

Utvrđivanje topologije elektroenergetske mreže na temelju analize putujućih valova.

Jerčić, Roko

Doctoral thesis / Disertacija

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:168:179260>

Rights / Prava: [In copyright / Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-19**



Repository / Repozitorij:

[FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repository](#)





Sveučilište u Zagrebu

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Roko Jerčić

**UTVRĐIVANJE TOPOLOGIJE
ELEKTROENERGETSKE MREŽE NA
TEMELJU ANALIZE PUTUJUĆIH
VALOVA**

DOKTORSKI RAD

Zagreb, 2020.



Sveučilište u Zagrebu

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Roko Jerčić

**UTVRĐIVANJE TOPOLOGIJE
ELEKTROENERGETSKE MREŽE NA
TEMELJU ANALIZE PUTUJUĆIH VALOVA**

DOKTORSKI RAD

Mentor:

prof.dr.sc.Ivica Pavić

Zagreb, 2020.



University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND
COMPUTING

Roko Jerčić

DETERMINING POWER NETWORK TOPOLOGY USING TRAVELLING WAVES ANALYSIS

DOCTORAL THESIS

Supervisor:
prof. Ivica Pavić, PhD

Zagreb, 2020

Doktorski rad izrađen je na Sveučilištu u Zagrebu, Fakultetu elektrotehnike i računarstva, na Zavodu za visoki napon i energetiku.

Mentor: prof. dr. sc. Ivica Pavić, Fakultet elektrotehnike i računarstva, Zagreb

Doktorski rad ima: 128 stranica

Doktorski rad br.: _____

Životopis mentora

Ivica Pavić diplomirao je na Elektrotehničkom fakultetu Sveučilišta u Zagrebu 1987. godine. Početkom te godine počeo je raditi u tvornici Rade Končar-Elektrouređaji, a u listopadu iste godine zaposlio se kao asistent na Zavodu za visoki napon i energetiku Elektrotehničkog fakulteta u Zagrebu. Doktorat znanosti stekao je na Fakultetu elektrotehnike i računarstva u polju elektrotehnike 1999. godine, a trenutno je zaposlen na radnom mjestu redovitog profesora u trajnom zvanju te sudjeluje u izvođenju nastave na preddiplomskom i diplomskom studiju iz područja prijenosa električne energije i analize elektroenergetskog sustava. Osim toga, nositelj je dva kolegija na poslijediplomskom doktorskom studiju, a sudjeluje i u izvođenju nastave na specijalističkim studijima Transformatori i Željeznički elektrotehnički sustavi. Sudjelovao je u više znanstveno-istraživačkih projekata te je objavio preko 100 radova u znanstvenim i stručnim časopisima i zbornicima međunarodnih i domaćih konferencija iz područja analize i vođenja pogona te planiranja razvoja elektroenergetskog sustava. Autor je dva sveučilišna priručnika te recenzent većeg broja znanstvenih članaka u inozemnim i domaćim časopisima. Član je stručnih udruga IEEE i HRO Cigre, a od 2007. godine član je Akademije tehničkih znanosti Hrvatske (HATZ).

Supervisor curriculum vitae

Ivica Pavić. received B.Sc. degree in electrical engineering from the University of Zagreb, Faculty of Electrical Engineering (ETF) in 1987. In the beginning of 1987, he started working in Rade Koncar - Electric Systems and from October of the same year he is working at the Department of High Voltage and Power Systems at ETF Zagreb. Ph.D. degree received in electrical engineering from the University of Zagreb, Faculty of Electrical Engineering and Computing (FER) in 1999 and he is currently a full professor involved in teaching of undergraduate and graduate study in field of electricity transmission and power system analysis. He is also involved in teaching of doctoral study and Transformers and Railway Electrical Systems specialist studies. He participated in several scientific and research projects and he published more than 100 papers in journals and conference proceedings in the area of power system analysis, control and planning. He is the author of two university manuals and he serves as a technical reviewer for various international and domestic journals. Prof. Pavić is a member of IEEE society and Croatian Committee of Cigré, and since 2007 he has been a member of Croatian Academy of Engineering (HATZ).

Zahvale

Zahvaljujem se svom mentoru prof. dr. sc. Ivici Paviću na svim podijeljenim idejama, vrijednim sugestijama i stručnom vodstvu tijekom istraživanja i izrade ovog rada.

Hvala braći Marku i Ivanu na pomoći i doprinosu u obradi rezultata istraživanja.

Veliko hvala mojoj obitelji, supruzi Anji i kćerki Leni, na potpori, strpljenju i razumijevanju.

Sažetak

Estimacija stanja važan je dio funkcija vođenja elektroenergetskog sustava, a ispravna interpretacija topologije mreže ključan je procesni dio svakog estimatora stanja. Interpretacija topologije mreže podrazumijeva nedvojbeno utvrđivanje uklopnog stanja pojedinih elementa elektroenergetske mreže. Mrežna topologija u danas korištenim sustavima utvrđuje se pomoću dostupnih podataka o binarnim stanjima sklopnih aparata i njihovom korelacijom s podacima konfiguracije elektroenergetskog sustava. Takav proces naziva se topološko procesiranje i često može dovesti do krive interpretacije mrežne topologije uslijed izražene osjetljivosti na asinkrono prikupljanje potrebnih podataka ili njihovo krivo očitavanje.

U ovom radu prezentiran je novi pristup topološkom procesiranju temeljen na interpretaciji refleksije utisnutog ispitnog naponskog signala, a sve u cilju poboljšanja te funkcije. Prikazan je način kako iz reflektiranog ispitnog naponskog signala koji ima karakter putujućeg elektromagnetnog vala ekstrapolirati topološku informaciju pomoću razrađenog sustava umjetnih neuronskih mreža. Ispitni naponski signal utiskuje se u optimalno odabrane sabirnice elektroenergetske mreže te se na istoj poziciji očitava refleksija putujućeg vala. Metoda izbora optimalnog mjesta za utiskivanje signala zasniva se na poznatom optimizacijskom problemu pokrivanja i rješavanju istog metodom cjelobrojnog linearnog programiranja. Nakon očitavanja refleksije ispitnog signala topološka informacija ekstrapolira se pomoću sustava umjetnih neuronskih mreža. Sustav umjetnih neuronskih mreža sastoji se od dvaju dijelova: sustav za dekompoziciju signala (DANN) i sustav za prepoznavanje topologije (TANN). Obzirom da je očitani signal superpozicija refleksija od svake pojedine sabirnice u promatranom dijelu mreže u DANN sustavu takav signal razlaže se na sastavne dijelove odnosno na doprinose svake pojedine refleksije. Izlazna vrijednost DANN sustava je vektor koji sadrži amplitude svakog pojedinačnog reflektiranog signala i taj vektor predstavlja ulazni vektor TANN sustava. TANN sustav kao rezultat vraća klasificirani vektor sa binarnim uklopnim stanjem na svakom kraju pojedinog voda što u konačnici predstavlja i topologiju mreže.

U svrhu verifikacije, opisana metoda primijenjena je na pojednostavljenom modelu dijela elektroenergetske mreže, a analiza dobivenih rezultata pokazala je zadovoljavajuću efikasnost u prepoznavanju topološke strukture.

Ključne riječi: estimacija stanja, topologija EES-a, topološki procesor, putujući valovi, valna refleksija, umjetne neuronske mreže

DETERMINING POWER NETWORK TOPOLOGY USING TRAVELLING WAVES ANALYSIS

Correct insight and interpretation of the network topology are crucial step of any state estimator. Interpretation of network topology implies undoubted determination of connecting status of each individual power system element. Network topology in today used systems is determined by the available data of the switchgear states and their correlation with the configuration data of the power system. That process is called topology processing and it can often lead to a misinterpretation of network topology due to a high sensitivity to asynchronous data acquisition or some other kind of misreading. In addition, due to the increasing automation of the system management process, an increasing speed and precision of topological processing is required.

The **first**, introductory **chapter** briefly describes motivation, goal and hypothesis of the research. Deregulation and liberalization of the electricity market and the development and implementation of distributed renewables requires a fast response of system management to ensure safe and reliable system operation. In this sense, the need for real-time power system management is emphasized, which requires highly automated processes and new advanced tools. State estimation process is the basic tool for realizing an automated power system and topology processor is crucial step in that way. This doctoral thesis deals with a new, improved, concept of topological processing and is aimed at proving the hypothesis that topological processing can be performed without knowing the switching states of individual devices in the power system. Aim of this work is to improve function of topological processing as part of state estimation process. In order to improve state estimator's accuracy and speed, a new approach of determining network topology is presented. Presented method is based on measurement of the injected test signal reflection from the impedance discontinuities in the network. Correct interpretation of the measured reflected signal gives possibility to determine the network topology at the reflection site.

The **second chapter** contains theoretical background to understand research process and it is divided into 4 subchapters.

The first subchapter describes the state estimation process. Each state estimation process contains several subprocesses such as measurement acquisition, topological processing,

observability analyses and detecting measurement error. Result of state estimation process is pool of voltage phasors in each node of the observed part of power system. There are several conceptual approaches to state estimation: conventional state estimation, fast state estimation and hybrid state estimation. Conventional state estimation uses data from SCADA system and after forming state equations by known iterative procedure comes to a final result. Fast state estimation can be possible for enough number of PMU devices. It uses data from PMU devices which are already time synchronized. Thus state equations can be linear and their solution goes fast. The hybrid state estimation is a combination of the two previous and combines data acquisition source of them.

In the second subchapter functional description of topology processing is presented. Topology processing is one of the most important functions of state estimation which is used to transform the bus-section/switching-device model into a bus/branch model. Conventional topology processing is performed prior to state estimation and other related functions such as observability analysis and bad data processing; once the network topology is known, state estimation assumes that this topology is correct, and proceeds to estimate state and identify analog bad data whenever possible. In the conventional approach, the determination of the real time model from the available data set is decomposed into two main subproblems: the processing of logical data and the processing of analog data. The former consists of topology processing and the latter involves observability analysis and state estimation in which the network topology and parameters are considered as given, and analog data is processed using a bus/branch network model. As already mentioned, topological processing essentially consists three basic parts: elimination of switchgear from the network model, merging section groups into a single bus and appropriate assignment of initial measuring points to the reduced model. In this process but also in the process of binary data collection an error often occurs. For that reason and also due to the need for higher topological processing speed in fast state estimators, it is necessary to improve this process. Therefore, a new method of topological processing based on reflection of the injected test signal analysis is proposed.

Since the test signal has the characteristics of a traveling wave, the third subchapter shows the properties of electromagnetic traveling waves on transmission lines. Traveling waves are observed when a wave is not confined to a given space along the medium. When electromagnetic wave propagates along a transmission line with a certain characteristic impedance, there is a fixed relation between the voltage and current waves. But if the wave arrives at a discontinuity, such as open circuit or short circuit, or a point of the line where the characteristic impedance $Z = (L/C)^{1/2}$ changes, for instance, on substation bus connected with

other transmission lines, because of the mismatch in characteristic impedance, an adjustment of the voltage and current waves must occur. At the discontinuity part of the energy is let through, and part of the energy is reflected and travels back. By measuring reflected wave it is possible to find out the characteristic impedance ratio at the reflection point also taking into account the losses on real transmission line. For lossless line, the series resistance R and parallel conductance G are neglected, but on the real transmission line, part of wave energy is lost on it. If losses of electric field equal to losses in magnetic field ($R/L = G/C$) that line is distortionless line. So, point is that reflected wave carries information about total characteristic impedance at the end of transmission line. Since the surge impedance seen at the end of the transmission line depends on the topology on terminated bus, by measuring and interpreting the reflected signal it is possible to find topology at a particular bus in the network. In this research interpretation of the reflected test signal was performed using a system of an artificial neural network.

So, fourth subchapter deals with theoretical background of artificial neural networks (ANN). An ANN is based on a collection of connected units or nodes called artificial neurons, which loosely model the neurons in a biological brain. Each connection, like the synapses in a biological brain, can transmit a signal to other neurons. Each artificial neuron has inputs and produce a single output which can be sent to multiple other neurons. The inputs can be the feature values of external data sampling, or they can be the outputs of other neurons. If ANN consist multiple layers, each connection providing the output of one neuron as an input to another neuron. Each connection is assigned a weight factor that represents its relative importance. A given neuron can have multiple input and one output connection. The propagation function computes the input to a neuron from the outputs of its predecessor neurons and their connections as a weighted sum. The neurons are typically organized into multiple layers. Neurons of one layer connect only to neurons of the immediately preceding and immediately following layers. The layer that receives external data is the input layer. The layer that produces the ultimate result is the output layer. In between them are zero or more hidden layers. ANN have the ability to learn. Learning process is the adaptation of the network to better handle a task by considering sample observations. Learning involves adjusting the connection weights (and optional thresholds) of the network to improve the accuracy of the result. This is done by minimizing the observed errors. Learning is complete when examining additional observations does not usefully reduce the error rate. One of the most commonly used method for ANN learning process is backpropagation algorithm. Backpropagation is a method to adjust the connection weights to compensate for each error found during learning. The error

amount is effectively divided among the connections. Technically, backpropagation calculates the gradient (the derivative) of the cost function associated with a given state with respect to the connection weights. The weight updates can be done via stochastic gradient descent.

Third chapter describes new proposed method for topology processing. As mentioned before, the network topology can be obtained by correctly interpreting of injected test signal using an artificial neural network system. The method is divided into two steps. First step is related to the building and learning of artificial neural network systems and it is called pre-implementation part. The second part is post-implementation and refers to the recognition of the topology from the measured reflection of the voltage test signal. The function of the test signal for recognizing the topology according to the algorithm described here should be chosen in such a way that it provides the best feedback. The choice of the test signal function is arbitrary, but must meet certain limitations such as magnitude and duration. Method proposed here suggest a symmetrical three-phase sine wave signal with an amplitude of 1 kV and a duration of 0.01ms. Voltage test signal propagated through electric network behaves as a traveling wave with certain wavelength, velocity and amplitude and all other wave properties such as reflection, transmission and interference. Amplitude of the reflected and transmitted wave depends on the wave propagated transmission line impedances and surge impedance seen on the bus where the wave is reflected. In case when several transmission lines or transformers are connected at the same bus, their total surge impedance is a parallel circuit of each surge impedances. Reflected wave signal carries information about total surge impedance at the end of the transmission line. Since total surge impedance at the end of the transmission line is defined by bus topology, it is concluded that it can be obtained by measuring and analyzing reflected wave.

Since transmission lines are similar lengths, it is possible that reflected signal is superimposed on each other's. In that case it is very difficult to extract topology information directly analyzing reflected signal. To resolve that problem system of artificial neural networks (ANN system) has been developed. An ANN system performs topology recognition based on the measured signal. First, it is necessary to train the system on a sufficient number of samples. The inputs of the ANN system are measured/simulated voltage vectors at each injection point. Each sample of sampled voltage signal is one element of input vector. Points of signal injection and measurement are the same. The input vectors size depends on the sampling rate and the time interval in which measurements are performed. The output vector consists of binary elements which represent whether a transmission line is on or off at the end. This vector

represents network topology. ANN system consists two parts: Decomposer (DANN), and Topology (TANN) artificial neural networks. The main task in the DANN system is to decompose superposition of reflected voltage test signal (injected voltage test signal is half-sine shape and each reflected signal has to be of the same shape). Decomposition is to transform input vectors into vectors of the same size with following elements: amplitudes of every half-sine signal at position of amplitude time stamp, zero for each other positions. In the decomposed vector only amplitudes of the individual reflections remain. DANN system is composed by three major layers: *Locally Connected*, *Dense* and custom-made modified *kSparse*. The *Locally Connected* layer is a convolutional type neural network with different, undivided, weighting factors. The reason for using in this case is to recognize a certain local correlation between individual sampled values of the measured signal. So in the measured signal it is necessary to find the sum of functions of known shape that gives that signal. Also, a neural network system for signal decomposition defined in this way is able to eliminate the influence of signal distortion, since it is designed to convolutionally search for the best function that corresponds to the measured signal, taking into account the function of the injected test signal. Output of *Locally Connected* layer is input in a *Dense* layer. The *Dense* layer is a fully connected neural network with different, undivided, weighting factors. It performs classification on structures derived from convolutional layers such as *Locally Connected*. Last, output layer is custom-made modified *kSparse* which transforms output of the previous, *Dense* layer in a way that n elements with the largest absolute value remain the same and the rest is set to zero. Number n is calculated from input measurement vector and correlates with number of major reflections in observed network. Output of DANN system is vector which consists only amplitudes of each reflections according to reflection time. That vector is input in TANN system. TANN system is built only by one *dense* layer which performs three times in a row. Output of TANN is final topology vector which consists binary values and each value corresponds with switchgear status at transmission line end. In other words, if it is connected to a substation bus connection status is 1, otherwise is 0.

System of ANN described here needs to be properly trained to perform their function. Training process takes place using linear operator $\mathbf{A}$ and very known backpropagation algorithm. Every row of operator $\mathbf{A}$ contains values of one test signal function with amplitude of 1 and amplitude position equal to position of a given row in matrix. Multiplying decomposed vector with such linear operator it is possible to reconstruct measured signal. Training procedure is done by minimizing difference between measured and reconstructed signal. To perform training procedure is need to create pool of known different topologies with known measured

test signals. Best way to creating that pool is simulating different switching conditions using network model.

The test signal is injected and measured only in some, optimally determined nodes. Third subchapter of third chapter deals with optimization procedure for optimize positions to inject and measure voltage test signal. Limitations of proposed method is that is possible to detect topology only in injection point and in all surrounding adjacent nodes. Optimization problem is to find a minimum number of injection nodes to cover entire network. This is done using procedure of setting and solving covering problem: defining variables, setting objective function, setting constraints, and resolving problem with linear integer programming function.

In the **fourth chapter**, the proposed method was tested on one part of the Croatian power system. Test network contains 11 substations interconnected by 15 transmission lines. The test network was modeled in the EMTP program using the real parameters of transmission lines and transformers. By optimizing the test signal injection points, it was obtained that it is optimal to select 5 of 11 positions so that the entire test network is topologically observable. A half-sine wave, amplitude 1000V and duration 50 microseconds, was selected for the test signal. The time span of monitoring one test is 2 ms because that is how much is needed to reflect the signal from the farthest bus in the test part of the network. Signal sampling was performed at a frequency of 2000 kHz which makes 2500 data for the input vector. After selecting the optimal positions for test signal injection, 500 simulations were made for method validation. 400 of them were used in the ANN training process and 100 for the results validation. Connection states for testing and validation were chosen and simulated randomly, without taking into account the possible necessity or technical justification of a particular state. Coincidence of the input and reconstructed signal in the ANN training process is shown. A fairly large match is visible which confirms the correct setup of the neural network system. The efficiency of neural network systems depends on the total amount of input data, and the results show that trend of the loss function decreases as the number of input data increases. 400 input data already gives satisfactory results and with more simulations the results would be even better. Such a small amount of training input data is sufficient because the signal decomposition system contributes to the efficiency of the system. With the DANN system the overall efficiency is 95%, and without the DANN system (only with the TANN system directly) it is only about 71%. The results show that not all switching positions have the same classification rate but that some have a larger one than others. There are many reasons for that such as the number of data in training process, the position in the network and others. The option with optimal threshold selection

gives better results than the one without. The results can also be improved by previous detection of the island operation and by excluding those parts of the network that are previously known to be in a non-energized state. At certain switching points the switching status is predicted with 100% accuracy while the worst result is given by switching point no. 28 with 91% accuracy. Average system efficiency amounts 96%. The results show that out of 100 aggregate topologies, 45% are completely correctly determined, 30% have only one error, and 25% have two or more errors.

Chapter 5 provides concluding considerations in which it has been proven that the measured reflected signal carries information about the topological structure of the power network and that the presented algorithm can extrapolate that information with a certain precision. The overall accuracy of the presented algorithm depends on the number of input data for training ANN system in relation to the number of all possible states. Obtained results show that this algorithm can achieve satisfactory accuracy even on a relatively small number of input data for training all thanks to the DANN system. Because of that, here developed DANN system is the biggest contribution of this research. The overall 96% efficiency in topological processing also represents a contribution to the state estimation process with respect to the response time of the algorithm and obtaining the final topological result. Despite the fact that it is not yet developed to the level of readiness for implementation in the power system, it represents a solid foundation, gives a clear direction and opens the way for future research in the field of topological processing.

Key words: state estimation, power system topology, topology processor, traveling waves, wave reflection, artificial neural networks

SADRŽAJ

1	UVOD.....	1
1.1	Uvodna razmatranja.....	1
1.2	Cilj i hipoteza istraživanja	2
1.2.1	Cilj istraživanja	2
1.2.2	Hipoteza istraživanja.....	2
2	TEORETSKE PODLOGE ZA ISTRAŽIVANJE	4
2.1	Estimacija stanja	4
2.1.1	Klasična estimacija stanja	4
2.1.2	Linearna estimacija stanja.....	12
2.1.3	Hibridna estimacija stanja.....	13
2.2	Topološko procesiranje.....	14
2.2.1	Konvencionalni topološki procesor	14
2.2.2	Složeni topološki procesor.....	19
2.2.3	Reducirani model elektroenergetske mreže	21
2.2.4	Pregled literature	24
2.3	Putujući valovi.....	28
2.3.1	Opći pojmovi i valne jednadžbe	28
2.3.2	Brzina rasprostiranja, prigušenje i izobličenje vala	31
2.3.3	Refleksije i transmisije valova u elektroenergetskoj mreži	32
2.4	Umjetne neuronske mreže	38
2.4.1	Tipovi neuronskih mreža	40
2.4.2	Primjena neuronskih mreža u analizi EES-a.....	42
3	NOVA METODA ZA TOPOLOŠKO PROCESIRANJE U ELEKTROENERGETSKIM MREŽAMA	43
3.1	Metoda za prepoznavanje topologije elektroenergetske mreže interpretacijom refleksije utisnutog naponskog testnog signala	43
3.1.1	Algoritam toka	44

3.1.2	Testni signal.....	46
3.1.3	Propagacija testnog signala.....	47
3.1.4	Interpretacija reflektiranog testnog signala.....	52
3.2	Algoritam za određivanje topologije elektroenergetske mreže bez poznavanja stanja sklopnih aparata	53
3.2.1	Algoritam za dekompoziciju izmjerenog signala	55
3.2.2	Algoritam za određivanje topologije elektroenergetske mreže	65
3.3	Metoda određivanja optimalnih lokacija utiskivanja naponskog ispitnog signala.....	68
3.3.1	Optimizacijski problem.....	68
3.3.2	Analiza topološke promotrivosti sustava.....	75
3.3.3	Analiza mogućnosti pojave izdvojenih otoka i neenergiziranih sabirnica	76
4	REZULTATI ISTRAŽIVANJA.....	77
4.1	Model elektroenergetske mreže.....	77
4.1.1	Pozicije utiskivanja i mjerenja ispitnog naponskog signala	80
4.1.2	Ispitni naponski signal	82
4.2	Rezultati prepoznavanja topologije na modelu elektroenergetske mreže .	83
4.2.1	Simulacije uklopnih stanja.....	83
4.2.2	Obilježja DANN sustava neuronskih mreža	89
4.2.3	Validacija metode	90
4.3	Analiza rezultata	106
5	ZAKLJUČAK.....	109
	LITERATURA	111
	Popis slika.....	122
	Popis tablica.....	124
	Popis kratica	125
	<i>Životopis</i>	126

1 UVOD

1.1 Uvodna razmatranja

U današnjim uvjetima, elektroenergetski sustav (EES) predstavlja vrlo složenu cjelinu gdje planiranje, nadzor i upravljanje moraju udovoljiti brojnim izazovima, kako tehničkim tako i ekonomskim. Ekonomski zahtjevi posljednjih godina sve više dolaze do izražaja u skladu s otvaranjem, deregulacijom i liberalizacijom tržišta električne energije dok intenzivan razvoj i porast potrošnje elektroenergetski sustav čini sve većim i složenijim često s pogonom na granici stabilnosti [1]. Shodno tome, nužna je pravovremena i adekvatna modernizacija EES-a kao odgovor na potrebu brzog odziva EES-a na pretpostavljene tržišne uvjete kao i na sve veće zahtjeve na integraciju alternativnih izvora energije i povećanje energetske efikasnosti. Prijenosna mreža budućnosti, odnosno, napredna prijenosna elektroenergetska mreža (*eng. Smart Transmission Grid*) aktivna je infrastruktura u funkciji pružanja potpore novoformiranom tržištu električne energije, novim odnosima i trendovima u upravljanju električnom energijom te eksploataciji raspoložive infrastrukture i optimizaciji pogona EES-a [2, 3]. U tom smislu naglašena je potreba za vođenjem EES-a u realnom vremenu što kao cilj zahtjeva visoko automatizirane procese te nove i naprednije alate. Kako operativno vođenje EES-a u realnom vremenu zahtijeva poznavanje trenutnog stanja EES-a, koncept *estimacije stanja* osnovni je alat za ostvarivanje automatiziranog, naprednog elektroenergetskog sustava. Funkcija estimacije stanja primarni je alat za nadzor i upravljanje EES-om, a temelji se na prikupljenim podacima iz realnog sustava na kojem je implementirana i utvrđena njegovom topološkom strukturom. Rezultat estimacije stanja je u potpunosti određeno stanje sustava u svakom danom trenutku [4]. Sve napredne funkcije trenutno postojećih sustava za vođenje EES-a, odnosno SCADA/EMS (*Supervisory Control And Data Acquisition/ Energy Management System*) sustava, kao što su analiza sigurnosti i optimalni tokovi snaga, a koje omogućavaju pouzdano i ekonomično vođenje EES-a, značajno ovise o točnosti podataka dobivenih iz proračuna estimacije stanja. Stoga je potrebno uložiti dodatne napore da ta funkcija vraća što preciznije rezultate u što kraćem vremenu proračuna. Određivanje stanja EES-a u realnom vremenu podrazumijeva prikupljanje i filtriranje redundantnog skupa mjerenja uz odbacivanje pogrešno detektiranih mjerenja te na osnovu njegove topološke strukture formiranje rezultata u obliku vektora stanja s varijablama stanja koje predstavljaju fazore napona u svim čvorištima sustava. Time je određeno najvjerojatnije stanje sustava u promatranom trenutku, što je podloga i ulazni podatak za ostale funkcije napredne

elektroenergetske mreže [5, 6, 7]. Jedan od ključnih koraka u provedbi estimacije stanja je određivanje topološke strukture sustava, odnosno topološko procesiranje. Topološko procesiranje je precizno određivanje topologije sustava u svakom određenom trenutku. Topološko procesiranje izvodi se na osnovu ulaznih podataka prikupljenih iz sustava (npr. binarna stanja sklopnih aparata) i korelacija istih s podacima elemenata EES-a. Takva vrsta topološkog procesiranja dugotrajan je proces i jako osjetljiv na ispravne i pravovremene ulazne parametre te je stoga nužno njegovo unaprijeđenje [8, 9]. Ovaj doktorski rad obrađuje novi, u tom smislu unaprijeđen, koncept topološkog procesiranja i usmjeren je na dokazivanje hipoteze da se topološko procesiranje može izvesti dijelom i bez poznavanja uklopnih stanja pojedinih aparata u EES-u što bi zasigurno bio napredak u smislu poboljšanja njegove funkcije.

1.2 Cilj i hipoteza istraživanja

1.2.1 Cilj istraživanja

Cilj predmetnog istraživanja je unaprijediti postojeće metode topološkog procesiranja u provedbi estimacije stanja.

