems, 2018, DOI :10.1186/s41601-017-0075-8

[112] De Mango F., Liserre M., Dell'Aquila A., i Pigazo A. „Overview of antiislanding algorithms for PV systems, Part I: Passive methods“, In power electronics and motion control conference, 2006. EPE-PEMC 2006. 12th international (str. 1878–1883). Piscataway: IEEE.

[113] Vachtsevanos, G. J., & Kang, H. „Simulation studies of islanded behavior of grid-connected photovoltaic systems“. IEEE Transactions on Energy Conversion, 1989, vol. 4, br.2, str. 177–183.

[114] Ahmad K. N. E. K., Selvaraj J. i Rahim N. A. „A review of the islanding detection methods in grid-connected PV izmjenjivačs“, Renew Sust Energ Rev, vol.21, str. 756–766.

[115] Ye Z., Kolwalkar A., Zhang Y., Du P. i Walling R. „Evaluation of antiislanding schemes based on nondetection zone concept“, IEEE Trans Power Electron, 2004, vol.19, br.5, str. 1171–1176.

[116] Vieira J. C., Salles D. i Freitas W. „Power imbalance application region method for distributed synchronous generator anti-islanding protection design and evaluation“, Electr Power Syst Res, 2011, vol.81, br.10, str. 1952–1960.

[117] Adrian Timbus, Alexandre Oudalov and Carl N.M. Ho. „Islanding detection in smart grids“, Energy Conversion Congress and Exposition (ECCE), 2010 IEEE, October 2010, DOI: 10.1109/ECCE.2010.5618306

[118] W. Bower and M. Ropp, “Evaluation of islanding detection methods for photovoltaic utility interactive power systems,” IEA-PVPS, http://www.iea-pvps.org, Online report T5- 09, ožujak 2002. [Online], http://www.oja-services.nl/ieapvps/products/download/rep5 09.pdf

[119] Kobayashi H., Takigawa K., "Islanding Prevention Method for Gridinterconnection of Multiple PV Systems," Proceedings of the 2nd World Conference and Exhibition on Photovoltaic Solar Energy Conversion, Hofburg Congress Center, Vienna, Austria, lipanj 6-10, 1998.

[120]Gonzalez S., “Removing Barriers to Utility-Interconnected Photovoltaic Izmjenjivačs,” Proceedings of the 28th IEEE PV Specialists Conference, Anchorage, AK. Sep 2000.

[121] R. Best. „Phase-Locked Loops: Theory, Design, and Applications“, 2nd. Ed., pub. McGraw-Hill Inc., 1993.

[122] S. J. Ranade, N. R. Prasad, S. Omick, L. F. Kazda, "A Study of Islanding in Utility-Connected Residential Photovoltaic Systems, Part I: Models and Analytical Methods", IEEE Transactions on Energy Conversion, vol.4, br.3 listopad 1989, str. 436-445.

[123]. R. H. Wills. „The Interconnection of Photovoltaic Systems with the Utility Grid: An Overview for Utility Engineers", Sandia National Laboratories Photovoltaic Design Assistance Center, br. SAND94-1057, listopad 1994.

[124] H. Kobayashi, K. Takigawa i E. Hashimoto, "Method for Preventing Islanding Phenomenon on Utility Grid with a Number of Small Scale PV Systems", 21st IEEE Photovoltaic Specialists Conference (1991), str. 695-700.

[125] D. Handran, R. Bass, F. Lambert, J. Kennedy, "Simulation of Distribution Feeders and Charger Installation for the Georgia Tech Olympic Electric Tram System", 5th IEEE Workshop on Computers in Power Electronics, rujan 11-14 1996, str. 168-175.

[126]T. E. Grebe, "Application of Distribution System Capacitor Banks and Their Impact on Power Quality", IEEE Transactions on Industry Applications, vol.32, br.3, lipanj 1996, str. 714-719

[127] C. Jeraputra i P. Enjeti, "Development of a robust anti-islanding algorithm for utility interconnection of distributed fuel cell powered generation," IEEE Trans. on Power Electronics, vol. 19, br. 5, str. 1163– 1170, 2004.

[128] J. B. Jeong, H. J. Kim, S. H. Back, i K. S. Ahn, "An improved method for anti-islanding by reactive power control," in Proc. of ICEMS'05, vol. 2, 2005, str. 965–970.

[129] G. A. Kern, R. H. Bonn, J. Ginn i S. Gonzalez, "Results of Sandia National Laboratories grid-tied izmjenjivač testing," in 2nd World Conference and Exhibition on Photovoltaic Solar Energy Conversion, 1998.

[130] Z. Ye, L. Li, L. Garces, C. Wang, R. Zhang, M. Dame, R. Walling i N. Miller, "A new family of active anti-islanding schemes based on DQ implementation for grid-connected izmjenjivačs," PESC'04, vol. 1, Aachen, Germany, 2004, str. 235–241.

[131] L. Asiminoaei, R. Teodorescu, F. Blaabjerg i U. Borup, "A new method of on-line grid impedance estimation for PV izmjenjivač," APEC '04, vol. 3, 2004, str. 1527–1533

[132] A. Timbus, R. Teodorescu, F. Blaabjerg, and U. Borup, “Online grid measurement and ENS detection for PV izmjenjivač running on highly inductive grid,” IEEE Power Electronics Letters, vol. 2, br. 3, str. 77–82, 2004

[133] DIN-VDE, Automatic disconnection device between a generator and the public low-voltage grid, DIN-VDE Std. 0126-1-1, 2005.