Unaprijeđenje postojećih metoda ostvaruje se u smislu: sinkronizacije prikupljanja ulaznih podataka, ubrzanja procesa prikupljanja ulaznih podataka, ubrzanja procesa obrade prikupljenih ulaznih podataka kao i optimizacije infrastrukture i troška topološkog procesiranja.

1.2.2 Hipoteza istraživanja

Hipoteza predmetnog istraživanja glasi: *staničnu i mrežnu topologiju u svrhu estimacije stanja moguće je odrediti pravilnom interpretacijom utisnutog testnog naponskog signala.*

Utisnuti naponski testni signal rasprostire se elektroenergetskom mrežom u obliku putujućeg vala. Svojstvo putujućeg vala u elektroenergetskoj mreži refleksija je i transmisija u točkama promjena valne impedancije tj. impedantnih diskontinuiteta. Promjena valne impedancije događa se ponajprije u čvorištima sustava (sabirnicama u transformatorskim stanicama) i ovisi o veličini valne impedancije svakog pojedinog incidentnog voda na predmetnom čvorištu. Valna impedancija svakog pojedinog voda ovisi isključivo o njegovim konstrukcijskim parametrima. Funkcija reflektiranog vala stoga nosi informaciju o valnim impedancijama u točki refleksije te je donosi u polazišnu točku. Preciznim očitanjem te

pravilnom interpretacijom reflektiranog signala moguće je odrediti topološku strukturu u čvorištu sustava koje je ujedno i mjesto nastanka refleksije.

Zbog boljeg razumijevanja predmetne problematike, u narednom poglavlju dane su teoretske podloge vezane uz estimaciju stanja, putne valove i umjetne neuronske mreže koje se koriste za interpretaciju reflektiranog signala. Teoretske podloge dane su s referenciranom literaturom te prikazom dosadašnjih znanstvenih i praktičnih postignuća na tom području. Obzirom da je ovo istraživanje usmjereno na unaprjeđenje funkcije topološkog procesiranja za to je područje posebno dan kronološki pregled literature.

2 TEORETSKE PODLOGE ZA ISTRAŽIVANJE

2.1 Estimacija stanja


Estimacija stanja u osnovi je proces pri kojem se, korištenjem raspoloživog skupa mjerenja iz EES-a, određuje najvjerojatnije stanje tog sustava u promatranom trenutku [5]. Stanje sustava definiraju varijable stanja koje čine vektor stanja tj. skup relativnih fazora napona u svim čvorištima sustava što je podloga za konačni izračun najvjerojatnijih tokova snaga u njegovim granama. Razvojem procesa estimacije stanja, vidljivo u [5 - 15], postoji više konceptualnih pristupa estimaciji stanja:

- Klasična, konvencionalna estimacija stanja,
- Estimacija stanja temeljena na tehnologiji sinkroniziranih mjerenja fazora (linearna estimacija),
- Kombinacija klasične i linearne estimacije (hibridna estimacija).

2.1.1 Klasična estimacija stanja

Koncept estimacije stanja u klasičnom obliku postoji već desetljećima i još uvijek je temelj za razvoj naprednih programskih rješenja u prijenosnim mrežama s težnjom za vođenjem sustava u realnom vremenu [16]. Početak estimacije započinje prikupljanjem podataka tj. mjerenjem ulaznih parametara. Obzirom da svako mjerenje neophodno sadrži i mjernu pogrešku, jedan od osnovnih preduvjeta za pouzdanu, odnosno najbolju, estimaciju stanja je eliminacija mjerne pogreške sadržane u ulaznim podacima. Dodatno, samoj estimaciji stanja prethode, odnosno paralelno se njome izvode, određene pozadinske funkcije neophodne za ispravnu i pouzdanu estimaciju stanja, a pojednostavljeni dijagram toka prikazan je na slici 2.1. Kao što je vidljivo sa slike, estimacija stanja sadržava procese:

- topološkog procesiranja,
- analize promotrivosti sustava,
- detekcije mjernih pogrešaka.



Slika 2.1 Funkcije estimatora stanja

Konačan rezultat estimacije su varijable stanja tj. amplitude i kutovi (fazori) napona u svim čvorištima sustava te prijenosni omjeri po iznosu i kutu svih transformacija u promatranom sustavu [5].

2.1.1.1 Proces estimacije stanja metodom najmanjih kvadrata

Konvencionalno, estimacija stanja kao ulaz koristi mjerenja koja obuhvaćaju [10]:

- analogna mjerenja iznosa napona i struja (iznos djelatne i jalove snage)
- signalizaciju statusa prekidača i sklopne opreme,
- pseudomjerenja, odnosno predviđene vrijednosti proizvodnje i potrošnje, kao i nulte injekcije u pasivnim čvorištima (eng. *zero-injection*, čvorište bez proizvodnje i tereta).

Podaci se iz mjernih uređaja putem komunikacijske infrastrukture prikupljaju koristeći ICCP (eng. *Inter-Control Center Communications Protocol*) i centralno se pohranjuju u bazi podataka SCADA sustava [17]. Mjerenja ponekad nisu dostupna u promatranom trenutku ili zbog ekonomičnosti uopće ne postoje na određenoj poziciji te k tome nisu sva prikupljena u sinkrono istom trenutku već u periodu između dva ciklusa prikupljanja koje može biti u vremenskom razmaku od nekoliko sekundi [18]. Ukoliko broj i raspored mjerenja omogućavaju određivanje vektora varijabli stanja sustav smatramo promotrivim (opservabilnim, sagledivim) [18, 19]. Prikupljeni mjerni podaci sadrže i određeni stupanj redundancije u skladu s čim estimaciju stanja možemo kategorizirati kao predefiniranu, definiranu i poddefiniranu, ovisno da li je broj mjerenja tj. neovisnih jednadžbi stanja veći, jednak ili manji od broja varijabli stanja [5, 20]. Predefinirana estimacija, odnosno, predefiniran sustav sadrži više informacija tj.

izmjerenih podataka od minimalno nužnog broja za određivanje varijabli stanja. Takav sustav sadrži redundantna mjerenja kojima je moguće umanjiti vjerojatnost pogreške prilikom uzorkovanja i prijenosa podatka ili nadomjestiti nedostatak ukoliko je neka od izmjerenih vrijednosti privremeno nedostupna. Definiran sustav sadrži točan broj ulaznih podataka koliko je minimalno potreban za potpunu promotrivost sustava tj. ima jednak broj izmjerenih vrijednosti kao i varijabli stanja. Poddefinirani sustav sadrži manji broj mjerenih vrijednosti od traženih varijabli stanja i time je nepromotriv ili parcijalno promotriv, odnosno moguće je samo jednoznačno odrediti varijable stanja u ograničenom dijelu sustava. Takva situacija događa se prilikom nepostojanja ili nedostupnosti neredundantnog mjerenja. Neredundantno mjerenje naziva se i *kritičnim mjerenjem*, a njegov izostanak rezultira gubitkom potpune promotrivosti. *Kritičan par* predstavljaju dva redundantna mjerenja, od kojih niti jedno nije kritično, dok *kritičnu n-torku* čini više redundantnih mjerenja, a čije uklanjanje rezultira potpunom ili djelomičnom nepromotrivošću sustava, a od kojih niti jedno ne pripada nižem redu kritičnosti [4 - 22].

Kao što je rečeno, predefiniran sustav sadrži veći broj informacija tj. veći broj mjerenih podataka od neophodnog broja za izračun varijabli stanja, međutim takav dodatni broj mjerenja se ne odbacuje kao višak budući da u sebi nosi korisne informacije u smislu zamjene s nedostupnim redundantnim mjerenjem, ali i u smislu detekcije i korekcije mjerne pogreške. Ako je m broj dostupnih mjerenja, a n broj traženih varijabli stanja preporučeni faktor redundancije (m / n) je između 1,4 i 2,5 [23], dok minimalni broj mjerenja u estimaciji stanja mora biti jednak broju varijabli stanja ($m \geq n$). Predefinirani sustav smatra se potpuno promotrivim kada postoji jedno jedinstveno rješenje za varijable stanja, ali obzirom da u proračun estimacije stanja ulazi samo broj podataka koji je minimalno potreban za izračun varijabli stanja postoji više mogućih rješenja. Za odabir najboljeg rješenja tj. najbolje estimacije iz preodređenog skupa, kao i za minimizaciju nužno prisutnih mjernih pogrešaka, najčešće se koristi kriterij najmanjih kvadrata (*WLS – Weighted Least-Squares*) [24]. WLS je nelinearna metoda koja koristi nesinkronizirana mjerenja iz SCADA sustava, a za cilj ima minimiziranje sume kvadrata težinskih odstupanja estimiranog mjerenja od stvarne vrijednosti. U ovoj metodi pretpostavlja se da vrijednost greške u svakom mjerenju može biti podjednako vjerojatna kako pozitivna tako i negativna [5,23,24]. Osim toga, pretpostavka je da vjerojatnost kvadrata greške ima normalnu (Gaussovu) razdiobu sa standardnom devijacijom σ te da je korelacija između mjerenja jednaka nuli. Kako izmjerena vrijednost sadrži pogrešku, taj podatak može se prikazati kao:

$$z_m = z_t + \eta \quad (2.1)$$

gdje je z_m izmjerena vrijednost, z_t točna vrijednost, a η slučajna greška koja predstavlja mjernu nesigurnost. Mjerna nesigurnost η slučajan je broj i podliježe Gauss-ovoj (normalnoj) razdiobi prema relaciji:

$$\text{PDF}(\eta) = \frac{1}{\sigma\sqrt{2\pi}} e^{(-\frac{\eta^2}{2\sigma^2})} \quad (2.2)$$

gdje je σ standardna devijacija, σ^2 varijanca slučajnog broja, a *PDF* (eng. *Probability Density Function*) funkcija gustoće vjerojatnosti [5, 25]. Funkcija *PDF* opisuje ponašanje slučajne greške η . Standardna devijacija σ opisuje raspršenost podataka, odnosno prosječno odstupanje od srednje vrijednosti i osigurava način da se modelira važnost slučajne greške u mjerenju. U WLS metodi točnija mjerenja s većim težinskim faktorima više utječu na konačan rezultat, obzirom da se težinski faktor pojedinog mjerenja određuje prema točnosti mjernog uređaja u vidu standardne devijacije mjerenja. Pojednostavljeno, ako je σ veliko, mjerenje je relativno netočno, dok mala vrijednost σ označava i malu mjernu pogrešku. Metoda najmanjih (težinskih) kvadrata daje nam način da svakom mjerenju pridružimo pripadajuću težinsku mjeru ovisno o njegovoj kvaliteti. Razrada WLS metode dana je literaturom [4, 5, 26-30], a može se zaključiti da je kriterij maksimalne vjerojatnosti u estimaciji nepoznatog parametra uvijek predstavljen kao vrijednost parametra koji daje minimum sume kvadrata razlike između izmjerene vrijednosti i točne vrijednosti (predstavljene kao funkcija nepoznatog parametra), pri čemu je svaki kvadrat te razlike podijeljen sa varijancom greške mjerenja (tj. dana mu je težinska mjera) [25-33].

Informacije o uklopnom stanju sklopne opreme i povezanosti elementa koriste se prilikom topološkog procesiranja tj. formiranja matrice admitancija sustava i strukture mreže, čime se dobiva model EES-a. Funkcija topološkog procesiranja detaljno je objašnjena u narednim poglavljima.

2.1.1.2 Matematička formulacija

Estimacija stanja je dakle proces kojim je moguće eliminirati utjecaj pogreške ulaznih parametara, filtrirati redundantne podatke te naposljetku potpuno odrediti stanje sustava procjenom stvarnih vrijednosti fazora napona u svim čvorištima sustava [5]. Ukoliko se

pretpostavi matematički sustav s n nepoznanica (varijabli stanja) i m ulaznih podataka (mjerenja), njihova međusobna relacija dana je izrazom:

$$\mathbf{z} = \mathbf{h}(\mathbf{x}) + \boldsymbol{\varepsilon} \quad (2.3)$$

gdje je:

$\mathbf{z}$ – vektor ulaznih mjerenja, dimenzije $(m \times 1)$,

$\mathbf{x}$ – vektor varijabli stanja, dimenzije $(n \times 1)$,

$\mathbf{h}(\mathbf{x})$ – matrica nelinearnih funkcija koja opisuje relaciju ulaznih mjerenja i vektora stanja dimenzije $(m \times n)$,

$\boldsymbol{\varepsilon}$ – vektor mjerne pogreške, dimenzije $(m \times 1)$.

Uz pretpostavku matematički neovisnih mjerenja, estimacija stanja opisuje se kao optimizacijski problem s funkcijom cilja i određenim ograničenjima [5]. Naime, potrebno je, kao funkciju cilja, minimizirati mjernu pogrešku što se matematički može opisati:

$$\min f(\mathbf{z} - \mathbf{h}(\mathbf{x})) \quad (2.4)$$

Uz normalnu razdiobu mjerne pogreške $\varepsilon_i \sim N(0, \sigma_j^2)$ funkcija cilja može se zapisati kao $J(\mathbf{x})$ i određena je kao suma kvadrata pogrešaka s određenim težinskim faktorom, odnosno kao razlika mjerenih i estimiranih vrijednosti:

$$\min_{\mathbf{x}} J(\mathbf{x}) = \frac{1}{2} \sum_{j=1}^m \left(\frac{z_j - h_j(\mathbf{x})}{\sigma_j} \right)^2. \quad (2.5)$$

$J(\mathbf{x})$ moguće je zapisati i u matričnom obliku:

$$J(\mathbf{x}) = \frac{1}{2} [\mathbf{z} - \mathbf{h}(\mathbf{x})]^T [\mathbf{R}]^{-1} [\mathbf{z} - \mathbf{h}(\mathbf{x})] \quad (2.6)$$

gdje je $[\mathbf{R}]$ matrica kovarijanci pogrešaka (*Measurement Error Covariance Matrix*) [5]. U slučaju matematičke neovisnosti mjernih podataka, a time i pogrešaka, $[\mathbf{R}]$ je dijagonalna matrica s elementima σ_j^2 , a $[\mathbf{R}]^{-1}$ je dijagonalna matrica težinskih faktora $1/\sigma_j^2$ (*Weighting Matrix*). Obzirom na nelinearnost između varijabli stanja, estimirani vektor $\mathbf{x}$ dobiva se iterativnim postupkom:

$$\mathbf{G}(\mathbf{x}^k)\Delta\mathbf{x}^k = -\mathbf{g}(\mathbf{x}^k) \quad (2.7)$$

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \Delta\mathbf{x}^k \quad (2.8)$$

gdje je $\mathbf{g}(\mathbf{x})$ gradijent matrične funkcije $\mathbf{J}(\mathbf{x})$, a $\mathbf{G}(\mathbf{x})$ matrica multiplikacije (*Gain Matrix*) koja ovisi o korištenoj metodi iterativnog postupka minimizacije funkcije cilja (*Gauss-Newton* ili *Newton-Raphson*). Minimum funkcije cilja $\mathbf{J}(\mathbf{x})$ dobiva se iz uvjeta da su sve parcijalne derivacije po svim promjenjivim varijablama jednake nuli, a što je identično s uvjetom da je gradijent funkcije $\mathbf{J}(\mathbf{x})$, $\mathbf{g}(\mathbf{x})$, jednak nuli:

$$\mathbf{g}(\mathbf{x}) = \frac{\partial J(\mathbf{x})}{\partial \mathbf{x}} = -\sum_{j=1}^m \left(\frac{z_j - h_j(\mathbf{x})}{\sigma_j} \right) \frac{\partial h_j(\mathbf{x})}{\partial \mathbf{x}} = 0. \quad (2.9)$$

Rješenje nelinearne jednadžbe (2.9) rješava se jednom od iterativnih metoda, najčešće Newton-Raphson-ovom metodom. Razvojem u Taylor-ov red u okolini točke $\mathbf{x} = \mathbf{x}_0$ te zanemarujući članove višeg reda, aproksimira se gradijent funkcije:

$$\mathbf{g}(\mathbf{x} + \Delta\mathbf{x}) \cong \mathbf{g}(\mathbf{x}) + \mathbf{G}(\mathbf{x})\Delta\mathbf{x} \quad (2.10)$$

gdje je $\mathbf{G}(\mathbf{x})$ Jakobijeva matrica $\mathbf{g}(\mathbf{x})$:

$$\mathbf{G}(\mathbf{x}) = \frac{\partial \mathbf{g}(\mathbf{x})}{\partial \mathbf{x}} = \frac{\partial^2 J(\mathbf{x})}{\partial \mathbf{x}^2} = \sum_{j=1}^m \sigma_j^{-1} \frac{\partial h_j(\mathbf{x})}{\partial \mathbf{x}} \left(\frac{\partial h_j(\mathbf{x})}{\partial \mathbf{x}} \right)^T - \sum_{j=1}^m \sigma_j^{-1} \Delta\mathbf{z} \frac{\partial^2 h_j(\mathbf{x})}{\partial \mathbf{x}^2}. \quad (2.11)$$

gdje je $\Delta\mathbf{z} = \mathbf{z} - \mathbf{h}(\mathbf{x})$. Ako je $\partial \mathbf{h} / \partial \mathbf{x} = \mathbf{H}(\mathbf{x})$, koristeći (2.10) i (2.11) rješenje može biti napisano u matričnom obliku:

$$\Delta\mathbf{x} = \mathbf{G}^{-1}(\mathbf{x})\mathbf{H}^T(\mathbf{x})\mathbf{R}^{-1}\Delta\mathbf{z}(\mathbf{x}). \quad (2.12)$$

Zbog:

$$\sum_{j=1}^m \sigma_j^{-1} \frac{\partial h_j(\mathbf{x})}{\partial \mathbf{x}} \left(\frac{\partial h_j(\mathbf{x})}{\partial \mathbf{x}} \right)^T = \mathbf{H}^T(\mathbf{x})\mathbf{R}^{-1}\mathbf{H}(\mathbf{x}) \quad (2.13)$$

korak iterativnog postupka za izračun vektora varijabli stanja dobivamo jednadžbom:

$$\Delta \mathbf{x} = \left(\mathbf{H}^T(\mathbf{x})\mathbf{R}^{-1}\mathbf{H}(\mathbf{x}) - \sum_{j=1}^m \sigma_j^{-1} \Delta \mathbf{z}_j \frac{\partial^2 h_j(\mathbf{x})}{\partial \mathbf{x}^2} \right)^T \mathbf{H}^T(\mathbf{x})\mathbf{R}^{-1}\Delta \mathbf{z}(\mathbf{x}). \quad (2.14)$$

Druga derivacija u (2.14) pojavljuje se samo u nelinearnim modelima sustava, s napomenom da je u velikoj većini slučajeva utjecaj tog člana u konvergenciji estimacije zanemariv [5,26]. Zanimarivanjem istog, izraz (2.14) postaje:

$$\Delta \mathbf{x} = \left(\mathbf{H}^T(\mathbf{x})\mathbf{R}^{-1}\mathbf{H}(\mathbf{x}) \right)^T \mathbf{H}^T(\mathbf{x})\mathbf{R}^{-1}\Delta \mathbf{z}(\mathbf{x}). \quad (2.15)$$

Svaki novi član vektora varijabli stanja $\mathbf{x}$ u iterativnom postupku računa se prema relaciji (2.8), a postupak se ponavlja sve dok funkcija $g(\mathbf{x})$ iz (2.7) ne postane približno jednaka nuli. Time je estimiran vektor traženih varijabli stanja i proces estimacije je završen [4-34].

2.1.1.3 Detekcija i identifikacija mjerne pogreške

Ukoliko estimacija stanja rezultira varijablama stanja koje nisu unutar zadane točnosti može se zaključiti da je došlo ili do pogreške prilikom mjerenja tj. uzorkovanja podatka ili da rezultirajući vektor nije moguće dobiti postavljenim modelom estimacije iz dostupnih mjernih podataka [5]. U prvoj varijanti dolazi do slučajnih, sustavnih ili grubih mjernih pogrešaka. Slučajne mjerne pogreške događaju se uslijed konačne točnosti mjernih i komunikacijskih uređaja, sustavne greške rezultat su nesavršenih mjernih metoda dok grube greške nastaju uslijed kvarova u mjernom sustavu, pogrešnog očitavanja ili nesinkronizma podataka [35]. Estimacija stanja, uz pretpostavku preodređenog sustava, može identificirati, lokalizirati te odbaciti grubu mjernu pogrešku bez značajne posljedice na kvalitetu rezultata estimacije. Odgovarajućim izborom redundantnih mjerenja moguća je ispravna detekcija i identifikacija grubih mjernih grešaka [36]. Prilikom detekcije i identifikacije grubih mjernih pogrešaka u svakom ciklusu postupka koriste se ostaci (*eng. Residual*), odnosno razlike mjerenih i estimiranih vrijednosti:

$$\mathbf{r} = \mathbf{z} - \mathbf{h}(\mathbf{x}) \quad (2.16)$$

gdje $\mathbf{r}$ predstavlja vektor ostatka (*residual*) dimenzija $(m \times 1)$.

Obzirom da je sama funkcija cilja estimacije stanja jednaka razlici mjerenih i estimiranih vrijednosti, može se zapisati:

$$J(x) = \sum_{j=1}^m R_{jj}^{-1} e_j^2 = \sum_{j=1}^m (e_j^N)^2 \quad (2.17)$$

Za detekciju grube mjerne pogreške najčešće je korišten statistički χ^2 test, odnosno hi-kvadrat test (*eng. Chi-Squares Test*) [37]. Ukoliko su slučajne pogreške raspodijeljene po normalnoj razdiobi $e_i \sim N(0, \sigma_j^2)$, normirane pogreške imati će standardnu normalnu razdiobu $e_i^N \sim N(0, 1)$, dok će $J(x)$ imati χ^2 razdiobu s najviše $(m-n)$ stupnjeva slobode, obzirom da najmanje n mjerenja mora zadovoljiti jednadžbe snage, što daje $m-n$ linearno nezavisnih pogrešaka. Indikator postojanja grube pogreške u skupu mjerenja je konačna vrijednost funkcije cilja $J(x)$ veća od unaprijed zadane granice $\chi_{(m-n)p}^2$. U tom se slučaju sa pouzdanošću p smatra da postoji gruba pogreška u skupu mjerenja [37-40].

Metoda najmanjih težinskih kvadrata (*WLS*) nakon detekcije identificira i odbacuje grubu mjernu pogrešku, nakon čega slijedi ponovna estimacija stanja [5]. Metoda najvećeg normiranog ostatka (*eng. Largest Normalized Residual - LNR*) može poslužiti prilikom identifikacije jednostruke grube pogreške. Ostaci (*residuals*) raspodijeljeni su po normalnoj razdiobi $r_i \sim N(0, \Omega)$, gdje je $\Omega(x)$ matrica kovarijanci ostataka (*eng. Residual Covariance Matrix*). Normirani ostaci dobivaju se primjenom izraza:

$$r_j^N = \frac{|r_j|}{\sqrt{\Omega_{jj}}} \quad (2.18)$$

$$\Omega(x) = (I - H(x) \cdot G^{-1}(x) \cdot H^T(x) \cdot R^{-1}) \cdot R \quad (2.19)$$

gdje je I jedinična matrica. Estimator stanja odbacuje mjerenje s *LNR* nakon čega slijedi novi ciklus estimacije stanja [41]. Postupak se ponavlja do odbacivanja svih mjerenja s grubim pogreškama, uz uvjet da je sustav promotriv.

2.1.1.4 Topološki procesor

Topološki procesor element je estimatora stanja u kojem se provodi determinacija topologije (povezanosti) elektroenergetske mreže koja je nužna za formulaciju matrice funkcija $h(x)$ koja opisuje relaciju ulaznih mjerenja i vektora stanja. Također, istim se provodi i determinacija pozicija mjernih uređaja u elektroenergetskoj mreži, odnosno determinacija

pozicije ulaznih parametara za provedbu estimacije stanja. Taj proces determinacije naziva se topološko procesiranje i vrlo je važan korak u provedbi estimacije stanja [42-45]. Neispravna i nepravovremena determinacija topologije elektroenergetske mreže jedan je od najvećih problema prilikom estimacije stanja obzirom da pogrešna topologija često dovodi do divergencije numeričkog estimacijskog algoritma, a gotovo redovito do bitno smanjene točnosti estimiranih varijabli stanja [46]. Funkcija topološkog procesiranja izvodi se paralelno s prikupljanjem mjernih podataka i preduvjet je za analizu promotrivosti sustava, a posljedično i cijelu provedbu estimacije stanja [4, 5, 47-55]. Dosada poznati koncepti, algoritmi i funkcije topološkog procesiranja obrađeni su u Poglavlju 2.2.

2.1.2 Linearna estimacija stanja

Zbog vremenskog trajanja iterativnog postupka kao i zbog asinkronizma prilikom prikupljanja ulaznih podataka pomoću SCADA sustava rezultat estimacije stanja zapravo je aproksimacija prosječnog stanja EES-a u određenom vremenskom intervalu [5, 11-14, 56, 57]. Vremenski interval za svaki konkretan slučaj različit je, započinje prvim prikupljenim ulaznim podatkom i završava rezultirajućim vektorom stanja, a može biti u trajanju i do nekoliko sekundi. Uslijed aktivacije relejne zaštite ili bilo koje druge brze promjene stanja u EES-u, zbog trajanja estimacijskog postupka i nesinkroniziranog prikupljanja ulaznih podataka, dolazi do nekonzistencije estimiranih varijabli stanja [58-62]. Tada je pouzdani rezultat estimacije stanja najčešće moguće dobiti tek nakon uspostave stacionarnog stanja, što u visokoautomatiziranom načinu vođenja EES-a može znatno otežati postupak povratka u normalno pogonsko stanje [4, 5].

Tehnologijom sinkroniziranih mjerenja fazora predstavljenom 80-tih godina 20. stoljeća teoretski je moguće ostvariti dinamičku estimaciju stanja u realnom vremenu [63]. Sinkronizirano mjerenje fazora (napona ili struje) ostvaruje se pomoću PMU (*eng. Phasor Measurement Unit*) uređaja vremenski međusobno sinkroniziranih pomoću GPS (*eng. Global Positioning System*) sustava. PMU uređaji na taj način direktno mjere fazore npr. napona obzirom da je vremenskom sinkronizacijom postignuto da je poznat njihov relativni kut [64]. Estimator stanja koji koristi podatke iz PMU uređaja kao ulazne podatke zapravo ne estimira stanje već ga mjeri [11-14][18]. U slučaju dovoljnog broja PMU uređaja u čvorištima EES-a stanje sustava tada je moguće dobiti rješavanjem linearnog sustava jednadžbi bez potrebe za iterativnim postupkom što u konačnici bitno ubrzava proces same estimacije [65, 66]. Implementacija PMU uređaja predstavlja poboljšanje u smislu promotrivosti sustava, a samim time i proračuna estimacije stanja. Ukoliko u sustavu postoji dovoljno PMU uređaja da je cijeli

sustav pokriven isključivo s PMU uređajima, tada se proračun estimacije stanja može definirati linearnim modelom [11,12]. U slučaju proračuna estimacije stanja s isključivo ulaznim podacima iz PMU mjerenja, relacija između mjerenih fazora i vektora sustava postaje linearna i može se opisati slijedećom jednačinom:

$$\mathbf{z} = \mathbf{H} \cdot \mathbf{x} + \boldsymbol{\varepsilon} \quad (2.20)$$

gdje je $\mathbf{z}$ vektor izmjerenih vrijednosti fazora napona i struja u obliku kompleksnog broja, $\mathbf{H}$ je izmjerena Jakobijeva matrica koja predstavlja funkciju parametara mreže, dakle konstantna, $\mathbf{x}$ je vektor kompleksnih varijabli stanja tj. vrijednosti fazora napona, a $\boldsymbol{\varepsilon}$ je mjerna pogreška [5].

Jedan od ograničavajućih faktora u realizaciji takvog, linearnog, estimatora stanja je cijena takvog sustava osobito u slučaju EES-a s velikim brojem čvorišta. Također, u slučaju nepostojanja redundantnih mjerenja nije moguće detektirati i identificirati grube pogreške mjerenja kao niti nadomjestiti pojedino mjerenje [5,19]. Važno je uzeti u obzir da mala pogreška pri mjerenju kuta napona ima veliki utjecaj na konačni izračun tokova snaga.

2.1.3 Hibridna estimacija stanja

Kombiniranjem pozitivnih karakteristika obaju pristupa pri estimaciji stanja moguće je poboljšati točnost, robusnost, sposobnost detekcije i eliminacije mjernih pogrešaka, te skratiti vrijeme proračuna estimacije stanja [66, 67]. Načini kombiniranja podacima i procesima klasičnih i linearnih estimacija stanja nisu jednoznačni. Hibridne varijante najčešće se izvedu na način da se konvencionalni estimator nadogradi PMU mjerenjima ili da se linearni estimator koji koristi PMU mjerenja nadopuni transformiranim mjerenjima iz SCADA sustava [80, 81]. Nadopuna ulaznih podataka može biti manjeg ili većeg obima, a dodatni podaci mogu se koristiti kao redundantni. Također, u preodređenom sustavu moguće je pridijeliti veći težinski faktor mjerenjima za koje se smatra da su veće preciznosti (npr. redundantno mjerenje dobiveno PMU uređajem može imati veći težinski faktor u odnosu na mjerenje iz SCADA sustava). Mjerenja dobivena pomoću PMU uređaja moguće je i indirektno koristiti na način da se, pomoću tako dobivenih mjerenja, izračunavaju parametri mreže nužno korišteni u konvencionalnoj estimaciji stanja [67-70].

2.2 Topološko procesiranje

Poznavanje topološke strukture elektroenergetskog sustava i korištenje istog u procesima estimacije stanja naizgled je trivijalan problem. Takav dojam ponajprije se stječe zbog intuitivnog zaključka da su informacije o uklopnom stanju pojedinog sklopnog aparata jednostavno dostupne, a poznavanje istih određuje topološku strukturu – npr. isključen prekidač predstavlja i isključen dalekovod. U stvarnosti to ipak nije jednostavno. Dinamička, brza, estimacija stanja zahtijeva i brzo topološko procesiranje posebno u slučajevima promjenjivog, nestacionarnog stanja kada je mnoštvo sklopnih operacija, a time i promjena topološke strukture sustava. Proces prikupljanja i obrade podataka u tim slučajevima zahtijeva i određeno trajanje koje je najčešće duže od trajanja same estimacije stanja. Također, nesinkronizam prilikom prikupljanja podataka dovodi do situacije u kojoj topološko procesiranje prilikom promjena topološke strukture rijetko može imati stvarne ulazne podatke koji odgovaraju realnom topološkom stanju sustava u danom trenutku. Uglavnom, cilj topološkog procesiranja u dinamičkim sustavima ispravno je prepoznati i u najkraćem vremenu procesuirati promjene prilikom sklopnih operacija te kao rezultat vratiti ispravno topološko stanje sustava koje služi kao preduvjet provedbi estimacije stanja.

2.2.1 Konvencionalni topološki procesor


U određenom elektroenergetskom sustavu topološki procesor determinira trenutni model mreže, odnosno, trenutnu povezanost elemenata elektroenergetske mreže (*eng. connectivity*) i pozicije mjernih uređaja odnosno pozicije ulaznih podataka. Konvencionalni topološki procesori koriste bazu podataka SCADA sustava za determinaciju lokacije mjernih uređaja te akviziciju binarnih stanja sklopnih aparata [5, 19]. U suštini, konvencionalni topološki procesor iz binarnih stanja sklopnih aparata mreže te poznatog cjelovitog modela mreže (ukupna topološka struktura) determinira trenutno stanje povezanosti određenih mrežnih elemenata (*eng. bus-branch connectivity*). Cjeloviti model mreže određen je samom fizičkom konstrukcijom elektroenergetskog sustava i on je time definiran na promatranom području. Binarni statusi sklopnih aparata (prekidača i rastavljača) daljinski se prenose komunikacijskim putem u bazu podataka SCADA sustava iz koje se koriste u topološkom procesiranju.

Pri konvencionalnom pristupu topološko procesiranje podijeljeno je u dva koraka [5]:


1. Transformacija fizičkog u matematički model,
2. Pridjeljivanje mjernih točaka matematičkom modelu.

Transformacija fizičkog u matematički model podrazumijeva procesiranje prikupljenih podataka i znanog cjelovitog modela mreže u model mreže s čvorištima i linijama tj. konekcijski model (eng. *bus-section/switching device model to bus/branch model*). Model mreže s čvorištima i linijama pogodan je za definiranje matrice admitancija čvorišta tj. za potpuno matematičko modeliranje mreže i korištenje pri estimaciji stanja [5, 18 – 20]. Inače, pri konvencionalnom pristupu estimaciji stanja, problem modeliranja dinamičkih sustava iz dostupnog seta ulaznih podataka podijeljen je u dvije osnovne cjeline: procesiranje logičkih (binarnih) podataka (npr. statusi sklopnih aparata) i procesiranje analognih podataka (npr. tokovi snaga, iznosi napona...) [5]. Topološko procesiranje koristeći logičke statuse sklopnih aparata te funkcije digitalne logike iz fizičkog modela mreže vraća konekcijski model mreže s čvorištima i linijama (eng. *bus-branch model*) koji se potom koristi u analizi promotrivosti i samoj estimaciji stanja kao funkcijama koje implementiraju analogne podatke u tako priređeni model. Sam sukus topološkog procesiranja prikazan je na slikama 2.2. i 2.3. slika 2.2. predstavlja ulazni model na fizičkoj razini nalik jednopolnoj shemi elektroenergetske mreže (eng. *bus-section/switching-device model*) dok slika 2.3. predstavlja grafički rezultat topološkog procesiranja u obliku konekcijskog modela. Slika 2.3. prikaz je slike 2.2. nakon provedenog topološkog procesiranja u slučaju kada su svi sklopni elementi označeni na slici 2.2 u zatvorenom stanju.

Prvi korak pri provedbi topološkog procesiranja analizirati je ulazne podatke te konvertirati prikupljene, sirove podatke na odgovarajuću veličinu i vrijednost. Potom je potrebno provesti određene radnje u smislu verifikacije i detektiranja određenih operativnih ograničenja, nemogućih i nefizikalnih uvjeta ili jednostavnih mjernih nekompatibilnosti kao što je postojanje struje (toka snage) kroz otvoreni rastavljač ili postojanje pada napona na zatvorenom prekidaču [5].




Slika 2.2 Ulazni model sa sklopnim aparatima (bus-section/switching device model)



Slika 2.3 Konekcijski model s čvorištima i linijama (bus-branch model)

Konvencionalno, podaci se analogno prenose komunikacijskom putem do baze podataka, ali pojavom numeričkih uređaja kao što su terminali polja ili PMU uređaji moguće je digitalno prenijeti potrebne podatke s puno većom brzinom i preciznošću.

Nakon prikupljanja ulaznih podataka određuje se međusobna povezanost određene grupe ili cijele skupine sabirnica. Sklopni aparati (prekidači i rastavljači) u zatvorenom položaju između dviju sabirnica povezuju iste u jednu cjelinu koja se tada može smatrati cjelovitom sabirnicom te iz topološkog aspekta predstavlja jedno te isto čvorište odnosno jednu sekcijску grupu (*eng. section group*) [5]. Kao primjer navedenom moguće je razmotriti sliku 2.4. koja prikazuje jednu sabirničku grupu sa dva sustava glavnih sabirnica te jednim pomoćnim sabirnicama. Zatvoreni položaj svih sklopni aparata na slici 2.4 implicira da sve naznačene sabirnice predstavljaju jednu sekcijску grupu odnosno jedno jedinstveno čvorište. Sekcijske grupe određuju se pri samom početku topološkog procesiranja i u narednim procesima koriste se kao relevantna i cjelovita struktura.



Slika 2.4 Primjer sabirničkog sustava

Povrh određivanja sabirničkih grupa potrebo je odrediti i međusobnu povezanost preostalih elemenata elektroenergetskog sustava kao što su vodovi (dalekovodi), transformatori, *phase shifteri*, kondezatorske baterije, kompezatori, generatori, mjerni transformatori i ostali. Zatvoreni sklopni aparati u pripadajućem polju mrežnog elementa predstavljaju povezanost elementa sa određenom sekcijskom grupom. Nakon određivanja statusa sklopnih aparata na terminalima svih mrežnih elemenata svaki od njih pridjeljuje se pripadajućoj sekcijskoj grupi. Time je dobivena reducirana struktura elektroenergetske mreže sastavljena od točaka (sabirničkih grupa, transformatora, generatora...) i linija među njima (vodova) [42, 71].

Nakon navedenog koraka potrebno je provesti analizu povezanosti (*eng. Network Connectivity Analysis*) te odrediti (identificirati) dijelove mreže tj. otočne pogone koji mogu biti pod naponom, bez napona ili uzemljeni. Topološki procesor stvara dvije podatkovne strukture: podatkovnu strukturu sa sabirnicama i vodovima (čvorišta i linije) te strukturu s mrežom i mrežnim uređajima (generatorima, transformatorima...) [5]. Prilikom provedbe navedenih procesa dio inicijalne, originalne mreže se gubi, odnosno mreža se reducira na osnovne elemente. U tom procesu moguće je da je eliminirana i originalna, stvarna pozicija mjernih uređaja koji sudjeluju u kasnijem procesu estimacije stanja. Kada je god to moguće

potrebno je povratiti tj. ponovno odrediti poziciju istih na konačnom, reduciranom modelu jer ovaj dio topološkog procesiranja u kojem se određuju pozicije mjernih točaka kritičan je dio za provedbu daljnje estimacije stanja [5, 28, 46].

Nakon ovako definirane topološke strukture, moguće je formirati matricu admitancija čvorišta i započeti proces estimacije stanja. Prilikom promjene statusa nekog od sklopnih aparata potrebno je promijeniti samo dio topološke strukture zahvaćen promjenom. Naravno, u nužnost promjene ulazi i revizija sekcijских grupa, pridruženih linija i mrežnih elemenata kao i pozicije definiranih mjernih mjesta. Također, vrši se usporedba nove topološke strukture s topološkom strukturom iz prethodne iteracije jednostavnom provjerom vjerodostojnosti pomoću Kirchhof-ovih zakona za struje i napone (*KCL i KVL*) [5].


Postoje slučajevi kada promjene unutar sekcijske grupe dovode do značajne promjene topologije mreže. Najjednostavniji je primjer slučaj isključenja prekidača spojnog polja dvaju sustava glavnih sabirnica. U tom slučaju od jedne sekcijske grupe predstavljene topološkom procesoru kao jedno čvorište nastaju dvije sekcijske grupe odnosno dva čvorišta. To automatski implicira povećanje matrice admitancija čvorišta te redefiniranje ulaznih podataka u topološki procesor što za posljedicu ima produljenje vremena estimacije stanja te mogućnost dodatne pogreške.

Kao što je već navedeno pogreške prilikom topološkog procesiranja, bilo zbog neispravnog ručnog unosa inicijalnih ulaznih podataka, bilo zbog pogrešnog očitavanja ili prijenosa podataka, značajno utječu na rezultat estimacije stanja i čine vrlo kritičan korak u tom procesu. Zbog velike osjetljivosti konvencionalnih topoloških procesora na brze topološke promjene te na brzinu i sinkronizam prikupljanja podataka razvijeni su složeniji topološki procesori čija je tendencija svesti nabrojane kritične korake na najmanju moguću mjeru.

2.2.2 Složeni topološki procesor

Pored standardne analize povezanosti koja određuje (identificira) otočne pogone pod naponom, bez napona ili uzemljene što je jedna od osnovnih zadaća konvencionalnog topoloških procesora, složeni topološki procesori posebno analiziraju dodatne otočne pogone na način da otvorene sklopne aparate ne grupiraju u pripadajuće sekcijske grupe već ih posebno promatraju. Također, posebno se analiziraju nepoznati i sumnjivi statusi sklopniх aparata. Sumnjiv status sklopnog aparata proglašava se onaj koji je doživio jednu ili više promjena stanja u odnosu na prethodnu estimacijsku iteraciju. Ova posebna analiza olakšava detekciju pogrešno uzetih statusa sklopniх aparata koji u konačnom rezultatu estimacije daju pogrešan vektor stanja sustava. Jednostavnija detekcija pogreške leži u tome što je ovdje istu nedvojbeno moguće

pridijeliti pogrešnom statusu sklopnog aparata umjesto da se pri konvencionalnom topološkom procesoru sumnja proširuje i na izmjerene analogne podatke (npr. izmjereni vektor napona u nekom čvorištu) [19, 35, 45 72]. Navedene tvrdnje prikazane su na primjeru prikazanom na slici 2.5 Naime, u određenim slučajevima, prilikom pogrešno prenesenog statusa sklopnog aparata pri konvencionalnom pristupu dolazi do pogrešnog prepoznavanja topološke strukture mreže tako da umjesto jedne cjelovite mreže ili promatranog dijela mreže ulazne podatke prepoznaju kao dva ili više odvojenih dijelova mreže.



Slika 2.5 Jednostavna elektroenergetska mreža

Na slici 2.5 prikazana je jedna jednostavna cjelovita elektroenergetska mreža. U slučaju pogrešno unesenog/prenesenog statusa prekidača 5 (očitan je kao otvoren, a u stvarnosti je zatvoren) konvencionalni topološki procesor prepoznaje dva razdvojena otočna pogona. Pod pretpostavkom da tok snage po vođu (4-7) postoji, odnosno, nije 0 (očitano analognim mjerenjem Y) te da su sva analogna mjerenja ispravna, pogreška u estimiranom vektoru dogodit će se u oba otočna pogona što će cijeli model mreže učiniti neispravnim. Ukoliko se prekidač u otvorenom statusu promotri zasebno, moguće je otkriti da je upravo to mjesto nastanka pogreške te tako izbjeći pogrešnu pretpostavku da je do netočno estimiranog vektora stanja došlo zbog eventualne pogreške u očitavanju i upisu izmjerene analogne vrijednosti vektora napona [5].

Složeni topološki procesor u mogućnosti je lokalno, na području određene sekcijske grupe ili transformatorske stanice, provesti i proračun estimacije stanja ukoliko to područje sadrži određeni sumnjivi podatak kako bi i prije samog, cjelovitog procesa estimacije bilo moguće otkloniti odnosno ispraviti pogrešan ulazni podatak. Naravno, prethodno je moguće samo ukoliko redundancija podataka isto dozvoljava, a u suprotnom, sumnjivo područje moguće je izolirati i ponovno provjeriti ulazne podatke kako statusne (binarne) tako i analogne tj. mjerne. Lokalna estimacija stanja kao dio topološkog procesiranja može uključivati i analizu promotrivosti kao i detekciju ulazne mjerne pogreške na ograničenom dijelu mreže. Također,

složeni topološki procesor u mogućnosti je provesti i određene testove vjerodostojnosti na dijelu mreže koji sadrži sumnjivi podatak. Test vjerodostojnosti obuhvaća provjeru zadovoljava li estimirani rezultat na određenom dijelu mreže Kirchovove zakone za napone i struje tj. provjeru je li vektorska suma struja u određenom čvorištu odnosno sekcijskoj grupi jednaka nuli i je li suma padova napona u zatvorenoj petlji jednaka nuli. Ovakva provjera, osim detektiranja mjernih i statusnih pogrešaka, može potvrditi i ispravnost određenih ulaznih mjernih podataka. Takvim podacima u procesu estimacije stanja može biti pridijeljen veći težinski faktor. Naravno, ne može se jamčiti kvaliteta obrađenih podataka, čak i u slučajevima kada su potpuno dosljedni, jer postoji mogućnost da su isti dosljedno netočni [5]. Unatoč ovom nedostatku, rezultati analize ispravnih, točnih podataka mogu biti korisni za detekciju stvarnih pogrešnih podataka u cjelovitoj mreži.

2.2.3 Reducirani model elektroenergetske mreže


Kao što je već spomenuto, topološko procesiranje u suštini sastoji se od triju osnovnih cjelina:

- eliminacija sklopnih aparata iz modela mreže,
- spajanje sekcijских grupa u jedinstveno čvorište,
- odgovarajuće pridjeljivanje inicijalnih mjernih točaka u reducirani model.

Eliminacijom sklopnih aparata iz modela mreže te spajanjem sekcijских grupa u jedinstveno čvorište dobiva se pojednostavljen odnosno reduciran prikaz/model elektroenergetske mreže. Naravno, od krucijalne je važnosti u reduciranom modelu zadržati odgovarajuću topološku funkcionalnost te ispravne pozicije ulaznih mjernih točaka. Ovo sažimanje odnosno redukcija može se matematički opisati redukcijom Jakobijeve matrice u metodi najmanjih kvadrata pomoću Gaussove eliminacije koja transformira Jakobijevu maticu iz one koja predstavlja model sadržan od sekcijских grupa (*eng. bus-section/switching device*) u konekcijski model (*eng. bus-branch model*) [4, 5].

2.2.3.1 Pozicije mjernih mjesta u reduciranom modelu mreže


Pozicije mjernih mjesta napona, struje ili toka snage u elektroenergetskom sustavu mogu biti razne ovisno o nadležnom operatoru, konfiguraciji rasklopnog postrojenja ili transformatorske stanice, potrebi za određenim konkretnim podatkom ili slično. Na slici 2.6 prikazane su neke od mogućih pozicija vatmetra i varmetra tj. uređaja za mjerenje tokova radne i jalove snage na određenim topološkim strukturama.



Slika 2.6 Prikaz nekih mogućih pozicija mjernih uređaja

Na slici 2.6 (a), obje sabirnice spajaju se odnosno reduciraju u jedno jedinstveno čvorište, a uređaj za mjerenje toka snage jednostavno je pridijeliti dalekovodu (TL) koji izlazi iz predmetnog čvorišta. Slika 2.6 (b) prikazuje neznatnu modifikaciju slučaja 2.6 (a) gdje topološki procesor umjesto na naznačenoj poziciji prebacuje mjernu točku „u vod“ odnosno prebacuje ju ispred sklopnih aparata gledajući od strane voda. U situaciji prikazanoj na slici 2.6 (c), nakon što se u topološkom procesiranju eliminiraju sklopni aparati i stvori konekcijski model čvorišta i linija (zatvoren prekidač ili rastavljač predstavljaju nultu impedanciju i direktan spoj, u suprotnom konekcija nije ostvarena), podatak iz mjernog uređaja reprezentiran je kao suma tokova snaga dviju linija tj. sumarni podatak. Na slici 2.6 (d) prikazan je obrnuti slučaj kada je tok snage u jednoj liniji/dalekovodu predstavljen kao suma mjerenja iz dvaju mjernih mjesta. Izračun sumarnih podataka i pridjeljivanje pripadajućoj točki mora biti odrađeno prije početka procesa estimacije stanja i pripada u domenu topološkog procesiranja.

Na slici 2.7 nekoliko je praktičnih pravila koji prikazuju način kako reducirati fizički model sa sekcijским grupama u konekcijski model sastavljen samo od čvorišta i linija te im ispravno pridijeliti odgovarajuće mjerno mjesto.




Slika 2.7 Utjecaj redukcije mreže na mjerna mjesta

2.2.3.2 Redukcija Jakobijeve matrice u topološkom procesoru

U ovom poglavlju prikazano je kako se praktična pravila sa slike 2.7 u procesu topološkog procesiranja provode Gaussovom eliminacijom u Jakobijevoj matrici estimatora stanja WLS metode. U nastavku teksta na primjeru slike 2.7 (a) prikazana je navedena tvrdnja. Slika 2.7 (a) prikazuje redukciju mreže eliminacijom ZB linije (linija nulte impedancije), a zbog jednostavnosti u prikazu Gaussove eliminacije u primjeru je korištena Jakobijeva matrica DC estimatora stanja. Za modeliranje zatvorenih sklopnih aparata na ZB liniji (linija $k - m$)

potrebne su dvije varijable stanja i dva pseudomjerenja. Dvije varijable stanja su kut fazora napona na eliminiranom čvoru (θ_m) i mjerenje toka snage koje predstavlja status zatvorenih sklopnih aparata na ZB liniji (P_{km}). Dva pseudomjerenja su nulta injekcija toka snage u čvorištu m ($P_m = 0$) i kut između fazora napona u čvorištu k i m koji u tom slučaju iznosi 0 ($\theta_{km} = 0$) [5]. Eliminacijom sklopnih aparata iz modela, odnosno ZB linije, eliminiraju se dvije varijable stanja i dva pseudomjerenja. Ovaj proces matematički je opisan Gaussovom eliminacijom nad Jakobijevom matricom, a skica procesa prikazana je slikom 2.8 [5].



Slika 2.8 Grafički prikaz Gauss-ove eliminacije na Jakobijevoj matrici

Proces redukcije na slici 2.8 napravljen je pod pretpostavkom da je status sklopnih aparata koji se eliminiraju na (*zero branch* - ZB) liniji točan, odnosno ispravno prenesen/upisan u topološki procesor. Također, može se primijetiti da nezavisni vektor koji predstavlja ulazne mjerne podatke (z_r) ovim redukcijским procesom ostaje nepromijenjen budući da su eliminirana pseudomjerenja jednaka nuli.

2.2.4 Pregled literature

Zbog važnosti topološkog procesora za provedbu istraživanja u okviru doktorskog rada, u nastavku je napravljen kratki pregled literature iz ovog područja.

Brojni radovi koji obrađuju problematiku topološkog procesiranja danas su dostupni u svjetskim bazama podataka. Osobito su brojni radovi koji su usmjereni na unaprjeđenje i usavršavanje metoda detekcije i otklanjanja topoloških pogrešaka. Prvi radovi na polju topološkog procesiranja potječu od vremena uvođenja koncepta statičke estimacije stanja u

elektroenergetske sustave. U inicijalnim radovima [73] – [86] razlike između stvarnog i estimiranog stanja EES-a pripisivane su: pogreškama mjernih instrumenata, nesavršenosti u prijenosu podataka, nedovoljno izgrađenom mjernom sustavu odnosno nedovoljnom broju varijabli, vremenskom nesinkronizmu u prikupljanju podataka, pseudomjerenjima podložnim greškama, netočnim parametrima sustava. Sve nabrojane činjenice odnosile su se kako na samu estimaciju stanja tako i na sustav topološkog procesiranja. Pri procesu klasične, konvencionalne estimacije stanja, topološke pogreške, kao i pogreške ulaznih mjernih podataka detektirale su se i otklanjale nakon provedenog procesa estimacije, odnosno nakon formiranja vektora stanja sustava. Razne metode vezane uz post-procesno otklanjanje topološke pogreške prikazane su u radovima: [74], [75], [76], [77], [78], [79]. Detekcija i otklanjanje topoloških pogrešaka temeljila se na filtriranju podataka kroz veći broj redundantnih mjerenja te uvođenju što većeg broja pseudomjerenja [73]. Jedna od tada značajnijih metoda detekcije i otklanjanja topoloških pogrešaka opisana je u radu [54] u kojem se u post procesnoj fazi posebno promatraju slučajevi u kojima estimirana vrijednost u bitnome ne odgovara topološkoj strukturi (npr. estimirano protjecanje struje na vodu u praznom hodu) tada je status sklopnog elementa u estimatoru stanja potrebno promijeniti i estimaciju pokrenuti ponovno, a sam proces ponavlja se dokle god postoji situacija s neispravnim estimiranim stanjima. Nedostatak ove metode je dugotrajnost postupka i post-procesna analiza što ju čini učinkovitom samo u slučajevima estimacije stacionarnog stanja. Radovi [82, 83] daju metode temeljene na razlikama između mjerene i estimirane vrijednosti (rezidualne razlike) te indeksima uspješnosti. Naime, većina klasičnih testova detekcije topoloških pogrešaka kao što su i [54, 62], pretpostavlja da su mjerenja inicijalno lišena bilo kakvih pogrešnih ulaznih podataka, a sama detekcija ulaznih pogreški odvija se nakon obavljenog procesa estimacije stanja. Takve metode, naravno, mogu dovesti do divergencije u procesu estimacije, a time estimator stanja učiniti potpuno neoperabilnim. Otkrivanje topoloških pogrešaka u EES-u moguće je pomoću metode opisane u [22, 55] a radi se o geometrijskoj interpretaciji razlike između mjerene i estimirane vrijednosti (rezidualna razlika) uzrokovanih takvim pogreškama. Naime, ako je utjecaj topološke pogreške na rezidualnu razliku na jednom vodu značajno različit od rezidualnih razlika na ostalim vodovima tada je topološka pogreška vrlo izvjesna na tom vodu. U radu je prezentirana metoda detekcije jednostruke topološke pogreške (pogreška na samo jednom vodu) koja je vrlo slična metodi normalizacije pri mjernim pogreškama te uopćenje metode za višestruke topološke pogreške.

Rad [79] među prvima uvodi pred-procesnu analizu topoloških pogrešaka čime je otvorena mogućnost eliminacije prethodno navedenih problema. Metoda u [79] temeljena je na nelinearnoj transformaciji ulaznih mjernih podataka provedenoj u tri koraka za svako pojedino

čvorište i za njemu susjedna čvorišta. Prema [84] promatra se, umjesto cijele mreže, grupa čvorišta sačinjena od jednog čvorišta i njemu susjednih čvorišta kao jedinstvena struktura u kojoj u svakom trenutku moraju biti zadovoljene jednadžbe tokova snaga. Promjenom tehnike na sva čvorišta dobiva se generalizirana tehnika primjenjiva na cijelu promatranu mrežu. U [85] uvodi se koncept trajnog nadzora svakog pojedinog sklopnog elementa u mreži zasebno. U navedenom radu, razvijen je algoritam koji iz informacija dostupnih u kompletnom EMS sustavu kao što su: sustav analognih mjerenja, sustav relejne zaštite, signalnog sustava statusa sklopnih aparata, sustava upravljanja sklopnim aparatima i alarmnog sustava, pridjeljuje svakom sklopnom elementu status ON ili OFF. Poseban naglasak dan je na određeni vremenski raspon u vremenskoj okolini djelovanja sklopnog elementa mreže. Nakon pridjeljivanja odgovarajućeg statusa vrednuju se uvjeti kompatibilnosti prema svim susjednim sklopnim elementima. Nakon provedene validacije, svakom stanju sklopnog elementa pridjeljuje se status TRUE ili FALSE. Opisanom metodom topološko stanje mreže u estimatoru stanja moguće je dinamički određivati bez obzira na status izvođenja estimacijskog algoritma. U [86] uvodi se koncept korelacijskog indeksa između simptomatičnih anomalija u estimiranom vektoru stanja i ulaznih mjernih podataka koji se analizom osjetljivosti i prezentiranom ortogonalnom tehnikom mogu detektirati i eliminirati. Ova metoda za cilj ima dinamičko određivanje topoloških pogrešaka što je čini upotrebljivom u estimaciji stanja u realnom vremenu. Obzirom da pogrešne varijacije estimirane vrijednosti uzrokovanja topološkom pogreškom slabe što je električka udaljenost veća od žarišta pogreške, odnosno od pogrešno interpretiranog statusa sklopnog elementa, u [87] predlaže se pristup kojim je moguće jedno promatrano područje EES-a podijeliti u više zasebnih petlji i svaku zasebno provjeravati. To proces topološkog procesiranja razdvaja u više zasebnih procesa gdje se najosjetljiviji ulazni mjerni podatak u svakoj petlji koristi za identifikaciju topološke pogreške u pripadajućoj petlji. Konačan rezultat unija je svih pojedinih procesa. Rad [88] prezentira metodu za prepoznavanje topologije mreže na temelju analognih ulaznih podataka. Metoda ima dva dijela: predprocesni i klasifikacijski. U predprocesnom dijelu svaki analogni ulazni podatak pretvara se u vektor s prostorom $[0,1]^n$ što prouzrokuje skupove vrlo sličnih predprocesnih izlaznih vektora za svaku mrežnu topologiju. Faza klasifikacije sastoji se od sloja Gaussovih potencijalnih jedinica s Mahalanobisovom udaljenosti čime je moguće klasificirati predprocesne izlazne vektore te tako prepoznati stvarnu topologiju mreže. U radu [89] za indikaciju konekcija pojedinih mrežnih elemenata koriste se Booleove varijable, a metoda je temeljena na intervalnoj propagaciji ograničenja.