[134] B. Palethorpe, M. Sumner, and D. Thomas, “Power system impedance measurement using a power electronic converter,” Harmonics and Quality of Power, vol. 1, 2000, str. 208–213.

[135] M. Ciobotaru, V. Agelidis i R. Teodorescu, “Accurate and lessdisturbing active anti-islanding method based on PLL for grid-connected PV Izmjenjivačs,” in Proc. IEEE Power Electronics Specialists Conference PESC, 15–19 lipanj 2008, str. 4569–4576

[136] A. Timbus, R. Teodorescu i P. Rodriguez, “Grid impedance identification based on active power variations and grid voltage control,” 2007 IEEE 42nd IAS Annual Meeting Industry Applications Conference, 2007, str. 949–954.

[137] A. Wyote, R. Belmans, K. Leuven i J. Nijs, “Islanding of Grid-Connected Module Izmjenjivačs”, 28th IEEE Photovoltaic Specialists Conference, listopad 17-22, 2000, str. 1683-1686.

[138] Chakravarthy, S.K.; Nayar, C.V.; Determining the Frequency Characteristics of Power Networks Using ATP, Source: Electric Machines and Power Systems, Vol. 25, br. 4, lipanj, 1997, str. 341-353.

[139] M. Ropp, M. Begovic i A. Rohatgi, “Prevention of Islanding in Grid-Connected Photovoltaic Systems”, Progress in Photovoltaics vol. 7, 1999, str. 39-59

[140] J. Stevens, R. Bonn, J. Ginn, S. Gonzalez i G. Kern. „Development and Testing of an Approach to Anti-Islanding in Utility-Interconnected Photovoltaic Systems“, Sandia National Laboratories report SAND2000-1939, Sandia National Laboratories, Albuquerque, NM, August 2000.

[141] M. E. Ropp, K. Aaker, J. Haigh i N. Sabbah, “Using power line carrier communications to prevent islanding [of pv power systems],” Twenty-Eighth IEEE Photovoltaic Specialists Conference, 2000, str. 1675–1678.

[142] N. Strath, "Islanding detection in power systems," Ph.D. dissertation, Lund University, 2005. [Online]. Dostupna na: http://www.iea.lth.se/publications/Theses/LTH-IEA-1051.pdf

[143] IEC, IEC 61850 Communication networks and systems in substations, IEC Std., 2003

[144] IEC 61850-7-420 Communications Systems for Distributed Energy Resources (DER), IEC Std., 2006.

[145] M. Ropp, K. Aaker, J. Haigh, N. Sabbah, "Using Power Line Carrier Communications to Prevent Islanding", Proceedings of the 28th IEEE Photovoltaic Specialists Conference, listopad 17-22, 2000, str. 1675-1678

[146] Jyh-Shing R. Jang. „Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm", 9th National Conference on Artificial Intelligence, Anaheim, CA, USA, July 14-19, 1991, Volume 2

[147] Navneet Walia, Harsukhpreet Singh i Anurag Sharma." ANFIS: Adaptive Neuro-Fuzzy Inference System- A Survey", International Journal of Computer Applications (0975 – 8887), Volume 123, br.13, lipanj 2015, DOI: 10.5120/ijca2015905635

[148] Jang R., "ANFIS :Adaptive-Network-Based Fuzzy Inference System," IEEE Transactions on Systems, MAN, and Cybernetics, Vol. 23, br. 3, 1993.

[149] S. Mitra, Y. Hayashi, S. Member, "Neuro Fuzzy Rule Generation : Survey in," IEEE transactions on neural networks, Vol. 11, br. 3, str. 748-768, 2000.

[150] Roy S., "Design of adaptive neuro-fuzzy inference system for predicting surface roughness in turning operation," Journal of Scientific & Industrial Research, vol. 64, rujan 2005, str. 653-659

[151] Kaur A., Kaur A., "Comparison of Mamdani-Type and Sugeno-Type Fuzzy Inference Systems for Air Conditioning System," International Journal of Soft Computing and Engineering, ISSN: 2231-2307, br. 2, str. 323-325, 2012.

[152] Uc T., Karahoca A., Karahoca D. "Tuberculosis disease diagnosis by using adaptive neuro-fuzzy inference system and rough sets," Neural Comput & Applications, Springer, , str. 471-483, 2013. DOI 10.1007/s00521-012-0942-1

[153] Gite A., Bodade M., Raut M., "ANFIS Controller and its Application," International Journal of Engineering Research & Technology, Vol. 2, br. 2, str. 1-5, 2013.

[154] Walia N., Tiwari K., Malhotra R., "Design and Identification of Tuberculosis using Fuzzy Based Decision Support System," Advances in Computer Science and Information Technology, ISSN: 2393-9915, vol. 2, br. 8, str. 57-62, 2015.

[155] Abu-rub H., Iqbal A., Ahmed M., Peng Z., Li Y., Baoming G., "Quasi-Z-Source Izmjenjivač-Based Photovoltaic Generation System With Maximum Power Tracking Control Using ANFIS," IEEE Transactions on Sustainable Energy, Vol. 4, br. 1, str. 11–20, 2013.

[156] Loganathan C., Girija V, "Investigations on Hybrid Learning in ANFIS," International Journal of Engineering Research & Applications, Vol. 4, br. 10, str. 31-37, 2014.

[157] Rezaei K., Hosseini R., Mazinani M., "A Fuzzy Inference System for Assessment of the Severity of the peptic ulcers," Computer Science & Information Technology, , str. 263-271, 2014. DOI:10.5121/ csit.2014.4527

[158] Patel D., Parekh F., "Flood Forecasting using Adaptive Neuro-Fuzzy Inference System," International Journal of Engineering Trends and Technology, ISSN: 2231-5381, vol. 12, br. 10, str. 510-514, 2014.

[159] Taylan O., "An adaptive neuro-fuzzy model for prediction of student‟s academic performance," Computers & Industrial Engineering, Elsevier, vol. 57, str. 732-741, 2009.

[160] Power E., "Adaptive Neuro Fuzzy Inference System (ANFIS) For Fault Classification in the Transmission Lines," Online Journal on Electronics and Electrical Engineering, Ref: W09-0030, br. 2, str. 164-169

[161] Yann LeCun, Yoshua Bengio i Geoffrey Hinton." Deep learning", Nature Publishing Group, a division of Macmillan Publishers Limited, Nature vol. 521, str.436–444, 28 lipanj 2015. doi: 10.1038/nature14539.

[162] Tompson, J., Jain, A., LeCun, Y. i Bregler, C. „Joint training of a convolutional network and a graphical model for human pose estimation", In Proc. Advances in Neural Information Processing Systems 27 1799–1807, srpanj 2014.

[163] Sainath T., Mohamed A.-R., Kingsbury B. i Ramabhadran, B. „Deep convolutional neural networks for LVCSR", Acoustics, Speech and Signal, Processing 8614–8618, 2013.

[164] Ma J., Sheridan R. P., Liaw A., Dahl G. E. i Svetnik V. „Deep neural nets as a method for quantitative structure-activity relationships", J. Chem. Inf. Model. 55, 263–274, 2015.

[165] Ciodaro T., Deva D., de Seixas J. i Damazio D. „Online particle detection with neural networks based on topological calorimetry information“, J. Phys. Conf. Series 368, 012030, 2012.

[166] Helmstaedter M. et al. Connectomic reconstruction of the inner plexiform layerin the mouse retina“. Nature 500, str 168–174, 2013.

[167] Xiong, H. Y. et al. „The human splicing code reveals new insights into the genetic determinants of disease“, Science 347, str 6218, 2015.

[168] Bottou, L. i Bousquet, O. „The tradeoffs of large scale learning“, Advances in Neural Information Processing Systems 20 161–168, 2007.

[169] Glorot X., Bordes A. i Bengio. Y. „Deep sparse rectifier neural networks“, 14th International Conference on Artificial Intelligence and Statistics, str. 315–323, 2011.

[170] LeCun Y. et al. „Handwritten digit recognition with a back-propagation network“, Advances in Neural Information Processing Systems 396–404, 1990.

[171] LeCun Y., Bottou L., Bengio Y. i Haffner, P. Gradient-based learning applied to document recognition. Proc. IEEE 86, 2278–2324, 1998.

[172] Felleman D. J. i Essen D. C. V. „Distributed hierarchical processing in the primate cerebral cortex“, Cereb. Cortex 1, str. 1–47, 1991

[173] Waibel, A., Hanazawa, T., Hinton, G. E., Shikano, K. i Lang, K. „Phoneme recognition using time-delay neural networks“. IEEE Trans. Acoustics Speech Signal Process. Vol.37, str. 328–339, 1989

[174] Bengio, Y., Courville, A. & Vincent, P. „Representation learning: a review and new perspectives“, IEEE Trans. Pattern Anal. Machine Intell. Vol. 35, str.1798–1828, 2013.

[175] Bengio, Y., Ducharme, R. & Vincent, P. „A neural probabilistic language model“. Advances in Neural Information Processing Systems vol. 13, str. 932–938, 2001.

[176] Mikolov, T., Sutskever, I., Chen, K., Corrado, G. i Dean, J. „Distributed representations of words and phrases and their compositionality“, Advances in Neural Information Processing Systems vol.26 str. 3111–3119, 2013.

[177] van der Maaten, L. i Hinton, G. E. „Visualizing data using t-SNE“, J. Mach. Learn. Research vol. 9,str. 2579–2605, 2008.

[178] Corinna Cortes i Vladimir Vapnik.“ Support-vector networks“, Kluwer Academic Publishers, ISSN: 0885-6125, veljača 1995, https://doi.org/10.1007/BF00994018

[179] Lee Yoonkyung, Lin Yonghe i Wahba Grace. „Multicategory Support Vector Machines, Theory, and Application to the Classification of Microarray Data and Satellite Radiance Data“, Journal of the American Statistical Association, 2003, DOI://99. 10.2307/27590354.

[180] Dragan Mlakić, Srete Nikolovski, Emir Alibašić.“ Designing Automatic Meter Reading System Using Open Source Hardware and Software“, International Journal of Electrical and Computer Engineering Vol. 7, br. 6, prosinac 2017, DOI: 10.11591/ijece.v7i6.pp3282-3291,

[181] IEEE, “1547 IEEE Standard for Interconnecting Distributed Resources With Electric Power Systems,” 2003.

[182] IEEE, “1574.1 IEEE Standard Conformance Test Procedures for EquipmentInterconnecting Distributed Resources with Electric Power Systems,” IEEE, 2005.