Radovi [90 – 95] koji se pojavljuju početkom 2000-tih godina koriste sustave umjetnih neuronskih mreža za prepoznavanje topologije mreže te topoloških pogrešaka u procesu estimacije stanja. Rad [96] daje način na koji se inženjersko znanje o tokovima snaga u EES-u koristi u procesu učenja sustava umjetnih neuronskih mreža kojeg je potom moguće upotrijebiti u svrhu identifikacije topologije EES-a. U [90] također se koristi prethodno inženjersko znanje u predprocesnoj standardizaciji razine tolerancije u mjernoj pogrešci gdje se nakon lokalne klasifikacije korektnosti uključivanja pojedine grane u konekcijski model mreže globalno procjenjuje topološka struktura sustava. Isti autor u [94] predstavlja način kako pomoću umjetnih neuronskih mreža maksimalno iskoristiti ulazne mjerne podatke povećanjem mogućih relacija odnosno jednadžbi sustava. Potpuno novi koncept topološkog estimatora uveden je radom [97] u kojem se koristi proces estimacije topološkog stanja slično procesu estimacije varijabli stanja. Arhitektura sustava estimacije topološkog stanja sastoji se od modeliranja fizičke mreže (*eng. bus-section-switch model*), lokalizacije pogreške statusa sklopnog aparata te kombinatorike u analizi prikupljenih podataka. U [46] predstavljen je algoritam za optimizaciju mjernih mjesta u cilju poboljšanja detekcije topološke pogreške. Strateškim izborom mjernog mjesta moguće je ostvariti takve ulazne podatke da je povećana mogućnost nedvojbene detekcije topološke pogreške. Verifikacija topologije sustava u realnom vremenu predstavljena je u [98]. U radu se koristeći Petrijeve mreže verificira već dobivena topologija sustava koristeći multi-agent sustav kao diskretni dinamički sustav događaja. Multi-agent sustavi kao verifikacijski alat za topologiju sustava koriste se i u mnogim kasnijim radovima [99 – 102]. Koristeći indekse nesimetrije te umjetne neuronske mreže algoritam u radu [103] identificira i otklanja topološke pogreške zbog toga što vrijednosti indeksa nesimetrije stvaraju karakteristične skupove za različite mrežne topologije. Analiza podataka omogućuje ukazivanje na slučajeve topološke pogreške, koje se mogu razlikovati ispitivanjem vrijednosti indeksa nesimetrije.

Sumarno se može zaključiti da se radovi na polju topološkog procesiranja, dostupni u literaturi, mogu podijeliti u dvije osnovne cjeline. Jednu cjelinu čine radovi koji daju same metode, odnosno algoritmi topološkog procesiranja dok drugu cjelinu čine radovi koji obrađuju metode detektiranja i otklanjanja topoloških pogrešaka nakon već odrađenog procesa topološkog procesiranja.

2.3 Putujući valovi

Kako bi hipoteza doktorskog rada naznačena u uvodu bila razumljiva u cijelosti, ovom točkom, prikazan je kratak sažetak teorije valova i primjena iste u elektroenergetskom sustavu.

2.3.1 Opći pojmovi i valne jednačbe

Obzirom da je za uspostavu električnog polja na vodu potrebno konačno, određeno vrijeme, u slučajevima da je duljina voda takva da za određenu frekvenciju ona predstavlja značajan dio valne duljine vala, tada se za promatranje i analizu pojava na vodu mora koristiti valni koncept rasprostiranja, odnosno valne jednačbe.

Matematička analiza ponašanja valnih pojava na prijenosnim vodovima potekla je iz radova Jamesa Maxwella, Lorda Kelvina i Olivera Heavisidea. Heaviside je 1885. godine objavio prvi rad koji opisuje analizu propagacije signala u kabelima i dao moderan oblik tzv. telegrafskih, odnosno valnih jednačbi.

Prilikom propagacije vala prijenosnim dalekovodom dio energije gubi se uslijed konačne otpornosti linije odnosno njenog radnog otpora što predstavlja radne ili rezistivne gubitke. Na višim frekvencijama postaju izraženi i dielektrični gubici, koji se javljaju kao posljedica kapacitivnog ponašanja linije. Dielektrični gubici javljaju se kada izolacijski materijal apsorbira energiju za naizmjeničnu polarizaciju svojih molekula pri čemu se trenjem dio energije pretvara u toplinu [104]. Ukupni gubici izražavaju se u decibelima po metru (dB/m) i ovise o frekvenciji vala koji se prenosi.


Ukoliko je prijenosni vod homogen cijelom svojom dužinom, onda se njegovi parametri obzirom na valno rasprostiranje najbolje opisuju karakterističnom impedancijom Z_c . Karakteristična impedancija predstavlja odnos kompleksnog napona i kompleksne struje u stacionarnom stanju na određenoj frekvenciji u bilo kojoj točki duž prijenosnog voda. Energija odaslana sa strane izvora ka potrošaču preko prijenosnog voda u potpunosti će se apsorbirati ako je vod zatvoren karakterističnom impedancijom Z_c . U protivnom dio energije nužno će se reflektirati u ovisnosti o veličini terminirajuće impedancije. Tipične vrijednosti karakteristične impedancije za 110 kV dalekovode iznosi oko 300 Ω , dok za visokonaponske kabele iznosi oko 50 Ω . [105]

Valne jednačbe izvode se iz modela prijenosnog voda koji se svodi na beskonačnu rednu vezu četveropolnih elemenata prikazanih na slici 2.9 od kojih svaki predstavlja infinitezimalno mali segment koji se sastoji od:

- distribuirane otpornosti voda (Ω/m) označene otpornikom $r = R/d$

- distribuirane induktivnosti voda (H/m) označene zavojnicom $l = L/d$
- distribuiranog kapaciteta voda (F/m) označene kondezatorom $c = C/d$
- distribuiranog odvoda voda (S/m) označene poprečnim odvodom $g = G/d$

gdje je d – duljina prijenosnog voda.



Slika 2.9 Četveropolni element modela prijenosnog voda

Parametar Z_c predstavlja karakterističnu impedanciju i jednak je:

$$Z_c = \sqrt{\frac{r+j\omega l}{g+j\omega c}} \quad (2.21)$$

i po fizičkoj dimenziji odgovara impedanciji i nosi jedinicu Ω (*ohm*).

Veličina:

$$\gamma = \sqrt{(r + j\omega l)(g + j\omega c)} \quad (2.22)$$

naziva se koeficijent rasprostiranja i njen realni dio $\alpha = \text{Re}\{\gamma\}$ opisuje uzdužno prigušenje amplitude putnog vala dok njen imaginarni dio $\beta = \text{Im}\{\gamma\}$ opisuje njegov fazni pomak duž linije.

Telegrafске једnadžbe koje opisuju strujne i naponske prilike duž voda u svakom trenutku:

$$\frac{\partial u(x,t)}{\partial x} = -l \frac{\partial i(x,t)}{\partial t} - ri(x,t), \quad (2.23)$$

$$\frac{\partial i(x,t)}{\partial x} = -c \frac{\partial u(x,t)}{\partial t} - gu(x,t). \quad (2.24)$$

Minus (-) predznak s desne strane jednakosti uzrokovan je time što se amplituda struje i napona smanjuje kako se putni val propagira u smjeru rastuće varijable x . Rješavanjem diferencijalnih jednačbi (2.23) i (2.24) te algebarskim sređivanjem prikazanim u [105] dobiva se konačan, poopćen izraz za iznos napona (2.25) i struje (2.26) u bilo kojoj točki na vodi u bilo kojem trenutku.

$$u(x, t) = e^{\gamma x} f_1(t) + e^{-\gamma x} f_2(t) \quad (2.25)$$

$$i(x, t) = -\frac{1}{Z_c} [e^{\gamma x} f_1(t) - e^{-\gamma x} f_2(t)] \quad (2.26)$$

U izrazima (2.25) i (2.26) izrazi $f_1(t)$ i $f_2(t)$ proizvoljne su funkcije neovisne o varijabli x . Iz navedenih izraza vidljivo je da telegrafске jednačbe daju dva rješenja za putujući val. Jedno rješenje fizikalno predstavlja val koji se prostire s početka voda prema kraju, a drugo rješenje fizikalno predstavlja val koji se prostire s kraja prema početku. Minus predznak u drugom članu izraza potječe od konstitutivne relacije terminirajuće impedancije na kraju voda koja se ponaša kao izvor reflektiranog vala.

2.3.1.1 Karakteristična impedancija generatora i transformatora

Kada putujući val propagirajući se prijenosnom mrežom naiđe na sabirnicu koja je incidentna s elementom mreže koncentriranih parametara kao što je generator ili transformator tada se generiraju oscilacije rezonantne frekvencije u namotima uzrokujući stojni val. Obzirom da je stojni val u suštini superpozicija dvaju valova suprotnih predznaka smjera širenja, struje i napona na namotima transformatora i generatora tretiraju se kao putni valovi. Navedeno implicira postojanje njihove karakteristične impedancije, a time je moguće izračunavati i refleksije putnih valova od namota navedenih elemenata elektroenergetskog sustava. Izraz za izračunavanje karakteristične impedancije elemenata mreže s koncentriranim parametrima izveden je u [105], a ovdje prikazan izraz (2.27) vrijedi za izračunavanje karakteristične impedancije transformatora.

$$Z = \sqrt{\frac{L}{C}} = 2 \frac{N_t}{h} \left(\frac{wd}{w+d} \right) \sqrt{\frac{\mu_0}{\epsilon_0}} \sqrt{\frac{\mu_r}{\epsilon_r}} \quad (2.27)$$

N_t/h predstavlja broj namota po jedinici duljine primarnog namota transformatora, w je udaljenost tj. zračni raspor između jezgre i namota transformatora, a d je udaljenost metalne mase kućišta transformatora do njegovog primarnog namota. μ_0, μ_r, ϵ_0 i ϵ_r standardni su koeficijenti permeabilnosti i permitivnosti vakuma i pripadajućeg medija.

Prema [105] tipična vrijednost karakteristične impedancije za niskonaponski namot distribucijskog transformatora 500 kVA je oko 600 Ω , visokonaponskog namota oko 5000 Ω . Za 50 MVA transformator tipične su vrijednosti oko 100 Ω za niženaponski te oko 1000 Ω za višenaponski namot.

2.3.2 Brzina rasprostiranja, prigušenje i izobličenje vala

Promotri li se prijenosni vod kao beskonačan niz infinitezimalnih dijelova sa slike 2.9 moguće je izvesti izraz za brzinu rasprostiranja putnog vala cijelom duljinom voda. Pretpostavi li se da je na početku prijenosnog voda izvor elektromotorne sile, vod će se prema svom kraju nabijati nabojem koji stvara električno polje iznosa E . Struja koja će poteći uslijed razlike potencijala oko vodiča će stvoriti magnetsko polje H . Pretpostavka je također da se promjene magnetskog i električnog polja na infinitezimalnom dijelu prijenosnog voda Δx događaju trenutno. Izraz za struju (2.28) i napon (2.29) na prijenosnom vodu tada glasi:

$$i = \lim_{\Delta x \rightarrow 0} \frac{\Delta Q}{\Delta t} = \lim_{\Delta x \rightarrow 0} \frac{Cu \Delta x}{\Delta t} = Cu \frac{dx}{dt} = Cuv \quad (2.28)$$

$$u = \lim_{\Delta x \rightarrow 0} \frac{\Delta \Phi}{\Delta t} = LCu \left(\frac{dx}{dt} \right)^2 = LCuv^2 \quad (2.29)$$

gdje su L i C jedinični induktivitet i kapacitet voda respektivno. Kombiniranjem ovih dvaju izraza dobiva se izraz za brzinu putnog vala na prijenosnom vodu (2.30):

$$v = \frac{1}{\sqrt{LC}} \quad (2.30)$$

Brzina putnog vala isključivo ovisi o geometriji prijenosnog voda te permitivnosti i permeabilnosti okružujućeg medija. Valna duljina elektromagnetskog vala označava se s λ i iznosi:

$$\lambda = \frac{v}{f} \quad (2.31)$$

Kada strujni i naponski val putuje realnim prijenosnim vodom, što implicira postojanje gubitaka odnosno radnog otpora voda, amplituda tog vala eksponencijalno se smanjuje. Ova pojava naziva se prigušenje i uzrokovana je isključivo konstrukcijskim parametrima voda. Izraz za prigušenje strujnog (2.32) i naponskog (2.33) putujućeg vala glasi:

$$i(x, t) = i(x_0, t_0)e^{-(Rx/2Z)} \quad (2.32)$$

$$u(x, t) = u(x_0, t_0)e^{-(Rx/2Z)} \quad (2.33)$$

gdje su $i(x_0, t_0)$ i $u(x_0, t_0)$ iznosi struje i napona na početku voda u početnom trenutku, a R i Z radni otpor i karakteristična impedancija voda respektivno. Iz navedenih izraza vidljivo je da je prigušenje manje kada je radni otpor manji i/ili karakteristična impedancija veća [104, 105, 106].

Na realnom prijenosnom vodu, osim prigušenja uslijed radnog otpora može doći i do izobličenja tj. distorzije strujnog i naponskog vala. Do izobličenja dolazi uslijed nejednakih gubitaka u električnom i magnetskom polju odnosno u svakom slučaju u kojem nije zadovoljena slijedeća relacija:

$$\frac{R}{L} = \frac{G}{C} \quad (2.34)$$

U slučaju da je relacija (2.34) zadovoljena, takav prijenosni vod naziva se vod bez izobličenja (*eng. Distortionless Line*). U tom slučaju strujni i naponski putujući val nose jednaku količinu energije u svakoj prostornoj točki voda i omjer gubitka energije u svakoj točki je jednak. Tada nema razmjene energije između strujnog i naponskog vala i takav val zadržava originalni oblik samo što je prigušen u amplitudi uslijed gubitka na radnom otporu voda [105].

2.3.3 Refleksije i transmisije valova u elektroenergetskoj mreži

Kvantitativni omjer strujne i naponske komponente elektromagnetskog vala koji se širi prijenosnim vodom određene karakteristične impedancije podjednak je u svakoj točki cijele njegove dužine. Kada takav elektromagnetski val dođe do točke impedantnog diskontinuiteta kao što je otvoreni kraj voda, kraj voda u kratkom spoju ili bilo koje druge promjene u vrijednosti karakteristične impedancije u odnosu na vod kojim se širio nužno dolazi do narušavanja konstantnog omjera strujne i naponske komponente. U točki diskontinuiteta dio energije elektromagnetskog vala transmitira se dalje, a dio energije reflektira se i putuje natrag.

Prema zakonu o očuvanju energije, količina energije upadnog vala jednaka je sumi količine energije transmitiranog i reflektiranog vala [105]. Koliki udio energije upadnog vala se reflektira nazad, a koliki se transmitira dalje ovisi isključivo o omjeru karakterističnih impedancija na točki diskontinuiteta, a navedeno je vidljivo iz izraza koji slijede.

Neka je x_0 točka diskontinuiteta, a v_u, v_r i v_t napon, a i_u, i_r i i_t struja upadnog, reflektiranog i transmitiranog vala. Z_0 je karakteristična impedancija voda po kojem se val počeo širiti u trenutku t_0 , a Z_1 je karakteristična impedancija elementa mreže na koji val stiže u trenutku t . U točki diskontinuiteta u trenutku t vrijedi kontinuitet funkcije napona (2.35) i struje (2.36):

$$v_u(x_0, t) + v_r(x_0, t) = v_t(x_0, t) \quad (2.35)$$

$$i_u(x_0, t) - i_r(x_0, t) = i_t(x_0, t) \quad (2.36)$$

minus (-) predznak reflektiranog strujnog vala fizikalno predstavlja smjer širenja reflektiranog vala u smjeru negativnog prirasta prostorne osi x , odnosno zadovoljenje I Kirchoffovog zakona za struje. Izraz (2.36) može se pisati:

$$\frac{v_u(x_0, t)}{Z_0} - \frac{v_r(x_0, t)}{Z_0} = \frac{v_t(x_0, t)}{Z_1} \quad (2.37)$$

Kombiniranjem (2.35) i (2.37) dobiva se izraz za napon (2.38) i struju (2.39) transmitiranog vala:

$$v_t(x_0, t) = \left(\frac{2Z_1}{Z_0 + Z_1} \right) v_u(x_0, t) \quad (2.38)$$

$$i_t(x_0, t) = \left(\frac{2Z_0}{Z_0 + Z_1} \right) i_u(x_0, t) \quad (2.39)$$

te za napon (2.40) i struju (2.41) reflektiranog vala:

$$v_r(x_0, t) = \left(\frac{Z_1 - Z_0}{Z_1 + Z_0} \right) v_u(x_0, t) \quad (2.40)$$

$$i_r(x_0, t) = \left(\frac{Z_0 - Z_1}{Z_0 + Z_1} \right) i_u(x_0, t) \quad (2.41)$$

Izraz $\frac{Z_1 - Z_0}{Z_0 + Z_1}$ naziva se koeficijent refleksije naponskog vala, a $\frac{Z_0 - Z_1}{Z_0 + Z_1}$ koeficijent refleksije strujnog vala i označava se s r . Impedantni diskontinuitet se uglavnom pojavljuje na početku ili na kraju prijenosnih vodova, a rjeđe unutar jednog cjelovitog voda. Primjer slučaja u kojem se impedantni diskontinuitet javlja unutar jednog voda je prijelaz zračne dionice u kabelsku ili obrnuto ili slučaj tzv. T-spoja. U nastavku su prezentirani određeni specifični slučajevi koji se mogu pojaviti kao impedantni diskontinuitet na početku ili kraju prijenosnog voda, preuzeto iz [105,106].

a) Kraj prijenosnog voda neopterećen – prazan hod

U slučaju da se točka diskontinuiteta x_0 nalazi na kraju prijenosnog voda i da je isti otvoren, odnosno nalazi se u praznom hodu, naponska komponenta elektromagnetskog vala udvostručiti će se u iznosu, dok će strujna komponenta u toj točki iščeznuti. Preciznije rečeno, naponski val na kraju voda reflektirat će se u fazi s upadnim valom i superponirati s njim, a strujni val reflektirat će se u protufazi te će superpozicija upadnog i reflektiranog vala iznositi nula. U tom slučaju energija elektromagnetskog vala biti će sadržana isključivo u električnom polju.

b) Kraj prijenosnog voda zatvoren nultom impedancijom – kratki spoj

Obrnuti slučaj od slučaja u odjeljku a) javlja se kada se u točki x_0 na kraju prijenosnog voda dogodi kratki spoj tj. kada je vod zatvoren nultom impedancijom. U tom slučaju, strujni val reflektira se u fazi s upadnim valom i superpozicijom udvostručuje amplitudu. Naponski val reflektira se u protufazi i rezultat superpozicije iznosi nula. Tada je sva energija elektromagnetskog vala u točki x_0 sadržana u magnetnom polju.

c) Kraj prijenosnog voda zatvoren karakterističnom impedancijom

U slučaju da je vod na svom kraju opterećen potrošačem kojemu je impedancija jednaka valnoj impedanciji prijenosnog voda na tom vodu neće biti refleksije obzirom da ne postoji impedantni diskontinuitet. Matematički gledano, uvrsti li se u relacije refleksije i transmisije (2.38) – (2.41) $Z_0 = Z_1$ dobivamo izraze iz kojih je razvidno da reflektiranog vala nema, a da je transmitirani val jednak upadnom. Time se postiže fizikalno stanje kao da je vod beskonačno

dug, a njime se prenosi snaga koja se naziva prirodna snaga voda. Ako je vod opterećen prirodnom snagom tada su struja i napon u fazi i konstantni uzduž voda, nema prijenosa reaktivne snage niti njihanja energije uzduž voda.

d) Kraj prijenosnog voda zatvoren sabirnicom s više incidentnih vodova

U slučaju kada je vod zatvoren sabirnicom s više incidentnih vodova dolazi do transmisije dijela energije elektromagnetskog putnog vala dok se preostali dio reflektira natrag ovisno o međusobnom odnosu valnih impedancija incidentnih vodova. Ako je u trenutku t_0 elektromagnetni putni val stigao na kraj voda valne impedancije Z_0 koji je terminiran sabirnicom incidentnom s n vodova valnih impedancija od Z_1 do Z_n , tada kao terminirajuću impedanciju upadni val „vidi“ ukupnu impedanciju n vodova Z_{uk} koja je jednaka njihovom paralelnom spoju:

$$Z_{uk} = Z_1 || \dots || Z_n \quad (2.42)$$

odnosno,


$$Z_{uk} = \frac{Z_1 \cdot \dots \cdot Z_n}{Z_1 + \dots + Z_n} \quad (2.43)$$

Koeficijent refleksije naponskog vala u tom slučaju glasi:

$$r = \frac{Z_{uk} - Z_0}{Z_{uk} + Z_0} \quad (2.44)$$

e) Prijenosni vod povezan s elementom s koncentriranim parametrima

Nešto složeniji slučaj javlja se kada je na vod ili na kraj voda koji se nastavlja na sabirnice i druge vodove povezan element mreže s koncentriranim parametrima (slika 2.10).



Slika 2.10 Prijenosni vod povezan s elementom sa koncentriranim parametrima

Po istom principu kao i u prethodnim slučajevima u vodu karakteristične impedancije Z_0 javiti će se osim upadnog i reflektirani putni val, a vodom ili vodovima u nastavku rasprostirati će se transmitirani val. Suštinska razlika u odnosu na prethodne slučajeve

manifestira se u tome što je prisutan element s koncentriranim parametrima konačnog radnog otpora R na kojeg nije moguće primijeniti valne jednadžbe. Obzirom da je valna impedancija ohm-ska veličina i fizikalno ima veličinu radnog otpora, sa aspekta valnog rasprostiranja sustav se iz perspektive voda valne impedancije Z_0 ponaša kao da „vidi“ paralelni spoj radnog otpora R i valnih impedancija vodova u nastavku.

Koeficijenti refleksije i transmisije u tom slučaju iznose:

$$r = \frac{V_r}{V_u} = \frac{Z_1 || R - Z_0}{Z_1 || R + Z_0} \quad (2.45)$$

$$\tau = \frac{V_t}{V_u} = 1 + r \quad (2.46)$$

Također, u slučaju kaskadnog spoja više prijenosnih linija različitih valnih impedancija doći će do refleksije i transmisije u svakoj točki impedantne promjene. Za napomenuti je da val na kraju voda „vidi“ samo valnu impedanciju voda s kojim je incidentan.

f) Razdjeljivanje napona na početku voda

Na početku voda u ovisnosti od vrijednosti izlazne impedancije izvora, odnosno generatora, dolazi do razdjeljivanja elektromagnetskog vala koji od cijele mreže vidi samo valnu impedanciju prvog incidentnog voda. Prema tome, amplituda početnog elektromagnetskog vala određena je koeficijentom razdjeljivanja. Za naponski val taj koeficijent iznosi:

$$\xi = \frac{V_0}{V_{izvora}} = \frac{Z_0}{Z_{izvora} + Z_0} \leq 1 \quad (2.47)$$

Iz navedenog izraza može se primijetiti da je koeficijent razdjeljivanja uvijek manji ili jednak jedan, tj. izlazni napon ne može biti veći od napona izvora.

g) Višestruke refleksije

Ako zaključna impedancija na kraju voda nije jednaka njegovoj karakterističnoj impedanciji, na kraju voda formirat će se reflektirani val koji će se rasprostirati nazad ka izvoru. Prilikom nailaska ovog reflektiranog vala na izvor, ukoliko ni njegova unutarnja impedancija

nije jednaka karakterističnoj impedanciji voda, pojavit će se nova, sekundarna, refleksija koja će se superponirati na inicijalni val. Takav superponirani val rasprostirat će se dalje po vodu prema njegovom kraju pri čemu zamišljeni promatrač na kraju voda neće moći razlikovati inicijalni i superponirani val već će moći vidjeti samo njihovu sumarnu vrijednost. Na kraju voda ponovno će doći do refleksije i pojave reflektiranog vala i postupak će se sukcesivno ponavljati dok reflektirani valovi ne dođu na tako malu vrijednost da ih se može smatrati iščezlim tj. kada padnu ispod razine šuma u EES-u.

Ukoliko se prijenosni vod promotri kao idealan (bez gubitaka) može se zaključiti da će se svaki slijedeći reflektirani val od početka i kraja voda superponirati na inicijalni i prvi reflektirani val sve dok ne dostignu graničnu vrijednost određenu koeficijentima refleksije na početku i na kraju voda. Granična vrijednost amplitude vala koji se rasprostire od kraja prema početku voda iznosi (2.48)

$$\hat{V}_r = V_0 r_B + V_0 r_B^2 r_A + V_0 r_B^3 r_A^2 + \dots = \sum_{n=0}^{\infty} V_0 r_B (r_B r_A)^n = r_B \frac{\xi V_0}{1 - r_B r_A} \quad (2.48)$$

dok granična vrijednost vala koji se prostire od početka prema kraju V_u iznosi:

$$\hat{V}_u = V_0 + V_0 r_B r_A + V_0 r_B^2 r_A^2 + \dots = \sum_{n=0}^{\infty} V_0 (r_B r_A)^n = \frac{\xi V_0}{1 - r_B r_A} \quad (2.49)$$

Nakon dovoljno dugo vremena u sustavu će praktično postojati samo dva vala: jedan upadni i jedan reflektirani, pri čemu je njihova amplituda ovisna o koeficijentima refleksije na početku i na kraju voda. Odnos međusobnih amplituda određen je samo koeficijentom refleksije na kraju voda, baš kao da nije došlo do višestrukih refleksija već da se prijenosnim vodom prostiru samo $\hat{V}_u$ i $\hat{V}_r$.

Obzirom da koeficijenti r_A i r_B mogu imati i pozitivne i negativne vrijednosti, u općem slučaju nije moguće odrediti hoće li višestruke refleksije oslabiti ili pojačati neki od prostirućih valova. Ukoliko se u obzir uzme da određeni promatrani vod duljine l ima konačno uzdužno prigušenje α , tada se pri svakom prolasku prijenosnim vodom val oslabi za faktor (2.50):

$$10^{\frac{\alpha \cdot l}{20}} \quad (2.50)$$

Time se modificiraju prethodno navedeni izrazi i dobiva izraz (2.51) koji određuje ekvivalentan utjecaj prigušenja amplituda putnih valova prijenosnim vodom.


$$\hat{V}_r = r_B \hat{V}_u = r_B \cdot \frac{\xi V_0}{1 - r_B r_A 10^{\frac{\alpha \cdot l}{20}}} \quad (2.51)$$

Utjecaj refleksija na ponašanje sustava vrlo je nepredvidiv, čak i u slučaju jednostavnih topoloških konfiguracija, stoga je analiza višestrukih refleksija vrlo složena.

2.4 Umjetne neuronske mreže

Umjetna neuronska mreža (*eng. Artificial Neural Network ili ANN*) [107 - 109] je matematički ili računalni model kojim se pokušava simulirati funkcija stvarne biološke neuronske strukture, kako bi se riješili određeni matematički ili fizikalni problemi. Obično se koriste za modeliranje složenih odnosa između određenih ulaza i izlaza ili kako bi se pronašli uzorci u velikoj količini podataka.

Umjetni neuroni osnovni su elementi neuronske mreže (Slika 2.11) i najjednostavnije ih se može prikazati kao vektor ulaznih elemenata $[x_1 \dots x_p]$ koji se preko neuronskih veza međusobno sumiraju pomnoženi s pripadajućim težinskim faktorom w_k . Rezultat sume u_k ulazna je varijabla prijenosne funkcije $\varphi(\cdot)$ čiji je izlaz y_k . Funkcija praga Θ_k kao druga varijabla prijenosne funkcije određuje osjetljivost neuronske mreže tj. određuje za koji će ulaz neuron prijeći prag aktivacije i dati rezultat na izlazu.



Slika 2.11 Prikaz umjetnog neurona

Matematička interpretacija funkcioniranja neurona dana je izrazima (2.52) i (2.53).


$$u_k = \sum_{j=1}^p w_{kj}x_j \quad (2.52)$$

$$y_k = \varphi(u_k - \theta_k) \quad (2.53)$$

Kao aktivacijska funkcija često se koristi sigmoidna funkcija oblika (2.54).

$$y_i = \frac{1}{1 + e^{-(u_k - \theta_k)}} \quad (2.54)$$

Skup međusobno povezanih neurona na način da izlazne vrijednosti jednoga neurona postaju ulaznim vrijednostima drugih naziva se neuronskom mrežom. Uobičajena neuronska mreža se sastoji od više slojeva, najčešće od ulaznog, jednog ili više skrivenih, te izlaznog sloja. Principijelna shema neuronske mreže prikazana je na slici 2.12.



Slika 2.12 Principijelna shema neuronske mreže

Da bi neuronska mreža obavljala svoju zadaću potrebno je provesti fazu učenja ili treniranja neuronske mreže. Učenje se provodi na način da se neuronskoj mreži predočava niz ulaznih veličina s već poznatim izlaznim veličinama. U toj fazi dolazi do korigiranja težinskih faktora veza među neuronima, na način da se pri svakom predočenom nizu ulazno-izlaznih podataka postiže sve bolja željena korelacija ulaznih i izlaznih veličina. Nakon što se postigne zadovoljavajuća točnost učenja, neuronskoj mreži se može predočiti ulazne veličine bez unaprijed poznate izlazne veličine. Pravilno naučena neuronska mreža bi u tom slučaju trebala dati izlaznu veličinu zadovoljavajuće točnosti.

Odgovarajući parovi ulazno - izlaznih veličina formiraju skup primjera za učenje (*eng. training set*) na kojem se, pomoću različitih algoritama za učenje, izvodi učenje (treniranje) neuronske mreže. Pored algoritma za učenje, neuronsku mrežu karakterizira i sam način učenja. Izbor algoritma za učenje i načina učenja ovisan je o prirodi problema koji se rješava, a u [110] navode se razni algoritmi učenja od kojih je ovdje najznačajnije učenje korekcijom pogreške. Ista literatura navodi i moguće načine učenja od kojih vrijedi izdvojiti: učenje pod nadzorom, učenje s podrškom i učenje bez nadzora.

Paralelna struktura i adaptivno treniranje mreže omogućavaju prepoznavanje međuovisnosti ulaznih podataka s podacima na izlazu, prilagodbom težinskih faktora neurona. Stvaranjem te međuovisnosti stvara se matematički model koji rješava zadane probleme s određenom vjerojatnošću. Povećavanjem kompleksnosti mreže povećava se i njena robusnost što rezultira većom otpornošću na pogreške što znači da gubitak pojedinih elemenata (težinskih faktora ili neurona) neće dovesti do prestanka rada mreže. To nije slučaj pri klasičnim programskim sustavima, gdje svaka pogreška u kodu može dovesti do prekida rada programa. Slijedeća važna karakteristika neuronskih mreža je njena asocijativnost. Naime, u slučaju da postoje određene smetnje prilikom prezentacije ulaznih veličina, neuronska je mreža sposobna pronaći najbližiji oblik ulaza (između prethodno naučenih primjera) te da na temelju njega na izlazu generira rezultat koji odgovara kompletnom ulazu bez smetnji. Zato su neuronske mreže vrlo često prikladne za rješavanje problema prepoznavanja uzoraka.

Najčešće korištena arhitektura neuronskih mreža svakako je višeslojna neuronska mreža (*eng. Multilayer Perceptrons* ili MLP) [110]. Ona se sastoji od jednog ulaznog sloja, jednog ili više skrivenih slojeva i jednog izlaznog sloja neurona. Višeslojni perceptron ima tri glavna svojstva: model neurona ima nelinearnu izlaznu karakteristiku koja je glatka, mreža sadrži jedan ili više skrivenih slojeva neurona i mreža je dobro povezana (postoji puno sinapsi).


2.4.1 Tipovi neuronskih mreža

Jedan od najčešće korištenih algoritama za učenje ANN je algoritam s povratnim širenjem pogreške (*eng. Backpropagation algorithm*) i takve mreže se najčešće nazivaju (*eng. Backpropagation networks*), koji je zasnovan na pravilu učenja s korekcijom pogreške (*eng. error-correction learning rule*) [111]. Glavna karakteristika tog algoritma je prolazak naprijed i natrag kroz neuronsku mrežu. Prilikom prolaska naprijed ulazne veličine aktiviraju neurone u pojedinim slojevima i rezultiraju na kraju skupom izlaznih veličina. Pri tome težinski faktori između pojedinih neurona ostaju nepromjenjivi. Dobivene vrijednosti izlaznih veličina razlikuju se od očekivanih vrijednosti, a njihova razlika predstavlja skup pogreški koje se zatim

"šire" natrag kroz neuronsku mrežu. Prilikom prolaska natrag težinski faktori se korigiraju u skladu s pravilom za korekciju pogreške s ciljem smanjenja pogreške između trenutnih i očekivanih izlaznih veličina.

Algoritam učenja s povratnim širenjem pogreške izveden je za bilo koju aktivacijsku funkciju, a najčešće se za nju odabire jedna od sljedećih funkcija:

- funkcija skoka
- linearna funkcija
- sigmoidalna funkcija



Slika 2.13 Tipovi aktivacijskih funkcija

Tipove aktivacijskih funkcija grafički prikazuje slika 2.13.

Proces učenja neuronskih mreža zasniva se na nizu primjera ulazno-izlaznih vektora koje nazivamo epohom i može se izvesti na dva načina:

- učenje s korekcijom težinskih faktora nakon svakog primjera
- učenje s korekcijom težinskih faktora nakon cijele epohe

Prilikom učenja neuronske mreže na prvi način, korekcija težinskih faktora i pragova izvodi se nakon svakog primjera ulazno-izlaznih vektora. Drugi način učenja neuronske mreže zasnovan je na korekciji težinskih faktora nakon prezentacije svih primjera koji čine jednu epohu.

Važan proces prilikom postupka učenja je odabir početnih težinskih faktora. Uobičajeno je početne vrijednosti težinskih faktora neuronske mreže postaviti na slučajne, uniformno distribuirane vrijednosti unutar malog intervala, da bi se izbjegle negativne posljedice poput preranog zasićenja. Ukoliko je neuronska mreža "dobro" naučena, ona će biti u stanju na temelju primjera iz prošlosti ispravno procijeniti nova, nenaučena stanja koja se mogu pojaviti u budućnosti.

2.4.2 Primjena neuronskih mreža u analizi EES-a

Umjetne neuronske mreže imaju širok spektar primjena koji varira od prepoznavanja uzoraka, klasifikacije uzoraka, optimizacije, predviđanja i automatskog upravljanja. Isto tako našle su primjenu prema dostupnoj literaturi i u raznim segmentima upravljanja i analiza EES-a. Najčešće obrađivane primjene neuronskih mreža prema literaturi [112] su:

- predviđanje opterećenja,
- prepoznavanje kvara / prepoznavanje mjesta kvara,
- ekonomsko optimiranje,
- procjena sigurnosti,
- prijelazna stabilnost.

Korištenje umjetnih neuronskih mreža ima za cilj automatizirati i ubrzati procese odlučivanja u sustavu vođenja EES-a. Glavna zadaća EES-a je isporuka električne energije korisnicima u propisanim iznosima napona i frekvencije. Ta se zadaća mora obavljati u realnom vremenu na siguran i pouzdan način te po mogućnosti uz minimalne troškove. Korištenjem neuronskih mreža moguće je donositi brze procjene te preventivno djelovati u slučaju kvara ili nestabilnosti i vratiti sustav u sigurno stanje uz optimalne troškove.

3 NOVA METODA ZA TOPOLOŠKO PROCESIRANJE U ELEKTROENERGETSKIM MREŽAMA

Metode korištene u istraživanju, odnosno metode kojima se dokazuje sama hipoteza prikazane su u ovom poglavlju. Način i izvedba utiskivanja naponskog testnog signala u elektroenergetsku mrežu nije predmet istraživanja i nije posebno obrađivan u tekstu ove doktorske disertacije. Metodologija istraživanja temeljila se na dokazivanju hipoteze da je moguće pomoću sustava umjetne inteligencije i strojnog učenja iz izmjerenog reflektiranog testnog signala ekstrapolirati informaciju o topološkoj strukturi elektroenergetske mreže na električki udaljenom mjestu bez poznavanja uklopnog stanja sklopnih aparata na istom.

3.1 Metoda za prepoznavanje topologije elektroenergetske mreže interpretacijom refleksije utisnutog naponskog testnog signala


U uvodnom dijelu prikazana je teoretska podloga ponašanja putnog vala u elektroenergetskoj mreži. Putni val elektromagnetski je val koji se propagira elektroenergetskom mrežom te ima svoje mjesto nastanka i smjer širenja. Takav elektromagnetski val ima vremensku i prostornu komponentu i posjeduje sva svojstva poznata iz teorije valova kao što su refleksija, transmisija, superpozicija, prigušenje i druga. Medij širenja elektromagnetskog vala u prijenosnoj mreži je prijenosni vod, odnosno dalekovod. Promjenom geometrije i/ili okružujućeg medija promatranog dalekovoda dolazi do promjene u konstantama propagacije te se prema zakonu o očuvanju energije dio energije elektromagnetskog vala transmitira, a dio reflektira natrag. Amplituda refleksije i transmisije ovisna je isključivo o međusobnom odnosu konstanti propagacije, tj. parametara elektroenergetske mreže na mjestu refleksije tj. transmisije. Elektromagnetski putni val propagira se dalekovodom određenom konačnom brzinom također definiranom geometrijom dalekovoda kojim se val širi. Prema navedenom, izmjereni reflektirani signal sadrži informaciju o udaljenosti mjesta refleksije (iz vremenske oznake) i informaciju o valnoj impedanciji incidentnih dalekovoda na mjestu refleksije iz čega je moguće ekstrapolirati informaciju o topološkoj strukturi. Precizna ekstrapolacija informacije nije jednostavan zadatak obzirom da u promatranjnoj mreži postoje dalekovodi istih ili sličnih duljina, kao i istih ili sličnih jediničnih parametara. Utisnuti testni signal ima važnu ulogu u određivanju topološke strukture opisanim načinom te mora biti odabran i izveden na način da se u obzir uzimaju određena ograničenja navedena u odjeljku 3.1.2.

3.1.1 Algoritam toka


Ovdje predložena metoda za prepoznavanje topologije elektroenergetske mreže zasniva se na interpretaciji reflektiranog testnog signala korištenjem umjetne inteligencije, odnosno korištenjem sustava neuronskih mreža. Predložena metoda sastoji se od dvaju osnovnih dijelova:

- Predimplementacijski dio
- Postimplementacijski dio

a dijagrami toka za oba dijela prikazani su Slikama 3.1. i 3.2.



Slika 3.1 Dijagram toka predimplementacijskog dijela



Slika 3.2 Dijagram toka postimplementacijskog dijela

Predimplementacijski dio potrebno je izvesti samo jednom za određeni dio mreže. U tom dijelu izvodi se optimizacijski proračun za izbor optimalnih pozicija utiskivanja testnog signala. Nakon izbora optimalnih pozicija potrebno je napraviti matematički model za dio prijenosne mreže na kojem se vrši detekcija topološke strukture. Ovdje je moguće iskoristiti i eventualno postojeće modele mreže napravljene u svrhu koordinacije izolacije ili projektiranja zaštite od raznih brzih prijelaznih pojava kao što su atmosferska pražnjenja ili sklopni prenaponi. Matematički model potreban je za izvođenje dovoljnog broja različitih simulacija na poznatoj topološkoj strukturi. Dovoljan broj simulacija potreban je u svrhu učenja sustava umjetnih neuronskih mreža kojeg je u predimplemenacijskoj fazi potrebno kreirati. nakon završenog procesa kreiranja i učenja sustava neuronskih mreža (detaljno prezentirano u narednim poglavljima) završava se predimplementacijski dio. U postimplementacijskom dijelu koristi se gotov, formiran i naučen, sustav neuronskih mreža za interpretaciju izmjerenog

reflektiranog testnog signala. Rezultat postimplementacijskog dijela topološkog prepoznavanja binarni je vektor koji predstavlja topološku strukturu promatranog dijela mreže i kao takav može se koristiti u daljnjim koracima estimacije stanja.

3.1.2 Testni signal

Funkciju testnog signala za prepoznavanje topologije prema ovdje opisanom algoritmu potrebno je izabrati na način da ista pruži najbolju povratnu informaciju. Izbor funkcije testnog signala je proizvoljan, ali mora udovoljiti određenim ograničenjima koja definira algoritam prezentiran ovom doktorskom disertacijom.

Za testni signal u svrhu prepoznavanja mrežne topologije odabrana je funkcija ograničenog vremenskog trajanja i određene amplitude. Ograničeno vremensko trajanje nužno je zbog svojstva superpozicije putujućih valova. Naime, za predloženi algoritam izrazito je nepovoljan slučaj u kojem bi se reflektirani val superponirao na inicijalni injektirani val. Time dolazi do situacije u kojoj bi reflektirani val narušio uzrok svog nastanka što u konačnici dovodi do pogrešnog tumačenja dobivenog rezultata i disfunkcionalnosti predloženog algoritma u detekciji mrežne topologije. Iz navedenog može se zaključiti kako trajanje injektiranog testnog signala može biti najviše toliko da njegova valna duljina bude manja od dvostruke duljine najkraćeg prijenosnog voda u promatranom dijelu mreže pri čemu je nužno uzeti u obzir brzinu širenja putnog vala ovisnu o konstrukcijskim parametrima prijenosnog voda. Navedeno ograničenje opisano je izrazom 3.1.

$$t \leq 2 \cdot l_{tl_min} \sqrt{L_{tl_min} C_{tl_min}} \quad (3.1)$$

gdje su l_{tl_min} , L_{tl_min} i C_{tl_min} duljina, induktivitet i kapacitet najkraćeg prijenosnog voda u promatranom dijelu mreže.

Zbog ograničenog trajanja funkcija testnog ispitnog signala sadrži i odgovarajuće harmoničke komponente. Prisutnost viših frekvencija, odnosno viših harmoničkih komponenti implicira i frekvencijsku ovisnost parametara prijenosnog voda, a time i različitu brzinu propagacije putujućeg vala. Kako bi se frekvencijska ovisnost parametara prijenosnog voda u predloženom algoritmu svela na najmanju moguću mjeru potrebno je odabrati testni signal takav da je doprinos harmoničkih komponenti osnovnoj frekvenciji najmanji mogući tj. da odabrani signal sadrži dominantnu osnovnu frekvenciju. Matematički rečeno, Fourierov

transformat odabranog testnog signala mora imati naglašeno izražen vrh (*peak*) na poziciji osnovne frekvencije.

Osim toga, testni signal mora biti simetrični trofazni signal budući da bi u suprotnom egzistirala nulta komponenta simetričnog trofaznog sustava. Egzistencija nulte komponente simetričnog trofaznog sustava podrazumijeva različitu brzinu širenja signala u tom sustavu obzirom da je brzina širenja signala prijenosnim vodom direktno ovisna o njegovom parametru. Naravno, različita brzina širenja testnog signala može dovesti do disfunkcionalnosti predloženog algoritma i pogrešne interpretacije rezultata.

Amplituda testnog signala može biti proizvoljno odabrana. Ona mora biti tolika da reflektirani signal bude značajno mjerljiv, a svakako iznad razine ukupnog harmoničkog izobličenja u promatranom dijelu mreže. Razina ukupnog harmoničkog izobličenja u mreži hrvatskog elektroenergetskog sustava na 110 kV naponskoj razini iznosi oko 1.5% iznosa osnovnog harmonika, a prema mrežnim pravilima prijenosnog sustava [113] ne smije iznositi više od 3% u 110 kV mreži, a 1.5% u 220 kV i 400 kV mreži. Prijedlog je koristiti signal amplitude 5% jakosti osnovnog harmonika u sustavu na kojem se predložena metoda primjenjuje.

U ovom istraživanju i ovdje predloženoj metodi korišten je simetrični trofazni signal amplitude 1 kV i trajanja 0.01 ms. Takav signal ne predstavlja opasnost za opremu elektroenergetskog sustava u praksi.

3.1.3 Propagacija testnog signala

Utisnuti naponski testni signal u određenoj točki, sabirnici EES-a propagira se u svim smjerovima prema zakonitostima i relacijama opisanima u poglavlju 2.3. Nailaskom signala na diskontinuitet u mediju kojim se širi dio energije vala se transmitira, a dio reflektira natrag prema izvoru. Obzirom na velike brzine širenja elektromagnetskog vala time i velike valne duljine te relativno kratke razlike u duljinama među prijenosnim vodovima vrlo je izvjesna međusobna superpozicija reflektiranih valova. Na mjestu izvora, reflektirani te superponirani val se mjeri te se metodom razvijenom i opisanom ovim doktorskim radom interpretira, a kao rezultat vraća se informacija o topološkom stanju na udaljenoj sabirnici u okolini sabirnice utiskivanja signala. U nastavku je prikazano nekoliko različitih karakterističnih slučajeva propagacije i refleksije testnog signala jakosti i trajanja opisanog u prethodnom poglavlju. Utisnuti naponski testni signal trofazni je simetrični signal funkcije naznačene u odjeljku 3.1.2. Obzirom da je signal trofazni simetrični na grafičkim prikazima vidljiva je 1p shema svakog pojedinog opisanog slučaja.

a) *Propagacija testnog signala vodom u praznom hodu*

Slika 3.3 prikazuje jedan jednostruki prijenosni vod između sabirnica Aa i Ba duljine l_{a1} te parametara R_{a1} , G_{a1} , L_{a1} i C_{a1} pri dominantnoj frekvenciji signala. Testni signal amplitude A_{a1} i trajanja p_{a1} sinusne funkcije injektiran je na sabirnici Aa na koju nije priključeno ništa drugo osim navedenog voda.



Slika 3.3 Propagacija testnog signala vodom u praznom hodu

Prema (2.30) brzina širenja vala iznosi $v_{a1} = 1/\sqrt{L_{a1}C_{a1}}$, a vrijeme proteklo od injekcije do povratka reflektiranog signala iznosi $t_{a1} = 2 \cdot l_{a1}/v_{a1}$. Karakteristična impedancija voda iznosi Z_{a1} i računa se prema (2.21). Amplituda reflektiranog signala ovisna je o uklopnom stanju na kraju voda odnosno koeficijentu refleksije te prigušenju uslijed radnog otpora voda i prema (2.50) iznosi:

$$A_{a1}^R = r_{Ba} \cdot \frac{\xi A_{a1}}{1 - r_{Ba} r_{Aa} 10^{-\frac{\alpha_{a1} l_{a1}}{20}}} \quad (3.2)$$


gdje su r_{Ba} i r_{Aa} koeficijenti refleksije na obje sabirnice respektivno i u ovom slučaju iznose 1 što znači da će se upadni val na otvorenom kraju voda reflektirati u punom iznosu i fazi. ξ je koeficijent razdjeljivanja na početku voda i u konkretnom slučaju iznosi također 1. α_{a1} je ukupni koeficijent uzdužnog prigušenja i računa se prema izrazu (2.33). Slijedom navedenog, amplituda reflektiranog signala iznosi:

$$A_{a1}^R = \frac{A_{a1}}{1 - 10^{-\frac{\alpha_{a1} l_{a1}}{20}}} \quad (3.3)$$

Ukoliko je na sabirnici Aa izmjeren reflektirani val u vremenu t_{a1} s amplitudom A_{a1}^R , u prikazanom slučaju može se zaključiti da je predmetni vod na udaljenoj sabirnici Ba u praznom hodu i bez poznavanja uklopnog stanja sklopnih aparata na istoj.

b) Propagacija testnog signala vodom zatvorenim sabirnicom sa dva incidentna voda

Nešto složeniji slučaj prikazan je na sljedećem primjeru prikazanom Slikom 3.4. Na slici je prikazan jednostruki prijenosni vod između sabirnica Ab i Bb. Na sabirnicu Bb priključena su još dva različita prijenosna voda zatvorena sabirnicama Cb i Db na drugom kraju. Sabirnica Ab pozicija je utiskivanja testnog signala i mjerenja refleksije i na istu nije povezano ništa drugo osim prijenosnog voda prema sabirnici Bb.



Slika 3.4 Propagacija testnog signala na sabirnici s više incidentnih vodova

Prijenosni vod Ab – Bb dug je l_{b1} te parametara R_{b1} , G_{b1} , L_{b1} i C_{b1} pri dominantnoj frekvenciji signala. Testni signal amplitude A_{b1} i trajanja p_{b1} sinusne funkcije injektiran je na sabirnici Ab. Parametri vodova Bb – Cb i Bb – Db su R_{b2} , G_{b2} , L_{b2} , C_{b2} i R_{b3} , G_{b3} , L_{b3} , C_{b3} respektivno, a duljina l_{b2} i l_{b3} . Amplituda i trajanje injektiranog signala jednaki su kao u prethodnom slučaju. Vrijeme povratka reflektiranog signala na sabirnicu Ab iznosi $t_{b1} = 2 \cdot l_{b1}/v_{b1}$, a amplituda reflektiranog signala računa se prema izrazu (2.50). U ovom je slučaju, za razliku od prethodnog, koeficijent refleksije na sabirnici Bb ovisan o uklopnom stanju vodova na njoj i prema (2.44) iznosi:

$$r_{Bb} = \frac{Z_{b2} + Z_{b3} - Z_{b2}Z_{b3}Z_{b1}}{Z_{b2} + Z_{b3} + Z_{b2}Z_{b3}Z_{b1}} \quad (3.4)$$

gdje su Z_{b2} i Z_{b3} karakteristične impedancije vodova Bb – Cb i Bb – Db. Ovdje je važno napomenuti i da će se transmitirani dio signala također reflektirati na sabirnicama Cb i Db. Nakon što se tako reflektirani signal transmitira kroz sabirnicu Bb jedan njegov dio doći će u obliku vala i na sabirnicu Ab na kojoj može biti izmjeren. Vrijeme proteklo do nailaska tih putnih valova jednako je sumi vremena potrebnog za refleksiju na svakom pojedinomvodu i jednostavno se analitički može odrediti prema (3.5) i (3.6)


$$t_{b12} = 2 \cdot (l_{b1}/v_{b1} + l_{b2}/v_{b2}) \quad (3.5)$$

$$t_{b13} = 2 \cdot (l_{b1}/v_{b1} + l_{b3}/v_{b3}) \quad (3.6)$$

gdje su t_{b12} i t_{b13} vremena refleksije od sabirnice Cb, odnosno Db. Ova informacija može biti dodatna, redundantna, informacija vezana uz uklopno stanje na sabirnici Bb budući da sama mogućnost očitavanja reflektiranog vala sa sabirnice Cb i Db nužno znači da su pripadajući prijenosni vodovi povezani na sabirnicu Bb.

c) Propagacija testnog signala vodom zatvorenim sabirnicom s jednim ili više vodova i jednim transformatorom

U ovom slučaju na sabirnicu Bc osim prijenosnog voda priključen je transformator TRc. Transformator je mrežni element s koncentriranim parametrima te na njemu ne postoji prostorno rasprostiranje putnog vala već samo refleksija ovisna o njegovoj karakterističnoj impedanciji. Karakteristična impedancija transformatora Z_{CTR} također je ovisna o njegovim konstrukcijskim parametrima i računa se prema izrazu (2.27). Slika 3.5 prikazuje opisani slučaj.



Slika 3.5 Propagacija testnog signala na sabirnici s incidentnim transformatorom

Prijenosni vod Ac – Bc dug je l_{c1} te parametara R_{c1} , G_{c1} , L_{c1} i C_{c1} pri dominantnoj frekvenciji signala. Testni signal amplitude A_{c1} i trajanja p_{c1} sinusne funkcije injektiran je na sabirnici Ac. Parametri voda Bc – Cc su R_{c2} , G_{c2} , L_{c2} , C_{c2} , a duljina l_{c2} . Amplituda i trajanje injektiranog signala jednaki su kao u prethodnim slučajevima. Vrijeme povratka reflektiranog signala iznosi na sabirnicu Ac iznosi $t_{c1} = 2 \cdot l_{c1}/v_{c1}$, a amplituda je jednaka (3.7)

$$A_{c1}^R = r_{Bc} \cdot \frac{\xi_{A_{c1}}}{1 - r_{Bc} r_{Ac} 10^{\frac{\alpha_{c1} \cdot l_{c1}}{20}}} \quad (3.7)$$

vrijednosti ξ i r_{Ac} kao i u prethodnim slučajevima jednake su 1 zbog tog što je i u ovom slučaju na sabirnicu utiskivanja signala Ac priključen samo vod $Ac - Bc$. r_{Bc} u ovom slučaju iznosi:


$$r_{Bc} = \frac{Z_{c2} + Z_{cTR} - Z_{c2}Z_{cTR}Z_{c1}}{Z_{c2} + Z_{cTR} + Z_{c2}Z_{cTR}Z_{c1}} \quad (3.8)$$

iz čega je jasno da upadni putujući val vidi paralelan spoj transformatora i prijenosnog voda.

Transmitirani dio signala putovati će samo vodom $Bc-Cc$ i reflektirati se od sabirnice Cc natrag. Dio tog reflektiranog signala izmjereno na sabirnici Ac postojati će samo u vremenu potrebnom da testni signal prevali put od sabirnice Ac do Cc i natrag.

d) Propagacija testnog signala u upetljanoj mreži

Znatno složeniji slučaj javlja se ukoliko je promatrani dio prijenosne mreže upetljane odnosno zamkaste strukture. Prijenosna mreža u svojoj naravi i jest upetljana i ovakav slučaj je temelj za daljnju razradu i interpretaciju utisnutog testnog signala. Za razliku od prethodnih slučajeva, osim reflektiranog dijela testnog signala, na sabirnicu na kojoj se utiskuje signal i mjeri refleksija dolazi i transmitirani dio signala koji nužno sudjeluje prilikom interpretacije rezultata i procjeni topološkog stanja. Najjednostavniji slučaj upetljane mreže prikazan je slikom 3.6.