[183] H.R. Baghaee, M. Mirsalim, G.B. Gharehpetian, “Real-time verification of new controller to improve small/large-signal stability and fault ride-through capability of multi-DER microgrids”, IET Gen., Trans. Dist., vol.10, br. 12, str. 3068 - 3084, rujan. 2016, DOI: 10.1049/iet-gtd.2016. 0315.

Popis slika

[1.] Slika 2.1. Anomalija koju autori ref. [41] iskorištavaju pri otkrivanju otočnog rada.

[2.] Slika 2.2. Trajektorija struja razlike i suzdržanih struja tijekom zasićenja strujnih mjernih transformatora i unutarnjih kvarova [54].

[3.] Slika 2.3. Arhitektura EMC sustava koji su autori referata [59] preložili a koji se sastoji od 3 kontrolera i jednog centralnog upravitelja.

[4.] Slika 3.1. Profi lnapona prije i poslije nastupa otočnog rada [88].

[5.] Slika 3.2. Shematski prikaz mreže korištene za studij slučaja autora referata [99].

[6.] Slika 3.3. Električni parametri sa Psetpoint<Pload u konfiguraciji i.b (a) i i.c (b), P/f i Q/V su uvijek aktivni, sa sintetičkom inercijom isključenom (lijevo) i uključenom (desno)[99].

[7.] Slika 3.4. Reaktivna snaga distribuiranog izvora za podizanje napona na sabirnicama distribuiranog izvora [101].

[8.] Slika 3.5. Reaktivna snaga distribuiranog izvora za smanjivanje napona na sabirnicama distribuiranog izvora [101].
[9.] Slika 4.1. Koncept pojave otočnog rada distribuiranog izvora[111].
[10.] Slika 4.2. Generički sustav za ispitivanje otočnog pogona mikromreže po navedenim standardima [111].
[11.] Slika 4.3. Shematski dijagram za prikaz zone ne detekcije u parametrima razlike aktivne i reaktivne snage distribuiranog izvora i konzuma [111].
[12.] Slika 4.4. Prikaz klasifikacije osnovnih metoda detekcije otočnog rada distribuiranog izvora.
[13.] Slika 4.5. FN sustav i ODS mreža te konfiguracija komponenti pri vezivanju na točki zajedničkog spajanja [118].
[14.] Slika 4.6. Shematski prikaz operacije metode faznog skoka [118].
[15.] Slika 4.7. Strujno naponski fazni kut i frekvencija na izmjenjivaču prikazujući trenutak kada SMS metoda prepozna otočni rad distribuiranog izvora. [118]
[16.] Slika 4.8. Primjer valnog oblika korišten za primjenu metode Odstupanja frekvencije za otkrivanje otočnog rada [118].
[17.] Slika 4.9. Dizajn uređaja za automatsko odvajanje prema DIN –VDE-0126.
[18.] Slika 4.10. Podešavanje sustava uključujući PLCC odašiljač (T) i prijemnik (R)
[19.] Slika 5.1. Osnovna arhitektura ANFIS sustava sa dva ulaza i jednim izlazom [147].
[20.] Slika 5.2. Višeslojna neuronska mreža i postupak povratnog širenja [161].
[21.] Slika 5.3. Unutrašnja struktura konvolucijske neuronske mreže [161].
[22.] Slika 5.4. Vizualizacija naučenih jezičnih vektora.
[23.] Slika 5.5. Vizualna reprezentacija metoda potpornih vektora sa označenom marginom i hiperprostorom [179].
[24.] Slika 6.1. Globalna arhitektura metodologije kreiranja i testiranja metoda sa uzorkovanjem ulaznih podataka za svaku do metoda.
[25.] Slika 6.2. Prikaz frekvencije uzorkovanja podataka.
[26.] Slika 6.3. Improvizirani elektronički uređaj (IED) sastavljen za mjerenje na licu mjesta na točki zajedničkog spajanja-u.
[27.] Slika 6.4. Trend signala na točki zajedničkog spajanja u trenutku prelaska u otočni rad, odozgo prema dolje: frekvencija(f), RMSI, RMSU, aktivna snaga generirana od strane distribuiranog izvora (P_G), i reaktivna snaga generirana od strane distribuiranog izvora(Q_G), THD_I , THD_U.