Slika 3.6 Propagacija testnog signala u upetljanoj mreži

Sabirnica Ad pozicija je utiskivanja testnog signala i mjerenja refleksije. Utisnuti signal širi se u svim smjerovima preko svih incidentnih vodova sa sabirnicom Ad . Ovdje je bitno naglasiti da ovo nije slučaj razdjeljivanja signala na početku voda kako je to opisano u poglavlju 2.3.3. f) već se smatra da je izvor signala dovoljne snage da se u sabirnicu utisne signal željene amplitude. Utisnuti signal putuje vodovima $Ad - Bd$ i $Ad - Cd$ te se energija vala na

sabirnicama Bd i Cd podijeli na reflektirani i transmitirani dio. Transmitirani valovi putuju vodom Bd – Cd svaki u svom smjeru gdje također nailaze na sabirnice Bd i Cd gdje opet dolazi do refleksije i transmisije. Ukoliko su prijenosni vodovi bliskih duljina, što je u praksi često i slučaj, doći će do višestrukih interferencija. Transmitirani val koji dolazi na sabirnicu Ad u smjeru Ad – Bd – Cd interferirat će s višestruko reflektiranim valom na vodu Ad – Cd, a transmitirani val u smjeru Ad – Cd – Bd interferirat će s višestrukim refleksijama na vodu Ad – Bd. Također, višestruke refleksije podrazumijevaju i višestruke transmisije pa će tako postojati i interferencije s transmitiranim valovima kroz samu sabirnicu Ad. Također, potrebno je uzeti u obzir i da sabirnica utiskivanja signala i mjerenja refleksije nije u praznom hodu kao i u prethodnim slučajevima već i da na njoj samoj postoji refleksija s koeficijentom različitim od 1.

Vidljivo je da u ovom slučaju postoje višestruke refleksije i transmisije putnih valova kao i međusobne interferencije što funkciju izmjerenog signala može učiniti vrlo složenom. Analitički pristup interpretaciji složenog signala, čak i na najjednostavnijem slučaju upetljane mreže, postaje dugotrajan, a time i nepraktičan za uporabu u topološkom procesiranju.

3.1.4 Interpretacija reflektiranog testnog signala

Analitička interpretacija izmjerenog signala koji nosi topološku informaciju, čak i na vrlo jednostavnom modelu upetljane mreže, složen je i dugotrajan postupak. U obzir moraju biti uzeti svi koeficijenti refleksije i transmisije, prigušenje i distorzija vala na svakom vodu te razdjeljivanje signala na samom mjernom mjestu. K tome, izmjereni signal superpozicija je svih relevantnih signala reflektiranih ili transmitiranih od susjednih sabirnica koji pristignu u promatranom vremenu. Promatrano vrijeme predstavlja vrijeme povratka reflektiranog testnog signala od najudaljenije susjedne sabirnice, a u tom vremenu moguće su i višestruke refleksije na sabirnicama povezanim preko višestruko kraćih vodova. Prijenosni vodovi prema susjednim sabirnicama mogu biti istih ili sličnih parametara i duljina što zbog velike valne duljine injektiranog signala za posljedicu može imati podjednako vrijeme refleksije na sabirnicu na kojoj se signal mjeri. Svi testni signali prispjeli na tu sabirnicu u vremenu refleksije kraćem od perioda bilo kojeg od pristiglih signala međusobno će superponirati tako da će njihova superpozicija biti funkcija izmjerenog signala. Kako bi se pravilno interpretirao tako reflektirani signal potrebno je napraviti dva ključna koraka:

- ispravno odabrati frekvenciju uzorkovanja analognog signala,
- izvesti dekompoziciju izmjerenog signala na doprinose pojedine refleksije.

Prvo, potrebno je napraviti analognu – digitalnu pretvorbu izmjerenog signala sa dovoljnom frekvencijom uzorkovanja kako bitna informacija koju signal nosi ne bi bila propuštena. Cjeloviti teorem uzimanja uzoraka (*eng. Sampling Theorem*) [114] kaže da je kontinuirani signal čiji su koeficijenti Fourierove transformacije jednaki nuli izvan intervala $(-\omega_o, \omega_o)$ jedinstveno određen svojim vrijednostima definiranim u jednako udaljenim trenucima vremena ukoliko je kružna frekvencija uzorkovanja veća od $2\omega_o$. Kontinuirani se signal $x(t)$ može proračunati iz diskretnog signala $x(kT)$ interpolacijskom formulom:

$$x(t) = \sum_{k=-\infty}^{\infty} x(kT) \cdot \frac{\sin \frac{\omega_s(t-kT)}{2}}{\frac{\omega_s(t-kT)}{2}} \quad (3.9)$$

gdje je $\omega_s = 2\pi f_s = 2\pi/T$ kružna frekvencija uzorkovanja. Drugim riječima, ukoliko kontinuirani signal sadrži frekvencije od 0 Hz do maksimalno f_o Hz tada on u potpunosti može biti rekonstruiran iz slijeda uniformno udaljenih diskretnih uzoraka koji se pojavljuju s frekvencijom uzorkovanja f_s većom od $2f_o$ Hz. Iz navedenog slijedi da cjeloviti teorem uzimanja uzoraka vrijedi i za ovaj slučaj i on glasi:

$$f_s \geq 2f_o \quad (3.10)$$


Drugo, kako bi se ispravno interpretirao izmjereni signal potrebno je izvesti njegovu dekompoziciju. Dekompozicija ovdje predstavlja raščlambu superponiranog signala na njegove sastavne komponente, odnosno na zaseban doprinos svakog pojedinog vala reflektiranog od susjedne sabirnice. Pri tom su od presudne važnosti amplitude reflektiranih valova dok cjelovite funkcije svakog pojedinog reflektiranog vala nije potrebno rekonstruirati.

Dekompozicijski algoritam jedan je od osnovnih doprinosa ove doktorske disertacije i detaljno je pojašnjen u poglavlju 3.2.

3.2 Algoritam za određivanje topologije elektroenergetske mreže bez poznavanja stanja sklopnih aparata

Razvijeni algoritam za određivanje topologije elektroenergetske mreže bez poznavanja stanja sklopnih aparata na udaljenoj sabirnici temelji se na ekstrapolaciji izmjerenog, utisnutog, testnog signala te interpretaciji tako prikupljene informacije pomoću sustava umjetnih

neuronskih mreža (eng. *artificial neural networks* - ANN). Razlog korištenja umjetnih neuronskih mreža je vrlo složeno, dugotrajno, a time i ne-svrshodno rješavanje takvog problema analitičkim putem. Razvijeni algoritam temelji se na sustavu neuronskih mreža koje se funkcionalno mogu podijeliti u dvije osnovne cjeline. Prva cjelina tj. prvi sustav obavlja dekompoziciju izmjerenog testnog signala na doprinose refleksije od svake pojedine sabirnice na svakom pojedinom mjernom mjestu, a drugi sustav obavlja funkciju prepoznavanja topološke strukture koristeći rezultat dekompozicije kao ulazni parametar. Navedeni proces predstavljen je blok shemom prikazanim na slici 3.7.



Slika 3.7 Blok shema sustava ANN za prepoznavanje topologije EES-a

Na slici 3.7 DANN (eng. *decomposer artificial neural network*) predstavlja dekompozicijski sustav umjetnih neuronskih mreža, a TANN (eng. *topology artificial neural network*) sustav umjetnih neuronskih mreža za prepoznavanje topologije na temelju ulaznog dekomponiranog vektora. Prema slici 3.7 svaki pojedini podsustav (1 – i) odnosi se na svaku pojedinu sabirnicu na kojoj se utiskuje i mjeri testni signal. Proces učenja sustava neuronskih mreža potrebno je napraviti samo jednom inicijalno za svaku određenu poziciju utiskivanja i

mjerenja testnog signala. Nakon završenog procesa učenja ANN sustav obrađuje ulazni signal i kao rezultat vraća izlazni vektorski prostor koji predstavlja topologiju sustava. Proces učenja ANN sustava opisan je u algoritmima u narednim poglavljima, a učenje se odvija pomoću simulacija na verificiranom modelu mreže. Naravno, moguće je učenje provesti i na stvarnim izmjerenim podacima iz realnog sustava što je svakako korisnija opcija, međutim problem kod tog je prikupljanje dovoljnog broja izmjerenih podataka s različitim topologijama kako bi učenje bilo moguće adekvatno provesti. Trajanje samog procesa učenja u ovom algoritmu nije od presudnog značaja obzirom da pripada predimplementacijskom dijelu opisane metode.

3.2.1 Algoritam za dekompoziciju izmjerenog signala

Algoritam za dekompoziciju izmjerenog ulaznog signala dio je prve faze procesa određivanja topologije elektroenergetske mreže na temelju analize refleksije putujućih valova. Prva faza procesa počinje mjerenjem signala na optimalno odabranom mjestu u elektroenergetskoj mreži. Izmjereni signal zapisan je u obliku vektora čije vrijednosti svakog pojedinog člana odgovaraju svakom pojedinom uzorku digitalnog oblika mjerenog signala. Ukoliko je brzina uzorkovanja veća, ulazni vektor imat će više članova. Duljina ulaznog vektora odgovara trajanju izmjerenog signala. Za trajanje izmjerenog signala uzima se vrijeme potrebno da reflektirani val od kraja najduljeg voda incidentnog sa susjednom sabirnicom pristigne na ishodišno mjesto tj. mjesto utiskivanja testnog signala. Susjedna sabirnica je ona sabirnica koja je samo jednim vodom povezana sa sabirnicom injekcije testnog signala. Na taj način formirani vektor izmjerenih vrijednosti ulazi u sustav neuronskih mreža za dekompoziciju izmjerenog signala DANN, obzirom da je izmjereni signal superpozicija svih reflektiranih signala pristiglih u injekcijsku točku promatranog dijela mreže u vremenu u kojem mjerenje traje. Obzirom na velike valne duljine elektromagnetskog vala gotovo svi reflektirani signali bit će međusobno superponirani stoga je prvi izazov raščlaniti superpoziciju u izmjerenom signalu na doprinos refleksije od svake pojedine sabirnice u promatranom dijelu mreže. Rezultat dekompozicije je vektor kojem su vrijednosti jednake amplitudama izmjerenog reflektiranog signala u i -tom retku koji odgovara vremenskom uzorku u kojem se očekuje reflektirani val na točki injekcije. Polazišna točka je izraz 3.11.

$$[MV] = [A][DPV] \quad (3.11)$$

$[MV]$ predstavlja vektor izmjerenih vrijednosti prema prethodno navedenom opisu, $[A]$ je linearni operator dimenzija $n \times n$ s elementima:

$$A_{ij} = \begin{cases} V_0 \cos \left[\frac{(i-j)\pi}{\frac{sd}{2}} \right] & ; \quad |i-j| \leq \frac{sd}{2} \\ 0 & ; \quad |i-j| > \frac{sd}{2} \end{cases} \quad (3.12)$$


V_0 predstavlja amplitudu utisnutog testnog naponskog signala, a sd predstavlja njegovo diskretizirano trajanje. $[DPV]$ je dekomponirani vektor s amplitudnim vrijednostima na pozicijama očekivanog vremena refleksije signala od pojedine sabirnice dok su preostale vrijednosti jednake nuli. Obzirom da je cilj dobiti dekomponirani vektor kako bi bio jasniji doprinos refleksije od svake pojedine promatrane sabirnice u superponiranom signalu, potrebno je riješiti sustav jednažbi 3.13.

$$[DPV] = [A]^{-1}[MV] \quad (3.13)$$

Obzirom da je $\det \mathbf{A} \cong 0$, matrica $\mathbf{A}$ je skoro singularna i nije moguće naći inverznu matricu polazne matrice, potreban za rješavanje sustava jednažbi 3.13. što ovaj problem čini nerješivim analitičkim putem.

Kako bi naznačeni problem bio riješen, osmišljen je sustav neuronskih mreža za dekompoziciju ulaznog vektora izmjerenih vrijednosti. Sustav u suštini obavlja inverzni proces u odnosu na linearni operator $\mathbf{A}$, međutim nije ispravno poistovjetiti ga s matematičkim invertiranjem matrice $\mathbf{A}$. Arhitektura sustava umjetnih neuronskih mreža za dekompoziciju vektora izmjerenih vrijednosti prikazana je slikom 3.8. Arhitektura sustava sastoji se od triju vrsta međusobno nezavisnih slojeva (*eng. layer*): *Locally Connected*, *Dense* i *Sparse*. Izlazni vektor svakog od navedenih slojeva predstavlja ulazni vektor u sljedeći sloj.


Sustav se zapravo sastoji od dvaju *Locally Connected* slojeva, triju *Dense* slojeva te jednog modificiranog *kSparse* sloja.



Slika 3.8 Blok shema sustava ANN za dekompoziciju vektora izmjerenih vrijednosti

3.2.1.1 Locally Connected sloj

Locally Connected sloj je neuronska mreža konvolucijskog tipa s različitim, nedijeljenim, težinskim faktorima. Konvolucija je matematički pojam koji definira integral koji opisuje količinu preklapanja jedne funkcije s drugom dok se jedna pomiče preko druge [111]. Konvolucijskom neuronskom mrežom u sferi umjetne inteligencije naziva se kompozicija obuhvaćena učenjem lokalnih stacionarnih struktura koji se sastavljaju u hijerarhijske obrasce s više razina [115]. Konvolucijske neuronske mreže izuzetno su učinkovite u prepoznavanju određenih, statistički značajnih, uzoraka u skupovima s velikim brojem podataka. Neuronska struktura *Locally Connected* sloja prikazana je slikom 3.9. Razlog korištenja u konkretnom slučaju je prepoznavanje određene lokalne korelacije među pojedinim uzorkovanim vrijednostima izmjerenog signala, odnosno u izmjerenom signalu potrebno je pronaći sumu funkcija poznatog oblika koja daje taj signal.




Slika 3.9 Shema Locally Connected sloja

Obzirom da je funkcija utisnutog signala poznata, približno je poznat i oblik funkcije svakog reflektiranog signala. Reflektirani signal približno je jednakog oblika kao injektirani, naravno umanjen u amplitudi za koeficijent refleksije i prigušenja uslijed radnog otpora, te lagano deformiran uslijed frekvencijske ovisnosti parametara voda. Također, ovako definiran sustav neuronskih mreža za dekompoziciju signala u mogućnosti je eliminirati utjecaj izobličenja tj. distorzije signala budući da je koncipiran na način da konvolucijski traži najbolju funkciju koja odgovara izmjerenom signalu uzevši u obzir funkciju injektiranog testnog signala. Ovdje je naime iskorišteno fizikalno inženjersko znanje o ponašanju putnih valova u elektroenergetskom sustavu opisano u uvodnom poglavlju.

Ovdje razvijeni *Locally Connected* sloj podijeli ulazni izmjereni vektor na n dijelova širine sd što je diskretizirana širina injektiranog testnog signala. Svaki od n dijelova ulaznog vektora množi se matricom dimenzije $sd \times sd$ kako bi se dobilo n vektora dimenzije $sd \times 1$ koji se na kraju spajaju u jedan vektor koji još jednom ponovno prolazi isti postupak prije nego prijeđe u drugi sloj. Razlog ponavljanja postupka je unaprjeđenje samog postupka učenja i preciznosti samog rezultata. Inicijalne vrijednosti u matricama kojima se izvode operacije nad ulaznim vektorom su slučajno odabrani brojevi koji se korigiraju u procesu učenja *backpropagation* algoritmom.

3.2.1.2 Dense sloj

Dense sloj je potpuno povezana (eng. *fully connected*) neuronska mreža s različitim, nedijeljenim, težinskim faktorima. Shema trostrukog *Dense* sloja prikazana je slikom 3.10.



Slika 3.10 Shematski prikaz trostrukog *Dense* sloja u DANN-u

Dense sloj obavlja klasifikaciju na strukturama dobivenim iz konvolucijskih slojeva kao što je *Locally Connected*. *Dense* sloj neuronske je strukture gdje je svaki čvor u narednom povezan sa svakim čvorom u prethodnom sloju [116]. Posljednji sloj sadrži jedan čvor za svaki ciljani uzorak u određenom slučaju (svaki mogući uzorak koji pojedini slučaj može sadržavati), s normaliziranom eksponencijalnom funkcijom kao aktivacijskom funkcijom za generiranje vrijednosti između $0 \div 1$. Vrijednosti ovako definirane aktivacijske funkcije za dani uzorak mogu se interpretirati kao relativno mjerenje vjerojatnosti da uzorak pada u svaku ciljnu klasu. U ovom slučaju *Dense* sloj izveden je kao $N \times N$ matrica s normaliziranom eksponencijalnom funkcijom kao aktivacijskom funkcijom. N je broj uzoraka u izmjerenom reflektiranom signalu. Vrijednosti u matrici su parametri koji se ažuriraju u procesu učenja neuronske mreže *backpropagation* algoritmom.

3.2.1.3 kSparse sloj


Numeričko nalaženje inverzne vrijednosti približno singularnih operatora je veoma zahtjevan problem koji se manifestira u velikom rasponu mogućih operatora koji bi ga gotovo jednako dobro opisivali. Aproksimacija inverzne vrijednosti početne matrice u obliku neuralne mreže koja sadrži samo gore navedene konvolucijske i *Dense* slojeve također ne bi riješila taj problem s obzirom da postoji više različitih setova težinskih faktora za koje bi takva mreža bila dovoljno dobra aproksimacija. Iz navedenog se može zaključiti kako treba uvesti dodatno

ograničenje na mrežu. Može se iskoristiti činjenica da je broj značajnih signala koji se očitavaju u točkama injekcije puno manji od broja točaka mjerenja. Zbog toga se može zahtijevati da izlazni vektor takve mreže bude takav da mu je samo određen broj članova različit od nule. Takav zahtjev se može implementirati uvođenjem dodatnog sloja u neuralnu mrežu koji bi zadržavao n najvećih članova ulaznog vektora, a sve ostale bi postavio na nulu. Takav sloj je već korišten u prijašnjim radovima te se naziva *kSparse* sloj [117, 118]. Sloj konstruiran na taj način nema težinskih faktora koji se prilagođavaju tijekom procesa učenja, ali utječe na dinamiku učenja ostalih slojeva koji mu prethode. Važno je naglasiti da takav sloj provodi diferencijabilnu operaciju nad vektorom što omogućuje korištenje *backpropagation* algoritma za proces učenja. Za korištenje *kSparse* sloja potrebno je kao hiperparametar postaviti broj k koji predstavlja broj najvećih vrijednosti koje se zadržavaju.

U predmetnom problemu k nije fiksni broj i potrebno ga je odrediti. Naime, broj refleksija koji predstavlja i broj interesantnih najvećih vrijednosti koje se propuštaju u modificiranom *kSparse* sloju razlikuje se od slučaja do slučaja, odnosno ovisan je o topologiji koja se želi odrediti. Za potrebe predmetnog problema konstruiran je modificirani *kSparse* sloj koji će imati dva ulazna vektora. Iz prvog ulaznog vektora se procjenjuje vrijednost broja k dok se na drugi ulazni vektor provodi operacija zadržavanja k članova s najvećom apsolutnom vrijednošću (reflektirani signali mogu imati pozitivan i negativan predznak) nakon koje dobiveni vektor predstavlja izlazni vektor modificiranog *kSparse* sloja. Arhitektura DANN-a je postavljena tako da su ulazni vektori u modificirani *kSparse* sloj ulazni vektor DANN-a (vektor mjerenja) te izlazni vektor posljednjeg *Dense* sloja kao što se vidi na blok shemi 3.8. Izlazni vektor modificiranog *kSparse* sloja ujedno je izlazni vektor DANN-a. Broj nepromijenjenih članova propuštenih na izlaz k unutar modificiranog *kSparse* sloja određuje se relacijom 3.14.

$$n = k \sum_i^N \tanh(|x_i|) \quad (3.14)$$


x_i predstavlja elemente ulaznog vektora tj. vektora izmjerenih vrijednosti, N je njegova diskretizirana veličina dok je k koeficijent hiper-parametar DANN-a i iskustveno je određen. Funkcija *tanh* iskorištena je zbog svog oblika prikazanog slikom 3.11.



Slika 3.11 Tanh funkcija

Kao što je vidljivo na slici 3.11 $f(x) = \tanh(|x|)$ ima vrijednost 1 u svim elementima domene osim u onima u okolini nule. To znači da će izraz 3.14. sve elemente ulaznog vektora izmjerenih vrijednosti postaviti na 1 i sumirati osim onih koji imaju izraženo nisku vrijednost. Ovime je pretpostavljeno da je broj vrijednosti postavljenih na 1 proporcionalan broju refleksija od interesa u promatranom trenutku na promatranom dijelu mreže te se taj broj uzima kao broj elemenata koje modificirani *kSparse* sloj propušta nepromijenjene. Operacija koja se vrši modificiranim *kSparse* slojem na njegov prvi ulazni vektor (određivanje broja k) nije diferencijabilna te se ne može provoditi *backpropagation* algoritam osim u slučaju ako je prvi ulazni vektor modificiranog *kSparse* sloja ujedno i ulazni vektor cijele neuronske mreže jer tad nije potrebno propagirati pogrešku kroz takvu operaciju (ne postoje težinski faktori koji se trebaju mijenjati prije vršenja takve operacije).

Proces dekompozicije izmjerenog signala razvijenim sustavom neuronskih mreža shematski je prikazan slikom 3.12.



Slika 3.12 Proces dekompozicije vektora izmjerenih vrijednosti

3.2.1.4 Proces učenja DANN-a

Kako bi bio funkcionalan, ovako formiran sustav umjetnih neuronskih mreža mora proći proces učenja. Postoji nekoliko načina za učenje umjetnih neuronskih mreža koji su opisani u uvodnom poglavlju, a ovise o načinu i vrsti neuronskih mreža, a osobito o njihovoj namjeni. Algoritam korišten u konkretnom problemu jedan je od najpoznatijih algoritama za učenje neuronske mreže i naziva se „algoritam povratne propagacije pogreške“ ili kraće *backpropagation* algoritam budući da se pogreška izračunava na izlazu i distribuira se unatrag kroz slojeve neuronske mreže.

a) *Backpropagation* algoritam

Prije korištenja bilo kakvog algoritma učenja potrebno je definirati funkciju pogreške (*eng. error*) koja bi bila mjera razlike izlaznih vrijednosti neuronske mreže i ciljanih vrijednosti. Postoji širok raspon *error* funkcija koje se koriste u praksi. Za probleme regresije najčešće se koristi metoda najmanjih kvadrata (*eng. mean squared error*) koja je prikazana izrazom (3.15) nad skupom primjera za učenje D [119]:

$$E(\vec{w}) = \frac{1}{2} \sum_{d \in D} (t_d - o_d)^2 \quad (3.15)$$

gdje je t_d ciljani, a o_d dobivena izlazna vrijednost proizašla iz neuronske mreže. Kod višeslojne mreže (kakav je ovdje slučaj) izlazni sloj može sačinjavati i više neurona, pa se pogreška definira kao:

$$E(\vec{w}) = \frac{1}{2} \sum_{d \in D} \sum_{k \in \text{izlaz}} (t_{kd} - o_{dk})^2. \quad (3.16)$$

Za probleme binarne klasifikacije u većini slučajeva kao *error* funkcija koristi se *binary cross-entropy* prikazana izrazom (3.17). Pojam *cross-entropy* dolazi iz informacijske teorije i predstavlja mjeru razlike među raspodjelama vjerojatnosti dviju slučajnih varijabli. *Cross-entropy* je minimalan ako su dvije navedene raspodjele jednake [119]. Pri klasifikacijskim problemima u principu želi se procijeniti koja je vjerojatnost da određeni ulazni vektor pripada nekoj određenoj klasi. Može se pretpostaviti da poznati primjeri predstavljaju slučajnu varijablu gdje se postavi da primjeri iz određene klase imaju vjerojatnost 1 da pripadaju toj klasi, a primjeri koji nisu iz te klase imaju vjerojatnost 0 da pripadaju toj klasi. Također, analogno tome izlazne vrijednosti neuronske mreže mogu se shvatiti kao vjerojatnosti da pripadni ulazni vektor pripada toj klasi. Kako bi zahtijevali da je razlika te dvije slučajne varijable minimalna može se koristiti relaciju (3.17) kao error funkciju

$$E(\vec{w}) = - \sum_{d \in D} (t_d \log(o_d)) \quad (3.17)$$

U procesu učenja pokušava se minimizirati *error* funkcija. Kombinacija težinskih faktora koja minimizira tu razliku smatra se rješenjem problema učenja. *Backpropagation* je iterativni algoritam koji inkrementalno mijenja težinske faktore. Postavlja se pitanje za koliko promijeniti neki težinski faktor tijekom jedne iteracije procesa učenja. Cilj je najviše promijeniti onaj težinski faktor čijom promjenom se najviše smanji *error* funkcija [119]. Matematički se to može zapisati na način (3.18)

$$\Delta \omega_{kj} = -\alpha \frac{\partial E}{\partial \omega_{kj}} \quad (3.18)$$

pri čemu je E error funkcija, ω težinski faktor i a je slobodni parametar koji se naziva *learning rate*. Izraz (3.18) osnova je *backpropagation* algoritma. U svakom koraku, težinski faktor u određenom sloju mijenja se u smjeru najvećeg spusta niz plohu pogreške (*gradient descent*). Za funkcionalan proces učenja potrebno je naći parcijalnu derivaciju error funkcije po svakom težinskom faktoru koji će se tada promijeniti za iznos određen relacijom (3.18). Ako su operacije primijenjene u slojevima kao i aktivacijske funkcije korištene u njima diferencijabilne, moguće je pravilima lančanog deriviranja doći do derivacije po svakom težinskom faktoru. Nakon dovoljno iteracija $E(\mathbf{w})$ teži k minimumu. Može se primijetiti da je $E(\mathbf{w})$ u svim praktičnim slučajevima funkcija velikog broja varijabli te može sadržavati lokalne minimume koji nisu dovoljno dobra rješenja. Postavi li se premalen parametar a tijekom procesa učenja $E(\mathbf{w})$ može ući u lokalni minimum iz kojeg teško može izaći jer se težinski faktori tijekom svake iteracije mijenjaju za malen broj. S druge strane, bude li a prevelik nećemo moći postići konvergenciju u globalni minimum. Preporuča se korištenje većeg a na početku procesa učenja te njegovo postupno smanjivanje. Postoje razne verzije *backpropagation* algoritama koji ne neki način variraju parametar a tijekom procesa učenja kako bi se izbjegli globalni minimumi. Najčešće korišteni su (SGD, RMSProp, AdaGRAD, AdaDelta, Adam [120]). U ovom radu u svakom procesu učenja korišten je Adam (*Adaptive moment estimation*) .

b) Primjena backpropagation algoritma u učenju DANN-a

Izmjereni signal diskretiziran je uzorkovani signal koji se dekomponira na način da je rezultat vektor koji sadrži samo vrijednosti amplituda svih značajnih refleksija testnog signala izmjerenih na mjestu na kojem je signal utisnut. Obzirom da je utisnuti signal poznate funkcije, reflektirani signali imati će gotovo identičan funkcijski oblik izmijenjen samo u smislu prigušenja i blage distorzije koja se može dogoditi ukoliko na vodu nije zadovoljen uvjet (2.34). Uvažavajući navedeno, u procesu učenja uključuje se dodatni sloj koji rekonstruira početni signal množenjem dekomponiranog vektora linearnim operatorom $[A]$ s elementima iz (3.12). Navedeno je moguće zapisati s (3.19).

$$[MV]' = [A][DPV] \quad (3.19)$$

$[MV]'$ predstavlja rekonstruirani vektor diskretnih izmjerenih vrijednosti dobiven množenjem linearnog operatora $[A]$ s dekomponiranim vektorom $[DPV]$. Iz rekonstruiranog vektora $[MV]'$

i početnog vektora diskretiziranih izmjerenih vrijednosti $[MV]$ dobiva se funkcija pogreške l koju je potrebno minimizirati. Dakle funkcija pogreške izgleda (3.20):

$$l = \sum_i^N |x_i - x'_i|^{\sqrt[8]{x_i}} \quad (3.20)$$


gdje su x_i članovi vektora $[MV]$, a x'_i vektora $[MV]'$. $\sqrt[8]{x_i}$ iskustveno je odabran koeficijent u svrhu zanemarivanja preturbacija oko 0. *Backpropagation* algoritam postavlja težinske faktore na načina da je l minimalan odnosno takve da je $dl \rightarrow 0$. Bitno je za naglasiti da *backpropagation* algoritam djeluje na korekcije težinskih faktora među pojedinim neuronima isključivo u *Locally Connected* i *Dense* sloju dok modificirani *kSparse* sloj i linearni operator $[A]$ nisu podložni promjenama u ovom slučaju.