[28.] Slika 6.5. Prikaz uzorkovanja, pakovanja i plasiranja podataka u ANFIS kontroler za pojedinačni signal.
[29.] Slika 6.6. Detalji i arhitektura vezivanja ANFIS kontrolera u predloženu metode detekcije otočnog rada.
[30.] Slika 6.7. Veza između signalnih ANFIS-a i glavnog ANFIS-a prikazano preko površina kretanja ulaznih veličina.
[31.] Slika 6.8. Dijagram tijeka za predloženi algoritam detekcije otočnog rada zasnovanog na ANFIS umjetne inteligencije metodi.
[32.] Slika 6.9. Primjerak slike kao ulaznog parametra u DUsustav detekcije otočnog rada distribuiranog izvora.
[33.] Slika 6.10. Uzorkovanje, slaganje i priprema ulaznih podataka za CNN.
[34.] Slika 6.11. Dijagram tijeka dijagrama za metodu otkrivanja otočnog rada na temelju dubokog učenja.
[35.] Slika 6.12. Izlazni rezultati vježbanja CNN-a pomoću postavki iz tablice 12. Gore: Gubitak treninga, dolje: točnost vježbanja.
[36.] Slika 6.13. Predložena arhitektura uzorkovanja za određeni signal.
[37.] Slika 6.14. Pregled i blok dijagram predložene MPV metode.
[38.] Slika 6.15. MPV algoritam općenita klasifikacija hiperpovršinskog prikaza.
[39.] Slika.6.16. Ulazni podaci tijeka frekvencije za jednu dimenziju.
[40.] Slika 6.17. Ulazni podaci tijeka frekvencije za dvije dimenzije.
[41.] Slika 6.18. Ulazni podaci tijeka frekvencije za tri dimenzije.
[42.] Slika 6.19. Opći algoritam za otkrivanje otočnog rada distribuiranog izvorana temelju otočnih i za kvarove definiranih MPV podloga.
[43.] Slika 6.20. Unošenje podataka u dvije MPV klasifikacijske skupine: otkrivanje otočnog rada i otkrivanje kvarova.
[44.] Slika 6.21. Podaci o frekvenciji dobiveni tijekom otočnog rada i događaja kvara u mreži (crveni otočni rad, plava kvar).
[45.] Slika 7.1. Kreirani model u alatu koji predstavlja realnu mrežu koja je uzorkovana uz pomoć IED mjernog uređaja te služi kao poligon za testiranje umjetne inteligencije metoda detekcije otočnog rada..
[46.] Slika 7.2. Oprema FN postrojenja i priključak na distribucijskoj mreži. Gore lijevo: AC ormar na betonskom stupu s mjernom i zaštitnom opremom. Gore desno: DC ormarić i izmjenjivači 2x10 kW. Dolje: foto naponski paneli na krovu s instaliranom snagom od 23,8 kWp

[47.] Slika 7.3. Specifikacija P-V i I-V-a na FN panelu koristi se kao različiti uvjeti testiranja u simulaciji

[48.] Slika 7.4. Primjer modela otkrivanja otočnog rada za provjeru prikladne funkcionalnosti metode gdje je Qf faktor kvalitete, a napon i snaga su obje veličine faze (poznate i kao nenamjerna konfiguracija testiranja otočnog rada)[181]

[49.] Slika 7.5. Simbolički prikaz kvarova pod čijim su scenarijima testirane umjetne inteligencije metode predložene ovom disertacijom za detekciju otočnog rada distribuiranog izvora: a) trofazni kratki spoj, b) dvofazni kratki spoj, c) monofazni spoj sa zemljom.

[50.] Slika 7.6. Standardna shema testnog scenarija sa još jednim distribuiranim izvorom koji je priključen na istu točki zajedničkog spajanja sa distribucijskoj mreži-om.

[51.] Slika 8.1. Rezultati testiranja ANFIS metode detekcije otočnog rada prema različitim vrijednostima kvalitete mreže Qf pri 2% tereta mreže u odnosu na generiranu energiju sa distribuiranog izvora.

[52.] Slika 8.2. Rezultati testiranja ANFIS metode detekcije otočnog rada prema različitim vrijednostima kvalitete mreže Qf pri 100% tereta mreže u odnosu na generiranu energiju sa distribuiranog izvora.

[53.] Slika 8.3. Rezultati testiranja ANFIS metode detektije otočnog rada prema različitim vrijednostima kvalitete mreže Qf pri 200% tereta mreže u odnosu na generiranu energiju sa distribuiranog izvora.

[54.] Slika 8.4. Rezultati testiranja ANFIS metode po standardu UL1741 za jednu FN na mikromreži.

[55.] Slika 8.5. Rezultati testiranja ulaska i izlaska dodatnog tereta u mikromrežu.

[56.] Slika 8.6. Rezultati testiranja pri 3F-F kvaru na nisko naponskoj distribucijskoj mreži.

[57.] Slika 8.7. Rezultati testiranja pri 2F-F kvaru na nisko naponskoj distribucijskoj mreži.

[58.] Slika 8.8. Rezultati testiranja pri 1F-T kvaru na nisko naponskoj distribucijskoj mreži.

[59.] Slika 8.9. Rezultat testiranja ANFIS metode pri iniciranom brzom punjenju PHEV/električnih automobila.

[60.] Slika 8.10. Rezultati testiranja ANFIS metode pri dodatnom FN sustavu kao distribuiranog izvora na istoj mikromreži pod uvjetima testiranja propisanima po standardu UL 1741.

[61.] Slika 8.11. Rezultati testiranja DU metode pod različitim Qf vrijednostima distribucijskoj mreži-a prema tablic 19.

[62.] Slika 8.12. Rezultati testiranja DUmetode pod parametrima UL 1741 standarda prema tablic 18.
[63.] Slika 8.13. Rezultati za DU prema situacijama kvarova na nisko naponskoj distribucijskoj mreži.
[64.] Slika 8.14. Rezultati DUdetekcije otočnog rada pri uključlivanju brzog punjenja PHEV /električnih automobila bez pojave otočnog rada.
[65.] Slika 8.15. Rezultati DU detekcije otočnog rada pri uključlivanju brzog punjenja PHEV /električnih automobila uz pojavu otočnog rada.
[66.] Slika 8.16. Rezultati testiranja DU metode u situaciji prisustva dva distribuirana izvora u istoj točki zajedničkog spajanja a pod uvjetima standarda UL 1741.
[67.] Slika 8.17. Rezultati testiranja metode MPV za detekciju otočnog rada distribuiranog izvora pri različitim faktorima kvalitete mreže. Lijevo detekcija otočnog rada, desno detekcija kvarova na mreži
[68.] Slika 8.18. Rezultati testiranja MPV metode pri standardu UL1741.
[69.] Slika 8.19. Rezultati pri 3F-Z kvaru na mreži.
[70.] Slika 8.20. Rezultati pri 2F-F kvaru na mreži.
[71.] Slika 8.21. Rezultati pri 1F-T kvaru na mreži.
[72.] Slika 8.22. Rezultati testiranja MPV metoda pri brzom punjenju PHEV/el. automobila bez pojave otočnog rada.
[73.] Slika 8.23. Rezultati testiranja MPV metoda pri brzom punjenju PHEV/el. automobila s pojavom otočnog rada.
[74.] Slika 8.24. Rezultat detekcije otočnog rada pri prisustvu još jednog distribuirana izvora u istoj točki zajedničkog spajanja sa mikromrežom.
[75.] Slika 8.25. Usporedba zone ne detekcije za sve tri umjetne inteligencije metode za parametre generirane aktivne energije i napona u točki zajedničkog spajanja.

Popis Tablica

[1.] Tablica 2.1. Pregleda sadržaja IEEE 1547 standarda vezanog za zaštitu distribuiranog izvora i distribucijske mreže [16].
[2.] Tablica 2.2. Komparativne karakteristike raznih MPPT algoritama, uzete iz [63].
[3.] Tablica 2.3. Klasifikacijska struktura aplikacija umjetnih neuronskih mreža u vjetroelektranama [68].

[4.] Tablica 2.4. Usporedba vremena otkrivanja otočnog rada umjetne inteligencije metoda [80]
[5.] Tablica 3.1. Parametri otočnog događaja i njihov utjecaj na ispravan rad sustava zaštite (IPS) (DA znači da IPS ispravno radi, NE znači IPS neuspjeh u identificiranju uvjeta otočnog rada) [99].
[6.] Tablica 4.1. Neusklađenost izlazne snage distribuiranog izvora i konzuma za različite otočne standarde.
[7.] Tablica 4.2. Razlika između današnjih mreža i pametnih mreža koje dolaze[117].
[8.] Tablica 4.3. Usporedba metoda otkrivanja otočnog rada distribuiranih generatora [118].
[9.] Tablica 5.1. Prolazi hibridnog algoritma učenja [147].
[10.] Tablica 6.1. Detalji uzoraka i skupa uzoraka koji se plasira dalje za treniranje i testiranje metoda.
[11.] Tablica 6.2. Postavke za sliku kao ulazni podatak za CNN mrežu.
[12.] Tablica 6.3. Arhitektura CNN mreže nakon treniranja.
[13.] Tablica 6.4. Detalji treninga MPV algoritma za otkrivanje otočnog rada distribuiranog izvora.
[14.] Tablica 6.5. Rezultati treniranja MPV algoritma za detekciju kvara na distribucijskoj mreži-i.
[15.] Tablica 7.1. Parametri FN sustava koji je modeliran u Matlab alatu za testiranje metoda.
[16.] Tablica 7.2. Tehničke specifikacije FN panela koji su instalirani na FN elektrani koja je uzor za modeliranje i mjerenje.
[17.] Tablica 7.3. Popis svih IEEE 1547 standarda koji su objavljeni i koji se obrađuju
[18.] Tablica 7.4. Konfiguracija aktivne i reaktivne snage mreže za testiranje metoda.
[19.] Tablica 7.5. Vrijednosti Qf za različite slučajeve kvalitete distribucijskoj mreži pod kojima su metode detekcije otočnog rada testirane.
[20.] Tablica 8.1. Scenariji pod kojima je testiranje urađeno za brzo punjenje električnih automobila i/ili hibrida sa NN distribucijskoj mreži-e.
[21.] Tablica 8.2. Testiranje zone ne detekcije se radi na 2D površini definiranoj sa P i RMSV.
[22.] Tablica 8.3. Rezultati testiranja ANFIS metode pod uvjetima propisanima standardom UL1741 za svih 6 kvaliteta distribucijskoj mreži-a.
[23.] Tablica 8.4. Rezultati testiranja ANFIS metode po standardu UL1741.
[24.] Tablica 8.5. Rezultati testiranja DUmetode prema različitim Qf vrijednostima distribucijskoj mreži-a.
[25.] Tablica 8.6. Rezultati vremena detekcije otočnog rada pri različitim Qf faktorima mreže i standardom UL 1741.

[26.] Tablica 8.7. Rezultati testiranja pri kvarovima na distribucijskoj mreži.
[27.] Tablica 8.8. Rezultati vremena detekcije pri dodatnom distribuiranom izvoru u istoj točki zajedničkog spajanja sa mikromrežom.
[28.] Tablica 8.9. Sumarni rezultati zone ne detekcije za sve tri metode.
[29.] Tablica 8.10. Usporedba vremena detekcije otočnog rada pri testiranju prema standardu IEEE 1547/UL 1741 za slučaj jednog distribuiranog izvora na distribucijsku mrežu.