3.2.2 Algoritam za određivanje topologije elektroenergetske mreže


Druga faza za prepoznavanje topologije elektroenergetskog sustava u sustavu neuronskih mreža naziva se TANN (od eng. *Topology Artificial Neural Network*). Taj sustav koristi izlazne vektore DANN-a tj. dekomponirane vektore $[DPV]$ iz svih optimalno odabranih mjernih točaka kao ulaz, a izlazni sloj TANN sustava predstavlja vjerojatnosti uključenosti svakog prekidača za određeni ulazni vektor. Nakon toga potrebno je postaviti graničnu vrijednost (eng. *threshold*) na dobivene vjerojatnosti. Ako je izlazna vjerojatnost veća od granične vrijednosti, taj prijenosni vod smatra se priključenim na pripadajuću sabirnicu. U suprotnom, ako je izlazna vjerojatnost manja od granične vrijednosti taj se prijenosni vod smatra isključenim. Nakon toga se dobije jedinstveni topološki vektor kojem svaki član predstavlja binarni status povezanosti prijenosnog voda i sabirnica u jednom određenom polju. Naime, ovdje nije potrebno posebno promatrati statuse prekidača ili rastavljača već samo informaciju o incidenciji pojedinog voda s pojedinim sustavom sabirnica. Stoga, konačni vektor ovako kreiranog sustava neuronskih mreža za prepoznavanje topologije sadrži binarne podatke o svakom kraju prijenosnog voda (početak ili završetak) na način da nula (0) predstavlja diskonekciju dok jedinica (1) predstavlja konekciju, odnosno povezanost određenog voda s pripadajućim sabirničkim sustavom transformatorske stanice. Ovaj topološki vektor predstavlja konačan rezultat predmetnog topološkog procesiranja obzirom da je njime matematički zapisana topologija promatranog dijela elektroenergetske mreže. Isti se u opisanom obliku koristi u procesu brze estimacije stanja.

3.2.2.1 Arhitektura sustava ANN za prepoznavanje topologije (TANN)

Za određivanje konačne topologije potrebno je uključiti informacije iz svih mjernih točaka. Nakon što se koristeći DANN dekomponiraju mjerenja iz svih točaka injekcije oni se spajaju u rezultanti vektor. Tako konstruirani vektor ima dimenziju ($N \times M$), pri čemu je N broj mjernih točaka, a M broj točaka uzorkovanja. Kako bi takav vektor bio ulaz u umjetnu neuronsku mrežu za prepoznavanje topologije (TANN) potrebno je odrediti odgovarajuću arhitekturu. Arhitektura TANN-a može sadržavati proizvoljan broj *Dense* slojeva za koje vrijede sljedeći uvjeti: ulazni vektor prvog sloja ima dimenziju ($N \times M$), a izlazni vektor posljednjeg sloja ima dimenziju koja je jednaka broju promatranih krajeva prijenosnog voda. Za aktivacijsku funkciju posljednjeg sloja potrebno je koristiti sigmoidalnu funkciju prikazanu Slikom 3.13. Naime taj oblik funkcije rabi se zbog sigurnosti da vrijednosti izlaznog vektora TANN-a budu unutar intervala $[0,1]$. Broj korištenih *Dense* slojeva, dimenzije te aktivacijske funkcije svih slojeva osim posljednjeg ovise o kompleksnosti problema (npr. slučaj mreže s puno vodova) te ih je potrebno prilagoditi na temelju iskustva. Kako bi opazili nelinearne korelacije unutar ulaznih podataka, broj korištenih slojeva mora biti veći ili jednak 2 te bar jedan sloj mora imati aktivacijsku funkciju koja je nelinearna. Na Slici 3.14 se nalazi shema arhitekture TANN-a korištena u predmetnom problemu.



Slika 3.13 Sigmoidalna funkcija korištena kao aktivacijska funkcija posljednjeg sloja



Slika 3.14 Arhitektura TANN-a

3.2.2.2 Proces učenja TANN-a

Kako bi izvršili proces učenja potrebno je konstruirati bazu podataka koja bi uz izmjerene ili simulirane signale sadržavala i odgovarajuće topologije. Iz poznatih topologija mogu se konstruirati vektori koji predstavljaju vjerojatnosti da je pojedini kraj prijenosnog voda uključen za određeni ulazni vektor. Kako navedene topologije predstavljaju istinu, vjerojatnosti se mogu postaviti na 1 u slučaju da je prijenosni vod uključen ili 0 u suprotnom. S obzirom da izlazni vektori TANN-a također predstavljaju vjerojatnosti kao *error* funkcija za proces učenja koristi se *binary cross-entropy* (3.17).

U procesu učenja potrebna je baza podataka koja može biti konstruirana na stvarnim izmjerenim podacima ili simuliranim podacima. Stvarne izmjerene vrijednosti dobivaju se na način da se u optimalno odabranim točkama elektroenergetskog sustava utiskuju testni signali i očitavaju njihove refleksije, a poznavajući topologiju sustava u svakom trenutku moguće je konstruirati relacijsku bazu podataka za učenje predstavljenih neuronskih mreža. Nedostatak ove metode je što je potrebno prikupiti veliki broj mjerenja na različitim topologijama što je često dugotrajan proces. Alternativni način je izrada verificiranog modela mreže u nekom od komercijalnih programskih alata kao što je EMTP (*eng. ElectroMagnetic Transient Program*). Pomoću verificiranog modela elektroenergetske mreže potrebno je izvesti dovoljan broj simulacija kako bi se stvorila baza podataka za učenje. Potreban broj simulacija ovisi o vrsti elektroenergetske mreže, broju optimalno odabranih točaka i funkciji testnog signala i iskustveno se određuje prema navedenim kriterijima.

3.3 Metoda određivanja optimalnih lokacija utiskivanja naponskog ispitnog signala

Zbog tehničkih ograničenja domet ispitnog testnog naponskog signala utisnut u jednom čvorištu elektroenergetskog sustava nije neograničen. Naime, zbog prigušenja signala uslijed radnog otpora dalekovoda te koeficijenata refleksije, osobito pri višestrukim refleksijama, koji u pravilu bitno umanjuju amplitudu ispitnog signala nije moguće dobiti ispravno očitavanje iz električki udaljenog mjesta. Amplituda reflektiranog testnog signala reflektiranog na električki udaljenom mjestu najčešće je toliko niskog iznosa da je pri mjerenju refleksije unutar razine slučajne mjerne pogreške. Zbog navedenih razloga uvedeno je ograničenje dometa ispitnog testnog signala koji nosi topološku informaciju na čvorište sustava u kojem se signal utiskuje i mjeri te sva njemu susjedna čvorišta. To znači da se ovom metodom, mjerenjem signala u jednom čvorištu, može dobiti topološka informacija samo u tom čvorištu i njemu susjednim čvorištima. Susjedno čvorište predstavlja ono čvorište koje s inicijalnim čvorištem dijeli jedan te isti prijenosni vod. Iz navedenog je jasno kako mora postojati više lokacija utiskivanja i mjerenja ispitnog naponskog signala kako bi za kompletni promatrani dio mreže topološka informacija mogla biti dostupna. Obzirom da je cilj ubrzati funkcije topološkog procesiranja te minimizirati trošak jednog takvog sustava, potrebno je odabrati optimalne lokacije utiskivanja i mjerenja naponskog testnog signala. Cilj je potpuna promotrivost promatranog dijela elektroenergetske mreže u smislu topološkog procesiranja uz minimalan broj lokacija utiskivanja i mjerenja naponskog ispitnog signala.

3.3.1 Optimizacijski problem

Logičan izbor pri odabiru optimizacijskog algoritma je optimizacijski koncept nazvan Problem pokrivanja (eng. *Covering problem*). Taj koncept temeljen je na pitanju pokriva li određena kombinatorna struktura drugu, odnosno, koliko velika mora biti određena struktura da bi to napravila. Problem pokrivanja je u pravilu minimizacijski problem s određenim ograničenjima [121]. Isti je definiran kao problem u kojem je za danu skupinu podskupova konačnog skupa X potrebno pronaći podskupinu s minimalnim brojem članova takvu da im je unija jednaka X [121]. Za ilustraciju navedenog može se navesti primjer: pretpostavimo osnovni skup S sa članovima $S = \{1,2,3,4,5\}$ te skupinu P sa podskupovima $P = \{\{1,2,3\}, \{2,4\}, \{4,5\}, \{1,3,4\}, \{3,5\}\}$. Potrebno je naći podskupinu koja ima minimalni broj članova, ali takvu da je njihova unija njenih podskupova jednaka osnovnom skupu. U ovom slučaju to je podskupina skupova R sa članovima: $R = \{\{1,2,3\}, \{4,5\}\}$. Važna karakteristika

koja definira kvalitetu optimizacijskog problema pokrivanja je pojam gustoće. Gustoća u problemu pokrivanja je srednji broj podskupova koji pokrivaju elemente osnovnog skupa. Po definiciji, gustoća bilo kojeg slučaja u problemu pokrivanja ne bi smjela biti manja od 1 što bi značilo da određeni dijelovi osnovnog skupa nisu pokriveni. Veća vrijednost od 1 implicira postojanje redundantnog skupa podataka odnosno slučaj u kojem su elementi osnovnog skupa pokriveni s elementima iz više podskupova. Idealan optimizacijski slučaj je kada je gustoća pokrivanja jednaka 1. Pokrivanja se nazivaju asimptotski točna ako njihova gustoća konvergira u 1 kako se dimenzija podskupa povećava.

Referirajući se na navedeno može se zaključiti da je koristeći optimizacijski koncept pokrivanja te pojma gustoće, moguće pronaći podskupinu s minimalnim brojem sabirnica za utiskivanje ispitnog testnog signala takvu da je ukupnost njihovog dometa za dobivanje topologije minimalno jednaka promatranom dijelu elektroenergetske mreže.

3.3.1.1 Metoda cjelobrojnog linearnog programiranja

Za rješavanje problema pokrivanja, ali i u ostalim optimizacijskim problemima koriste se metode linearnog programiranja. Metode linearnog programiranja odnose se na probleme u kojima se linearna funkcija cilja mora optimizirati (maksimizirati ili minimizirati) uz uvjete ili ograničenja dana u obliku jednadžbi ili/i nejednadžbi i uz nenegativne varijable odlučivanja [122]. To je formalni postupak optimizacije sustava kod kojih se funkcija cilja i ograničenja mogu izraziti linearnim kombinacijama promjenljivih veličina. Kod cjelobrojnog linearnog programiranja varijable odlučivanja su cijeli brojevi. Metoda cjelobrojnog linearnog programiranja definira oblik funkcije cilja te određena ograničenja nužna u optimizacijskom procesu [122]. Opći izraz funkcije cilja glasi (3.21):

$$\min z = \sum_{j=1}^n c(j) \cdot x(j) \quad (3.21)$$

pri čemu je z funkcija cilja, $c(j)$ trošak pojedine varijable, a $x(j)$ predstavlja varijablu odlučivanja. Cilj je minimizirati izraz (3.21) uz ograničenja navedena u (3.22 – 3.24)

$$\sum_{j=1}^n d(i, j) \cdot x(j) \geq b; D \cdot x \geq b; i = 1, \dots, m \quad (3.22)$$

$$0 \leq x(j) \leq 1 \quad (3.23)$$

$$x(j) \text{ je cijeli broj za } j = 0, 1, \dots, n \quad (3.24)$$

U (3.22) $\mathbf{D}$ je matrica gustoće, $\mathbf{x}$ varijabla odlučivanja, a $\mathbf{b}$ vektor minimalnih uvjeta. Algoritam za rješenje ovako postavljenog problema već je implementiran u mnogim matematičkim programskim paketima kao što su MATLAB, GAMS ili TOMLAB te se određenim pozivom funkcije dolazi do rješenja ovog problema.

Općenito, poznate optimizacijske metode posjeduju i poznat algoritam rješavanja iste. Najpoznatiji i najviše korišten algoritam za rješavanje problema linearnog programiranja je *simplex* algoritam, koji je 1947. godine razvio George Dantzig. *Simplex* algoritam je algebarski postupak pretraživanja ekstremnih točaka područja mogućih rješenja problema linearnog programiranja. Pri tome se redom pretražuju susjedne ekstremne točke, a kao sljedeća ekstremna točka izabire se ona koja daje jednako ili bolje rješenje nego prethodna [123].

Ovdje korištena metoda cjelobrojnog linearnog programiranja ima više poznatih algoritama za rješavanje, od kojih su najpoznatiji: linearno programiranje sa zaokruživanjem, potpuno nabiranje, djelomično nabiranje ... Najviše korištena metoda ovog tipa je metoda grananja i ograničavanja (eng. *branch and bound*), koja dijeli skup točaka u dva međusobno isključiva podskupa i zatim odlučuje koji će se od tih dvaju podskupova odbaciti, a koji će se dalje dijeliti na takva dva dijela. Ovaj se postupak nastavlja sve dok algoritam ne dođe do točke s optimalnom vrijednošću funkcije cilja, [124].

3.3.1.2 *Primjena u odabiru optimalnih lokacija utiskivanja ispitnog naponskog signala*

Pri odabiru lokacija utiskivanja ispitnog naponskog signala u promatranom dijelu elektroenergetskog sustava cilj je dobiti potpunu pokrivenost s aspekta dohvata topološke informacije iz svih čvorova sustava uz minimalni trošak investicije. Trošak investicije proporcionalan je broju lokacija utiskivanja ispitnog naponskog signala, stoga je dovoljno minimizirati samo broj predmetnih lokacija.

U svrhu što boljeg razumijevanja, u nastavku je predstavljen ilustrativni primjer. Promatrani dio elektroenergetske mreže moguće je opisati grafom. Graf je skup bridova i čvorova koji opisuju odnose između objekata gdje bridovi i čvorovi predstavljaju prijenosne vodove i pripadajuće sabirnice respektivno. Graf može biti usmjereni i neusmjereni te težinski i bestežinski. Usmjereni grafovi posjeduju barem neki jednosmjerni brid što znači da je po zamišljenom bridu moguće doći iz čvora A u čvor B, ali ne i obrnuto. U neusmjerenim


grafovima ne postoje jednosmjerni bridovi. U težinskim grafovima svaki brid ima svoju vrijednost, a u bestežinskim grafovima vrijednost svakog brida dogovorno iznosi 1. Brid koji počinje i završava u istom vrhu zove se petlja, a zatvoreni put u kojem su svi unutarnji vrhovi različiti zove se ciklus. Osnovna građevna jedinica grafa je čvor te je za svaki čvor poznat njegov ulazni i izlazni stupanj. Kod usmjerenih grafova ulazni stupanj označava broj bridova koji ulaze u čvor, a izlazni stupanj broj bridova koji izlaze iz čvora. Kod neusmjerenih grafova zbroj ulaznih stupnjeva svih čvorova jednak je zbroju izlaznih stupnjeva te iznosi dvostruki broj bridova.

Matematički zapisano, graf G je uređeni par $G = (V, E)$, gdje je $V = V(G)$ skup vrhova, $E = E(G)$ skup bridova disjunktih s V , a svaki brid $e \in E$ spaja dva vrha $(u, v) \in V$ koji se zovu krajevi od e . Kaže se da su vrhovi u i v susjedi ako su incidentni s bridom koji ih spaja. Stupanj vrha v u grafu G jednak je broju bridova koji su incidentni s vrhom v . Stupanj pojedinog vrha označava se s $\deg(v_i)$. Ako je u vrhu v petlja onda je $\deg(v) = 2$. Vrh stupnja 0 je izolirani vrh, a vrh stupnja 1 krajnji vrh. Graf je jednostavan ako su svaka dva vrha spojena s najviše jednim bridom i ako nema petlji. Jednostavan graf u kojem je svaki par vrhova spojen bridom naziva se potpunim grafom. Potpuni graf sa n vrhova označava se s K_n i ima:

$$\binom{n}{2} = \frac{n(n-1)}{2} \quad (3.25)$$

bridova, a svaki od vrhova ima $(n-1)$ susjeda.

Na slici 3.15 prikazan je grafički primjer opće mreže koji se može specijalizirati i kao primjer elektroenergetske mreže. Mreža se promatra kao neusmjereni potpuni graf u kojem su prijenosni vodovi bridovi, a sabirnice čvorovi. Praktično je označiti čvorove brojem od 1 do n .



Slika 3.15 Ilustrativan primjer grafa

Kao što je navedeno, stupnjevi čvorova odgovaraju broju bridova spojenih s istima, odnosno broju prijenosnih vodova spojenih sa sabirnicama elektroenergetskog sustava. Stupanj vrha može se označiti s a_i . Kako bi slikovito bio prezentiran optimizacijski proces, definira se termin bojanja. Pretpostavka je da su na početku svi bridovi bijeli. Odabirom jednog čvora bridovi incidentni s njim bojaju se u crno. Višestruki izbor jednog te istog čvora ne utječe na daljnje bojanje. Jednom obojan pojedini čvor ili brid ponovnim izborom ne vraća boju natrag, odnosno, brid jednom izabran i obojan u crno ne može promijeniti boju natrag u bijelo. Dakle, problem optimizacije broja mjesta injekcije i detekcije ispitnog testnog signala potrebnih za potpunu definiciju topologije elektroenergetske mreže jednak je minimizaciji broja čvorova potrebnih da se kompletan graf iz bijelog oboji u crno.

Primjenjujući metodu cjelobrojnog linearnog programiranja moguće je riješiti navedeni optimizacijski problem. Ishodišna točka rješavanja navedenog problema je definicija funkcije cilja. Promatrajući ilustrirajući primjer cilj je uključiti, odnosno odabrati, najmanji broj čvorova kako bi cijeli graf bio obojan. Povezano na temu, potrebno je odabrati najmanji broj sabirnica utiskivanja i detekcije ispitnog signala, a da bi elektroenergetska mreža u potpunosti bila topološki promotriva. Matematički zapisano potrebno je riješiti problem (3.26):

$$\min_n \left(\sum_{j=1}^n x_j \right). \quad (3.26)$$

pri čemu x_j predstavlja j-ti čvor grafa i može poprimiti samo binarne vrijednosti 0 ili 1. $x_j = 0$ ako čvor nije odabran, a $x_j = 1$ ako jest odabran. Konkretno, ako na sabirnicama određenog čvora postoji sklop za utiskivanje i detekciju ispitnog onda taj čvor smatramo odabranim. Vrijedi napomenuti da je $x_j = 1$ bez obzira koliko je puta čvor odabran.

Svaki optimizacijski problem mora imati određene optimizacijske kriterije za ispunjavanje funkcije cilja, odnosno određene uvjete uz određena ograničenja. Obzirom da je algoritam cjelobrojnog linearnog programiranja već predefiniran i postoji kao MATLAB funkcija *intlinprog* predmetni problem potrebno je svesti u format predefinirane funkcije. Algoritam u MATLAB-u *intlinprog* $x = \text{intlinprog}(f, \text{intcon}, A, b, Aeq, beq, lb, ub)$ rješava sljedeći problem [125]:

$$\min(f^T X) \quad (3.27)$$

takav da je

$$A\dot{X} \leq b. \quad (3.28)$$

Uz navedene, moguće je definirati i dodatne tj. prisilne uvjete:

$$A_{eq}\dot{X} = b_{eq} \quad (3.29)$$

Ukoliko dodatni uvjeti ne postoje, tada se jednostavno definira $A_{eq} = 0$ i $b_{eq} = 0$. lb i ub su granične vrijednosti za x tj $[lb_i, ub_i]$ je interval u kojem se x_i nalazi. Funkcija *intcon* detektira cjelobrojne članove x_i vektora x . S obzirom da varijabla u konkretnom problemu sadrži isključivo cijele brojeve funkciju *intcon* definiramo kao:

$$intcon = 1 : N \quad (3.30)$$

a granične vrijednosti lb i ub kao n -dimenzionalne vektore u kojima su svi članovi lb vektora jednaki 0, a svi članovi ub vektora jednaki 1. Ovime smo također ograničili varijablu x_i na cijeli broj u intervalu $[0, 1]$, odnosno varijabla x_i je binarna varijabla koja može biti ili 0 ili 1. Ukoliko postoje dodatni uvjeti tj. određeni prisilni uvjeti definiraju se vektorskim prostorom A_{eq} i b_{eq} . Ukoliko nema prisilnih uvjeta, kod postavki optimizacijskog problema tada se svi članovi navedenog vektorskog prostora postavljaju na 0. Međutim, ukoliko u navedenom ilustrativnom primjeru postoji potreba da je određeni čvor i nužno odabran tada je u matrici A_{eq} , član $A_{eq_{i,i}} = 1$ te u vektoru $b_{eq_i} = 1$ te u suprotnom, a ako je nužno ne odabran tada spomenuti članovi poprimaju vrijednost 0.

Najveći izazov o kojem bitno ovisi optimizacijski rezultat je definirati matricu gustoće te vektor minimalnih uvjeta tj. matricu A i vektor b u izrazu (3.28). Matrica gustoće, odnosno matrica A definira se kao $n \times n$ matrica (n je jednak broju članova), a predstavlja fizikalna ograničenja zapisana u matričnom obliku. Naime, kako je već ranije spomenuto, iz jedne injekcijske sabirnice moguće je dobiti samo topološko stanje u toj sabirnici i na svim susjednim sabirnicama. Matematički zapis tog ograničenja definira matricu A i u ovom slučaju zove se izmijenjena matrica susjedstva. Ukoliko su čvorovi međusobno povezani pojedini član matrice A za $i \neq j$ iznosi $A_{i,j} = 1$, a ukoliko čvor i nije povezan s čvorom j za $i \neq j$ iznosi $A_{i,j} = 0$. Matrični dijagonalni elementi iznose $A_{i,i} = deg(i)$ tj. dijagonalni element i,i matrice A odgovara stupnju čvora i odnosno broju bridova incidentnih s tim čvorom. Vektor b predstavlja vektor minimalnog uvjeta što u ovom slučaju fizikalno predstavlja uvjet da su svi bridovi

obojani u crno s minimalnim odabirom čvorova. Promotri li se navedeni primjer iz jednog vrha, svi njemu incidentni bridovi biti će obojani ukoliko je on odabran, ali ukoliko on nije odabran tada svi njegovi susjedi moraju biti odabrani da bi svi međusobni bridovi bili pokriveni. Naravno pretpostavka je da između čvorova postoji samo jedan brid. Iz navedenog proizlazi da pojedini članovi vektora $\mathbf{b}$ sadržavaju stupanj pojedinog čvora tj. $b_i = A_{i,i} = \deg(i)$. Izrazi (3.31) i (3.32) predstavljaju matricu ograničenja $\mathbf{A}$ i vektor uvjeta $\mathbf{b}$ za graf iz ilustrativnog primjera sa slike 3.15.

$$\mathbf{A} = \begin{bmatrix} 2 & 1 & 0 & 0 & 1 & 0 \\ 1 & 3 & 1 & 0 & 1 & 0 \\ 0 & 1 & 2 & 1 & 0 & 0 \\ 0 & 0 & 1 & 3 & 1 & 1 \\ 1 & 1 & 0 & 1 & 3 & 0 \\ 0 & 0 & 0 & 1 & 0 & 1 \end{bmatrix} \quad (3.31)$$

$$\mathbf{b} = \begin{bmatrix} 2 \\ 3 \\ 2 \\ 3 \\ 3 \\ 1 \end{bmatrix} \quad (3.32)$$

Kako bi cijela mreža bila topološki promotriva mora biti zadovoljen uvjet (3.33):

$$A\mathbf{x} \geq \mathbf{b} \quad (3.33)$$

Obzirom da metoda cjelobrojnog linearnog programiranja kao i MATLAB-ova funkcija *intlinprog* definira uvjet prema (3.28) potrebno je izraz (3.33) pomnožiti s (-1). Nakon množenja dobiva se konačan izraz za uvjet (3.34), čime se pozvanom funkcijom $x = \text{intlinprog}(f, \text{intcon}, A, b, Aeq, beq, lb, ub)$ dobiva vektor $\mathbf{x}$ kao optimizacijska varijabla odnosno vektor egzistencije sklopa za utiskivanje i mjerenje ispitnog testnog signala u pojedinoj sabirnici.

$$-A\mathbf{x} \leq -\mathbf{b} \quad (3.34)$$

Na ilustrativnom primjeru, nakon provedenog postupka optimizacije za varijablu $\mathbf{x}$ dobiva se rezultat: $\mathbf{x} = [1, 1, 0, 1, 0, 0]$. Prema tome, da bi ilustrativna mreža na slici 3.15 bila u potpunosti topološki pokrivena potrebno je za utiskivanje i mjerenje ispitnog signala odabrati

čvorove 1, 2 i 4. Naravno, ovo nije jednoznačan primjer obzirom da je, bez utjecaja na konačan rezultat, bilo moguće odabrati i čvor 5 umjesto 1. Ukoliko se želi fiksirati određeni čvor na način da mora u optimizacijskom procesu biti izabran, tada je potrebno koristiti operatore *Aeq* i *beq* definirane kao argumenti *intlinprog* funkcije.

3.3.2 Analiza topološke promotrivosti sustava

Sustav će biti topološki potpuno promotriv ukoliko je zamišljeno bojanje uspješno zahvatilo kompletan sustav tj. ukoliko je svaki brid i čvor promijenio inicijalnu boju. Međutim, rezultat bojanja ovisi o trenutnom topološkom stanju budući da algoritam funkcionira na način da informaciju o topološkom stanju susjednog čvora dobiva preko njihovog međusobnog spojnog voda. Ako je taj vod isključen tada ispitni naponski signal ne može biti odaslan prema susjednom čvoru, a time niti topološka informacija ne može biti primljena natrag. Kod analize topološke promotrivosti sustava potrebno je razlikovati dvije osnovne situacije:

- i. čvor posjeduje sklop za utiskivanje i mjerenje ispitnog signala,
- ii. čvor ne posjeduje sklop za utiskivanje i mjerenje ispitnog signala.

Ukoliko čvor posjeduje sklop za utiskivanje i mjerenje signala, njegovo topološko stanje potpuno je promotrivo. Drugim riječima, topologija tog čvora potpuno je poznata za bilo koje uklopno stanje na krajevima vodova incidentnih s njim. Bitno je naglasiti da je uklopno stanje udaljenijeg kraja incidentnog prijenosnog voda poznato samo ukoliko je njegov početak uklopljen u čvoru koji posjeduje predmetni sklop. Moguća je i situacija da se vod nalazi između dva čvora koja oba posjeduju sklop za utiskivanje i mjerenje ispitnog signala i u tom slučaju poznato je uklopno stanje tog voda u bilo kojoj mogućoj kombinaciji.