Popis kratica

AFD	Active frequency Drift eng.
AI	Artificial Intelligence, eng.
ANFIS	Adaptive Neuro-Fuzzy Inference System eng.
AODV	Ad hoc On-Demand Distance Vector eng.
BAT	Bat Algorithm eng.
BEMS	Building Energy Management Systems eng.
CBC-MAC	Cipher Block Chaining Message Authentication Code eng.
CENELEC	European Committee for Electrotechnical Standardization eng.
CNN	Convolution Neural Network eng.
DC/AC	Direct Current/Alternating Current eng.
DELM	Deep Extreme Learning Machine eng.
DFS	Detekcija faznog skoka
DFT	Diskretne Furijerove transformacije
DG	Distributed Generators eng.
DI	Distributivni izvor
DL	Deep Learning eng.
DMS	Distribution Management System eng.
DN	Distribution Network eng.
DSO	Distribution System Operator eng.
DSOPF	Dynamic Stohastic Optimal Power Flow eng.
DU	Duboko učenje
DV	Dalekovod
ECDSA	Elliptic Curve Digital Signature Algorithm eng.
EES	Elektro energetski sustav

f	Frequency eng.
FDI	False Data Injection eng.
FIS	Fuzzy Inference System eng.
FJ	Frequency Jump eng.
FL	Fuzzy Logic eng.
FM	Facility Manager eng.
FNG	Foto naponski generator
FNS	Foto naponski sustav
FPA	Flower Pollination Algorithm eng.
FVS	Fast Voltage Support eng.
GD	Gradient Degrading eng.
GMCDM	Group Multiple Criteria Decision Making eng.
GPT	Generator plinskih turbina
GVA	Generator vjetro agregata
HFBA	Hybrid firefly bat algorithm eng.
HTML5	Hyper Text Markup Language fifth edition eng.
HVAC	Heating, ventilation, and air conditioning eng.
IDM	Islanding Detection Method eng.
IED	Intelligent Electronic Device eng.
IEEE	Institute of Electrical and Electronics Engineers eng.
INC	Increment method eng.
JRE	Java Runtime Environment eng.
KNM	Konvolucijska neuronska mreža
LM	Levenberg-Marquardt
LS	Keast Square eng.
MAE	Mean Absolute Error eng.
MAF	Metoda aktivne frekvencije
MAPE	Mean Absolute Percentage Error eng.
MCDM	Multiple Criteria Decision Making eng.
MDOR	Metoda detekcije otočnog rada
MLP-PSO	Multilayer perceptron - Particle Swarm Algorithm eng.
MOO	Metode otkrivanja otočnog rada
MPPT	Maximum Power Point Tracking eng.

MPV	Metoda potpornih vektora
MSD	Mains Monitoring Devices eng.
NDZ	Non detection zone eng.
NFZ/PFZ	Nad frekventna zaštita/Pod frekventna zaštita
NMT	Naponski mjerni transformator
NNM	Nisko naponska mreža
NNZ/PNZ	Nad naponska zaštita/Pod naponska zaštita
ODS	Operator distribucijskog sustava
OFP/UFP	Over Frequency Protection/ Under Frequency Protection eng.
OiE	Obnovljivi izvori energije
P	Active power eng.
P&O	Preturb&Observe eng.
PHEV	Plug-in Hybrid Electric Vehicle eng.
PLC	Power Line Communications eng.
PLCC	Power Line Carrier Communication eng.
PLL	Phase Lock Loop eng.
PSO	Particle Swarm Optimization eng.
PSO	Power System Operator eng.
PWM	Pulse width modulation eng.
Q	Reactive power eng.
Qf	Quality factor eng.
R	Receiver eng.
RBF-PSO	Radial Basis Function - Particle Swarm Algorithm eng.
ReLU	Rectified Linear Unit eng.
RES	Renewable Energy Sources eng.
RF	Random Forest eng.
RGB	Red Green Blue eng.
RKLM	Runge-Kutta Learning Method eng.
RLC	Električni krug s udjelom aktivnog, induktivnog i kapacitivnog otpora
RMSE	Root Mean Square Error eng.
RMSi	Root Mean Square of Current eng.
RMSu	Root Mean Square of Voltage eng.

ROCAP	Rate Of Change Active Power eng.
ROCOF	Rate Of Change Of Frequency eng.
ROCOFOP	Rate Of Change Of Frequency Of Power eng.
ROCOV	Rate of Change Of Voltage eng.
RPV	Rate of Power Variation eng.
SAT	Saturation Test eng.
SCADA	Supervisory Control And Data Acquisition eng.
S-FEAR	Secure-Fuzzy Energy Aware Routing eng.
SFS	Sandia Frequency Shift eng.
SG	Smart Grid eng.
SMS	Slip Mode Frequency Shift eng.
SMT	Strujni mjerni transformator
SN	Srednji napon
SOM	Self-Organizing Map eng.
SPD	Signal Produced by Disconnect eng.
SQP	Sequential quadratic programming eng.
STATCOM	Static Synchronous Compensator eng.
SVM	Support Vector Machine eng.
SVS	Sandia Voltage Shift eng.
T	Transmitter eng.
T2FL	Type-2 Fuzzy Logic eng.
THDi	Total Harmonic Distortion of Current eng.
THDu	Total Harmonic Distortion of Voltage eng.
TSK	Takagi, Sugeno i Kang
UI	Umjetna inteligencija
WSN	Wireless Sensor Network eng.
ZND	Zona ne detekcije

11. SAŽETAK

U doktorskom radu je predstavljena metodologija detekcije otočnog rada distribuiranih izvora energije uz pomoć metoda umjetne inteligencije (umjetne inteligencije) sa ciljem zadržavanja pasivne prirode metode detekcije a povećanja preciznosti, smanjenja vremena detekcije i zone ne-detekcije (zone ne detekcije). Predložena metodologija se sastoji od tri cjeline realizirane kroz 9 poglavlja: snimanje parametara mreže sa pametnim brojilom, treniranje umjetne inteligencije metoda sa slogovima podataka, testiranje metoda kroz standarde IEEE 1547 i UL 1741. Detekcija otočnog rada je realizirano kroz tri predložene metode: Adaptivni sustav neuro-neizrazitog zaključivanja(eng. Adaptive Neuro-Fuzzy Inference System - ANFIS), Duboko učenje (eng. Deep Learning - DL) i Metoda potpornih vektora (eng. Support Vector Machine - MPV). Mjerenja su prikupljeni podaci sa realnog foto-naponskog (FN) sustava uz pomoć kojih je modeliran model u programskom alatu Matlabu/Simulink za testiranje navedenih umjetne inteligencije metoda. Također su izmjereni rezultati korišteni za treniranje kognitivnih metoda. Ocjenjivanje efikasnosti metoda se radi prema navedenim standardima, te još tri vrste kvara na niskonaponskoj distribucijskoj mreži, još jednim distribuiranim izvorom na istoj točki spajanja distribuiranog izvora sa distribucijskoj mreži-om, brzo punjenje električnih i hibridnih automobila (PHEV), te promjeni faktora kvalitete mreže (Q_f). Na kraju su predstavljeni rezultati od sve tri predložene umjetne inteligencije metode, kao sumarni prikaz u izvješću u poglavlju 8, te diskutirana moguća daljnja istraživanja u cilju poboljšanja navedena tri faktora metoda za detekciju otočnog rada.

Ključne riječi: ANFIS, Deep Learning, Support Vector Machine, distribuirani izvor, niskonaponska distributivna mreža, otočni rad, mjerenje, umjetna inteligencija, obnovljivi izvori energije.

Abstract

The methodology for detecting islanding of Distributed Generators (DGs) in Distribution Network (DN) using the method of artificial intelligence (AI) is presented in the dissertation with the aim of retaining the passive nature of the detection method and increasing the precision, reduction of detection time and non-detection zone (NDZ). The proposed methodology consists of three units realized through 9 chapters: smart metering network parameters, training of AI methods using recorded data, testing methods through standards IEEE 1547 and UL 1741. Detection of the islanding is done through three proposed methods: Adaptive Neuro-Fuzzy Inference System

(ANFIS), Deep Learning (DL), and Vector Support Machine (MPV). The measurements were collected from the real photographic (FN) system used in modeling of testing simulation environment in Matlab / Simulink software to test these Artificial Intelligence methods. Measurement results were also used to train cognitive methods. Efficiency evaluation of the method is done according to the mentioned standards and three other situations in microgrid: fault on the low voltage distribution network, another distribution sources at the same point of common coupling of distribution source with distribution network, rapid charging of electric and hybrid cars (PHEV) and change of network quality factors (Q_f). Finally, the results of all three proposed Artificial Intelligence methods are presented as a summary report in the chapter 8 and discussed possible further research to improve mentioned three factors of inslanding detection methods.

Keywords: ANFIS, Deep Learning, Support Vector Machine, Distributed Generator, Low Voltage Distribution Network, Island Work, Measurement, Artificial Intelligence, Renewable Energy Sources.

12. ŽIVOTOPIS

Rođen 15.06.1981. godine u Travniku, Bosna i Hercegovina. Pohađao Osnovnu školu „Hasan Brkić“ Stojkovići, Novi Travnik u razdoblju od 1988.-1996. godine. Srednju školsku spremu stekao pohađajući Prirodoslovno-matematičku gimnaziju u Srednjoj školi Novi Travnik od 1996.-2000. godine, te usporedo završio i Srednju glazbenu školu „Jakova Gotovca“ u Novom Travniku. Upisao 2000. godine Elektrotehnički fakultet u Sarajevu, Univerzitet Sarajevo i tu stekao titulu diplomiranog inženjera elektrotehnike, smjer računarstvo i informatika sa diplomskim radom pod nazivom „Game engine, napredna grafička obrada“, izrađenim pod mentorstvom prof. dr. sc. Selme Rizvića. Po završetku fakultetske naobrazbe zapošljava se 2007. godine u JP Elektroprivreda HZ-HB d.d. Mostar, Distribucijsko područje Centar, na radnom mjestu Samostalnog inženjera 1, u sektoru za Upravljanje i mjerenju u EES-u, gdje radi sve do danas.
Upisuje Magistarski studij na Elektrotehničkom fakultetu u Sarajevu 2008. godine, koji završava stječući titulu magistar znanosti, obranivši temu magistarskog rada pod nazivom „Hibridni neuro fuzzy model za procjenu stepena srčanog udara“ pod mentorstvom prof. dr. Zikrije Avdagića. Također je angažiran kao vanjski suradnik na Sveučilištu/Univerzitetu „Vitez“ u Travniku, gdje obnaša poziciju višeg asistenta 2 predavajući vježbe na 4 predmeta: „Objektno orijentirano programiranje“, „ Napredno Java programiranje“, „ Softverski inženjering“ i „Softverski uzori“.
Trenutno živi i radi u Novom Travniku, Bosna i Hercegovina. Aktivni je član BH K CIGRE i BH K CIRED, te IEEE društva. Početkom 2016. godine upisuje doktorski studij na Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, FERIT.