Topološko stanje u čvoru koji ne posjeduje sklop za utiskivanje i mjerenje ispitnog naponskog signala mora biti moguće promotriti iz susjednih čvorova koji isti imaju. Optimizacijski je uvjet da jedan od dva ili više susjednih čvorova ima predmetni sklop, čime će minimalno jedan susjedni čvor imati tu mogućnost. Problem se javlja onda kada je prijenosni vod koji povezuje čvor koji posjeduje sklop za utiskivanje i mjerenje ispitnog naponskog signala i onaj koji ga ne posjeduje isključen na kraju bližem čvoru koji ga posjeduje, a isto se ponovi i sa potencijalno svim susjednim čvorovima u istoj situaciji, tada lokalnu topologiju tog čvora nije moguće dobiti ovdje opisanim načinom. Takvu topološku situaciju moguće je promotriti kao izolirani dio mreže odnosno izolirani otok.

3.3.3 Analiza mogućnosti pojave izdvojenih otoka i neenergiziranih sabirnica

Izolirani otoci u elektroenergetskom sustavu mogu se podijeliti na otoke po fizičkom kriteriju i otoke prema kriteriju promotrivosti. Fizičkim otokom naziva se dio elektroenergetske mreže koji sadržava čvorove s incidentnim prijenosnim vodovima gdje čvorovi mogu sadržavati transformatore, kondenzatorske baterije i ostale elemente mreže, a takva cjelina fizički je odvojena od ostatka mreže. Otok može biti energiziran ili neenergiziran. Energizirani otok je onaj otok koji posjeduje proizvodne elemente u određenom stabilnom režimu rada, a neenergizirani otok je izolirani dio elektroenergetske mreže bez vlastitog izvora napona odnosno bez mogućnosti energizacije čvora i njemu incidentnih dijelova. Otokom po kriteriju promotrivosti može se nazvati dio mreže gdje se svi potrebni parametri mogu dobiti iz vlastitog mjerenja bez potrebe za bilo kakvom ulaznom vrijednosti iz ostatka mreže.

Obzirom na optimizacijske kriterije koji definiraju domet jednog odabranog čvora za utiskivanje i mjerenje ispitnog naponskog signala samo na susjedne čvorove te kriterije potpunog pokrivanja može se zaključiti da je moguć slučaj fizičkog otoka koji neće imati mogućnost promotrivosti lokalne topologije. Takvo stanje moguće je samo i isključivo u jednom promatranom čvoru te samo i isključivo ako ne posjeduje sklop za utiskivanje i mjerenje ispitnog naponskog signala. U navedenom slučaju bitno je sagledati dvije osnovne varijante:

- i. čvor se nalazi u energiziranom otoku,
- ii. čvor se nalazi u neenergiziranom otoku.

Ukoliko se pojedini čvor nalazi u otočnom pogonu te ni u kojem slučaju ne može doći u energizirano stanje, taj čvor se proglašava neenergiziranim tj. njegove sabirnice nalaze se u beznaponskom stanju. Tada se sa stajališta estimacije stanja može zaključiti da ne postoje tokovi snaga povezani s tim izoliranim dijelom mreže, a apsolutna vrijednost napona na istom jednaka je nuli.

Ukoliko se pojedini čvor nalazi u otočnom pogonu te može doći u energizirano stanje, tj. sadrži izvor napona, u optimizacijskom procesu potrebno je definirati prisilni uvjet za egzistenciju sklopa za utiskivanje i mjerenje ispitnog naponskog signala. Prema navedenom, svi čvorovi u promatranom dijelu EES-a koji posjeduju izvore napona (generatore, transformatore s višeg naponskog nivoa ili distribuirane izvore na nižem naponu) moraju posjedovati ugrađene sklopove za utiskivanje i mjerenje ispitnog naponskog signala kako bi bili promotrivi u slučaju energiziranog otočnog pogona. Navedeni prisilni uvjeti definiraju se vektorskim prostorima $\mathbf{A}_{eq}$ i $\mathbf{b}_{eq}$ u *intlinprog* funkciji.

4 REZULTATI ISTRAŽIVANJA

Opisani algoritam za utvrđivanje topologije elektroenergetske mreže na temelju putujućih valova validiran je na modelu elektroenergetske mreže opisanom u nastavku. Razlog korištenja modela mreže u odnosu na eksperiment u realnom sustavu je mogućnost provedbe višestrukih simulacija s različitim topološkim stanjima kako bi mogla biti stvorena odgovarajuća baza podataka nužna za proces učenja sustava neuronskih mreža. Također, prednost verifikacije na modelu je mogućnost ispitivanja algoritma u rubnim slučajevima tj. na topologijama koji u realnom elektroenergetskom sustavu nisu operativno dozvoljeni. Valja napomenuti da model korišten za validaciju predloženog algoritma nije potpuni model stvarne mreže već je pojednostavljen na način da su u istom korištene komponente sustava koje imaju bitan utjecaj na transmisiju i refleksiju kao i na propagaciju putnih valova općenito. Broj elemenata elektroenergetske mreže u modelu reduciran je na način da su elementi jednakih parametara koji mogu biti u paralelnom spoju sublimirani i prikazani kao jedan element. Pojednostavljeno, dva paralelna prijenosna voda ili transformatora prikazani su kao jedan iz razloga što za estimaciju stanja nije važno koji je od dvaju prijenosnih vodova u paralelnom spoju uključen a koji isključen jer su iznosi i kutovi napona na njegovom kraju u oba slučaja jednaki. Predmetno istraživanje pokazalo je kako je opisanom metodom moguće dobiti topologiju elektroenergetske mreže s vrlo visokom efikasnosti što će biti i prikazano u ovom poglavlju.

4.1 Model elektroenergetske mreže

Model korišten za validaciju opisane metode pojednostavljeni je model dijela mreže hrvatskog elektroenergetskog sustava s realnim parametrima i prilagođenim vrijednostima duljine vodova. Predmetni dio elektroenergetskog sustava modeliran je u EMTP programu (ElectroMagnetic Transient Program) za izučavanje prijelaznih pojava. Korišteni model dijela elektroenergetske mreže prikazan je slikom 4.1. Parametri elemenata dijela elektroenergetskog sustava korišteni u modelu prikazani su tablicom I. Model se sastoji od 11 čvorišta povezanih sa 15 prijenosnih vodova iste naponske razine. Predložena metoda ne razmatra propagaciju ispitnog naponskog signala kroz više naponskih razina već se predviđa da svaka naponska razina posjeduje zaseban sustav koji koristi predloženu metodu. Parametri prikazani u tablici I. odnose se na parametre pri nazivnoj frekvenciji 50 Hz.


Tablica I Parametri prijenosnih vodova korišteni u modelu

	R [Ω/km]	L [mH/km]	G [S/km]	C [μF/km]	R₀ [Ω/km]	L₀ [mH/km]	G₀ [S/km]	C₀ [μF/km]	l [km]
I	0.120	1.305071	0	0.008626	0.384	3.915212	0	0.005825	55
II	0.120	1.336902	0	0.008658	0.384	3.915212	0	0.005793	70
III	0.120	1.336902	0	0.008658	0.379	3.908845	0	0.005793	45
IV	0.120	1.336902	0	0.008658	0.387	3.908845	0	0.005761	50
V	0.120	1.336902	0	0.008626	0.379	3.908845	0	0.005761	60
VI	0.192	1.336902	0	0.008594	0.442	4.010705	0	0.005793	65
VII	0.191	1.336902	0	0.008658	0.439	4.010705	0	0.005634	90
VIII	0.140	1.336902	0	0.008658	0.384	4.010705	0	0.005634	95
IX	0.120	1.336902	0	0.008626	0.384	3.880198	0	0.005825	40
X	0.190	1.336902	0	0.008626	0.437	4.010705	0	0.005825	80
XI	0.119	1.305071	0	0.008626	0.381	3.915212	0	0.005857	30
XII	0.119	1.305071	0	0.008626	0.381	3.915212	0	0.005857	35
XIII	0.119	1.305071	0	0.008626	0.381	3.915212	0	0.005857	75
XIV	0.120	1.336902	0	0.008945	0.384	3.972507	0	0.005825	85
XV	0.120	1.336902	0	0.008626	0.384	3.877014	0	0.005825	100

Svaki element mreže s koncentriranim parametrima, kao transformator ili generator, sa stajališta rasprostiranja, refleksije i transmisije putnih valova moguće je modelirati njegovom karakterističnom impedancijom. Karakteristična impedancija transformatora ima fizikalnu veličinu radnog otpora i izračunava se prema izrazu (2.27) iz poglavlja 2.3.1.1. Prema navedenom tipična vrijednost karakteristične impedancije za niskonaponski namot distribucijskog transformatora 500 kVA je oko 600 Ω , a visokonaponskog namota oko 5000 Ω . Za 50 MVA transformator tipične su vrijednosti oko 100 Ω za niženaponski te oko 1000 Ω za višenaponski namot. Vrijednosti nazivne snage transformatora između prijenosne 110 kV mreže i distribucijske mreže u hrvatskom EES-u najčešće su između 20 MVA i 60 MVA. Za potrebe konkretnog modela mreže prikazani transformatori modelirani su u obliku radnog otpora voda s vrijednostima prikazanim u tablici II. Potrebno je reći da su nedostupni potrebni podaci za precizno modeliranje svakog pojedinog transformatora, ali smatra se dovoljno dobrim za dokaz ovdje predložene metode da se transformatori modeliraju aproksimativnom vrijednošću iz gore navedenog raspona. Obzirom da su za potrebe izrade modela prijenosnih vodova uzete vrijednosti iz 110 kV mreže, za potrebe modeliranja transformatora kao referentna vrijednost uzeta je aproksimativna vrijednost karakteristične impedancije za višenaponski namot transformatora od 50 MVA, a kao najmanja uzeta je vrijednost od 800 Ω za 15 MVA transformator uz linearnu distribuciju međuvrijednosti.

Tablica II Karakteristične impedancije transformatora u modelu

Transformator	Snaga [MVA]	$Z_{TR}[\Omega]$
TR_MR	60	1057
TR_LU	15	800
TR_KT	40	943
TR_SI	20	829
TR_PR	20	829
TR_RA	60	1057
TR_TES	32	897
TR_ME	60	1057
TR_GL	20	829
TR_PT	40	943
TR_ZE	40	943



Slika 4.1 Model mreže za validaciju metode

Prema algoritmu toka predložene metode opisanom u poglavlju 3.1.1. te koristeći metodu opisanu poglavljem 3.3 prvi korak je određivanje optimalnog broja i pozicije utiskivanja i mjerenja ispitnog naponskog signala u ovdje prikazanom modelu mreže.

4.1.1 Pozicije utiskivanja i mjerenja ispitnog naponskog signala

Za određivanje pozicija utiskivanja i mjerenja ispitnog naponskog signala korištena je metoda cjelobrojnog linearnog programiranja opisana poglavljem 3.3., a za rješavanje optimizacijskog problema *intlinprog* funkcija u MATLAB-u. Optimizacijskim postupkom potrebno je minimizirati broj sabirnica utiskivanja i mjerenja ispitnog naponskog signala uz uvjet da svaki čvor sustava bude topološki promotriv. Sabirnica TES u prikazanom modelu mreže posjeduje generatorske jedinice potencijalno i može se naći u energiziranom otoku stoga je potrebno definirati prisilne uvjete $\mathbf{A}_{eq_top}$ i $\mathbf{b}_{eq_top}$ kako je opisano u potpoglavlju 3.3.3. Prisilnim uvjetima definirana je nužnost postojanja uređaja za utiskivanje i mjerenje ispitnog naponskog signala u odabranom čvoru. Svim sabirnicama pridijeljene su broježane oznake koje odgovaraju matričnim pozicijama u optimizacijskom algoritmu.

Prisilni uvjeti za prikazani model mreže $\mathbf{A}_{eq_top}$ i $\mathbf{b}_{eq_top}$ dani su izrazom (4.1), a matrica gustoće $\mathbf{A}_{top}$ za prikazani primjer korištena u *intlinprog* funkciji izrazom (4.2).

$$\mathbf{A}_{eq_top} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad \mathbf{b}_{eq_top} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (4.1)$$

$$\mathbf{A}_{top} = \begin{bmatrix} 3 & 1 & 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 2 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 3 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 2 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 2 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 6 & 1 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 & 2 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 1 & 1 & 5 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 1 & 2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 & 2 \end{bmatrix} \quad (4.2)$$

Vektor minimalnih uvjeta $\mathbf{b}_{top}$ za model korišten u ovom primjeru dan je izrazom (4.3) i kako je pojašnjeno u potpoglavlju 3.3.3 njegovi članovi jednaki su stupnju pripadajućeg čvora.

$$\mathbf{b}_{eq} = \begin{bmatrix} 3 \\ 2 \\ 3 \\ 2 \\ 2 \\ 2 \\ 6 \\ 2 \\ 5 \\ 1 \\ 2 \\ 2 \end{bmatrix} \quad (4.3)$$

Nakon što su svi uvjeti definirani i postavljena matrica gustoće moguće je pokrenuti *intlinprog* funkciju u MATLAB-u. *Intlinprog* funkcija kao rezultat vraća vektor s minimalnim

brojem članova gdje pozicija svakog člana dobivenog vektora odgovara poziciji sustava za utiskivanje i mjerenje ispitnog naponskog signala. Rezultat optimizacijskog postupka za predmetni primjer modela mreže je vektor $\mathbf{X}_{top}$ i dan je izrazom (4.4).

$$\mathbf{X}_{top} = [1 \ 0 \ 1 \ 0 \ 0 \ 1 \ 0 \ 1 \ 0 \ 1 \ 0]^T \quad (4.4)$$

Iz dobivenog rezultata vidljivo je da je za promatrani dio mreže sa slike 4.1 dovoljno odabrati 5 pozicija utiskivanja i mjerenja ispitnog naponskog signala kako bi cjelokupna mreža iz prikazanog modela bila topološki promotriva predmetnom metodom. Članovi vektora $\mathbf{X}_{top}$ s vrijednosti 1 odgovaraju tim sabirnicama i one su prema oznakama sa slike 4.1 redom: MR, KT, PR, TES i PT. Valja dodatno napomenuti da ovo nije jednoznačno rješenje te je moguće postojanje više jednakovrijednih rješenja gdje je potpuno proizvoljan izbor jednog od njih.

4.1.2 Ispitni naponski signal

U navedenim točkama na modelu mreže injektira se ispitni testni signal određene funkcije, amplitude i trajanja. Kao ispitni naponski signal u predmetnom modelu koristi se simetrični trofazni naponski signal amplitude $A_{test} = 1000 \text{ V}$, trajanja $d_{test} = 50 \mu\text{s}$ sinusne funkcije $u(t) = A_{test} \sin(2\pi \frac{1}{2d_{test}} t)$. U svim točkama modela ispitni signal injektira se istovremeno, odnosno međusobno sinkrono, a mjerni uređaji instalirani su u istim točkama u kojima se i utiskuje ispitni naponski signal. Samim time, osim signala utisnutog od strane uređaja instaliranog na istoj sabirnici, svaki pojedini mjerni uređaj mjeri signal odaslan i transmitiran sa neke od preostalih sabirnica u kojima se utiskuje signal. Robusnost procesa učenja sustava neuronskih mreža omogućava da međusobna interferencija lokacijski različito odaslanih ispitnih naponskih signala uz uvjet sinkronosti ne utječe negativno na konačan ishod procesa učenja. Oblik i trajanje ispitnog naponskog signala odabrani su na način da se uvažavaju ograničenja navedena u potpoglavlju 3.1.2. tj. da je trajanje ispitnog signala toliko da refleksija s kraja najkraćeg voda u promatranom dijelu sustava ne interferira u nijednoj točki s krajem inicijalno utisnutog signala.

Mjerenje, odnosno rezultat simulacijskog postupka u ovom slučaju izvodi se u vremenskom rasponu od 2 ms od početka utiskivanja ispitnog naponskog signala. Naime to je potrebno vrijeme, obzirom na brzinu širenja vala i duljine vodova u modelu, da se u početnoj točki izmjeri refleksija od najudaljenije sabirnice u promatranom dijelu sustava. Uzorkovanje pri mjerenju signala provedeno je frekvencijom od 2000 kHz odnosno period svakog pojedinog

uzorka je $0.5 \mu\text{s}$. Obzirom na gore navedeni vremenski period trajanja signala, ulazni vektor sa svake mjerne točke u sustav neuronskih mreža u ovom slučaju ima 2500 članova odnosno dimenziju 2500×1 . To znači da u ovom slučaju ukupan ulaz u sustav neuronskih mreža čini 5 sublimiranih vektora dimenzija 2500×1 , svaki sa pripadajuće optimalno odabrane mjerne točke.

4.2 Rezultati prepoznavanja topologije na modelu elektroenergetske mreže


U svrhu dokazivanja hipoteze istraživanja prikazani su rezultati dobiveni simulacijama na modelu mreže. Model mreže napravljen je u programskom alatu EMTP u kojem su i izvedene simulacije. Predmetne neuronske mreže izrađene su u programskom jeziku Python, TensorFlow korištenjem Keras biblioteke. Nakon izvedenih simulacija u EMTP, dobiveni rezultati izvoze se u *.txt* formatu i koriste se kao ulazni podaci za učenje, validaciju i testiranje neuronskih mreža za prepoznavanje točne topologije sustava.

4.2.1 Simulacije uklopnih stanja


Model mreže sa slike 4.1 izrađen je u programskom paketu EMTP i prikazan je slikom 4.2. Generatori ispitnog signala modelirani su simetričnim trofaznim generatorom i optimalno pozicionirani prema postupku opisanom u prethodnom poglavlju. Mjerna mjesta reflektiranih signala modelirana su *scope* funkcijom i pozicionirana na identične sabirnice kao i generatori signala. Svako mjerenje signala obavljeno je u vremenskom rasponu od 2 ms, odnosno u najduljem vremenskom intervalu potrebnom za refleksiju od najudaljenije sabirnice. Algoritmi za proračun širenja i refleksije elektromagnetnog vala u EMTP programu zasnovani su na kombinaciji dviju iterativnih integracijskih metoda za rješavanje običnih diferencijalnih jednačbi: *Trapezoidal* i *Backward Euler*. *Trapezoidal* metoda koristi se za rješavanje diferencijalnih jednačbi na gotovo cijelom području signala, a na *Backward Euler* metodu program se automatski prebacuje isključivo na područjima signalnog diskontinuiteta [126]. Integracijski korak je programibilan, ali jednom podešen postaje fiksna. Integracijski korak izabran je u skladu s najvećom frekvencijom u simulaciji i 100 puta je manji od perioda utisnutog signala te ovdje iznosi $0,5 \mu\text{s}$.

Za potrebe testiranja opisane metode napravljene su simulacije na 500 različitih topoloških stanja. Od toga, 400 simulacija korišteno je za potrebe učenja neuronskih mreža, a 100 simulacija korišteno je za validaciju i testiranje predložene metode. Topološka stanja za učenje te za testiranje i validaciju izabrana su i simulirana potpuno slučajno ne uvažavajući pri tom eventualnu potrebnost ili tehničku opravdanost pojedinog stanja. Na primjer: na prikazanom modelu moguće je da je za potrebe učenja ili validacije odabran slučaj sa samo jednim jedinim uključenim vodom što jest teoretski slučaj, ali u stvarnosti isti je neostvariv.


U nastavku su prikazane slike dobivenih rezultata na četiri različita primjera. Slike prikazuju reflektirani signal izmjeren u naznačenim točkama mjerenja preklopljen sa funkcijom rekonstruiranom prema metodi opisanoj u prethodnim poglavljima. Izmjereni signal predstavlja superpoziciju svih reflektiranih signala u modelu. Što je više superpozicija, odnosno što je više lokalnih maksimuma to predstavlja veću vjerojatnost da je više prijenosnih vodova priključeno na sabirnice. U drugom dijelu slike prikazan je vektor koji predstavlja amplitudu svake pojedine refleksije u superponiranom reflektiranom signalu. Taj vektor predstavlja rezultat procesiranja DANN neuronske mreže i prikazan je u obliku diskretne funkcije. Za primijetiti je kako je pojedini lokalni maksimum u diskretnom dijelu prikazan s dvije vrijednosti što implicira postojanje dvije bliske refleksije. Ovo je jedan od važnijih doprinosa ovog istraživanja jer bez dekompozicije izmjerenog signala ne bi bilo moguće razlučiti koliko je refleksija sadržano u pojedinom lokalnom ekstremu funkcije izmjerenog signala. Zbog razlučivosti prikaza, rezultati su prikazani samo u frekvencijskom spektru testnog signala dok je osnovni signal izuzet. Slike 4.3. – 4.6. prikazuju opisane signale izmjerene na mjernom mjestu MR (slika 4.3 i 4.5.) i PR (slika 4.4. i 4.6) testne mreže, a svaka slika pokazuje različito topološko stanje. Vidljivo je da je za različito topološko stanje izmjeren različit reflektirani signal, a samim time različit i DPV vektor. Slike 4.3 i 4.4 prikazuju reflektirani signal izmjeren u dvije različite točke sa samo jednim isključenim vodom u prvom slučaju te s dva isključena voda u drugom slučaju. Slike 4.5 i 4.6 prikazuju granične slučajeve gdje je od cijele testne mreže uključen samo jedan vod (slika 4.5) i uključena tri voda (slika 4.6). Topološko stanje dobiva se procesiranjem DPV vektora u TANN dijelu sustava neuronske mreže, a rezultati su prikazani u nastavku.




Slika 4.3 Reflektirani i rekonstruirani signal sa dekomponiranim vektorom - 1



Slika 4.4 Reflektirani i rekonstruirani signal sa dekomponiranim vektorom - 2




Slika 4.5 Reflektirani i rekonstruirani signal sa dekomponiranim vektorom - 3



Slika 4.6 Reflektirani i rekonstruirani signal sa dekomponiranim vektorom – 4

Signal prikazan plavom bojom izmjereni je signal u naznačenoj mjernoj točki. Narančasti signal u gornjem dijelu slike predstavlja rekonstruirani signal potreban za učenje DANN sustava neuronskih mreža kako je opisano u prethodnim poglavljima. Razlika između ovih dvaju signala u apsolutnom iznosu može se tumačiti i kao efikasnost DANN sustava za dekompoziciju izmjerenog signala. Logično, što je veća razina poklapanja ovih dvaju signala to je veća vjerojatnost da će sustav neuronskih mreža kao rezultat vratiti točnu topološku strukturu. U nastavku je prikazana slika 4.7 koja prikazuje primjer izmjerenog i rekonstruiranog signala kod mjesta gdje je sustav za dekompoziciju signala pogrešno dekomponirao signal pri čemu je došlo do netočnog prikaza topološkog stanja.




Slika 4.7 Reflektirani i rekonstruirani signal – pogreška

Iz slike 4.7 može se primijetiti ne-poklapanje izmjerenog/simuliranog signala s rekonstruiranim signalom na oko 1 ms od početka signala. Na predmetnom mjestu nije ispravno dekomponiran signal što je nužno dovelo do pogrešne topološke interpretacije kod TANN dijela sustava neuronskih mreža.

4.2.2 Obilježja DANN sustava neuronskih mreža

Broj svih mogućih topoloških stanja na određenom dijelu mreže vrlo je velik. Prema ovdje predloženoj metodi svaki pojedini kraj prijenosnog voda može biti u binarnom stanju (0 – vod nije priključen na sabirnice ili 1 – vod priključen na sabirnice) što daje konačni broj 2^{2n} stanja gdje je n ukupan broj prijenosnih vodova s početkom i krajem. U konkretnom slučaju, za mrežu od 15 prijenosnih vodova, broj mogućih topoloških stanja iznosi $2^{2 \times 15}$ odnosno 1.073.741.824 stanja. To je vrlo velik broj čak i za ovakav mali dio prijenosne mreže i bilo bi nužno napraviti velik broj simulacija potrebnih za učenje sustava neuronskih mreža. Zbog toga je dekompozicija ulaznog signala u DANN sustavu vrlo bitna jer unatoč tome što nije smanjen broj mogućih topoloških stanja povećana je razlučivost u odlučivanju. Time je i bitno smanjen broj potrebnih simulacija u procesu učenja neuronskih mreža i to je jedan od važnijih doprinosa ovog istraživanja.


Obilježja DANN sustava neuronskih mreža u procesu učenja ovise o količini ulaznih podataka jer veća količina podataka za učenje rezultira većom efikasnosti DANN sustava. Efikasnost DANN sustava može se prikazati preko Loss-funkcije definirane s (3.20). Loss-funkcija u suštini daje razliku između stvarnog ulaznog vektora i onog rekonstruiranog, a cjelokupnom procesu učenja cilj je minimizirati navedenu funkciju. Na slici 4.8 prikazan je graf s Loss-funkcijom (L) u ovisnosti o količini podataka za učenje.



Slika 4.8 Trend Loss-funkcije

U ovom slučaju manje je važan apsolutni iznos Loss-funkcije prikazan na grafu zbog tog što je ona po prirodi relativna funkcija; stoga nam navedeni iznos ne daje relevantnu informaciju. Ono što je važno to je trend smanjenja Loss funkcije kako raste broj podataka za učenje. Inače, za učenje DANN sustava korišteno je $5 \times N$ topologija, zbog toga što na predmetnom dijelu mreže ima 5 mjesta utiskivanja i očitavanja testnog signala. Loss-funkcija izračunata je iz 100 topologija (također 5×100 slika) koje nisu korištene u procesu učenja.

Također, efikasnost Loss-funkcije ovisna je o iteraciji u procesu učenja. Slika 4.9 prikazuje graf ovisnosti efikasnosti Loss-funkcije o iteraciji u opisanom iterativnom postupku.



Slika 4.9 Loss funkcija u ovisnosti u epohi učenja

Na grafu sa slike 4.9 vidljivo je da trend Loss-funkcije ima padajući karakter, odnosno da funkcija prikazana izrazom (3.20) koja čini razliku između rekonstruiranih i mjerenih veličina opada i u vrijednosti i u pogrešci kako raste broj iteracija.

4.2.3 Validacija metode

Rezultati validacije predložene metode prikazani su u grafičkom i tabličnom obliku. Validacija metode odrađena je na 100 simuliranih i nasumično odabranih topologija koje nisu bile korištene u procesu učenja. Rezultati su prikazani kao mjera ispravnosti klasifikacije te kao efikasnost procjene stanja svakog sklopnog uređaja. Kao mjera klasifikacije za svaki od

sklopnih uređaja iz predloženog dijela neuronske mreže napravljene su krivulje operativne karakteristike izlaznih vrijednosti (eng. *Receiver Operating Characteristic curve*) ili ROC krivulje. ROC krivulja prikazuje odnos stope stvarnih pozitivnih rezultata i stope lažnih pozitivnih rezultata. Što je položaj krivulje bliži gornjem lijevom kutu, to su rezultati točniji. Veći udio netočnih odnosno pogrešno klasificiranih rezultata približava krivulju dijagonali prvog kvadranta. Mjera koliko ispravno radi klasifikator površina je ispod ROC krivulje.

4.2.3.1 Mjera klasifikacije

Za svaki sklopni element modela mreže rezultati klasifikacije u obliku površine ispod ROC krivulje, prikazani su u tablici III.


Tablica III Mjera klasifikacije po pojedinom sklopnom elementu

1	2	3	4	5	6	7	8	9	10
0.986	0.978	0.973	0.971	0.994	0.989	0.992	0.987	0.983	0.986
11	12	13	14	15	16	17	18	19	20
0.984	0.969	0.991	0.996	0.971	0.972	0.999	1.000	0.999	0.999
21	22	23	24	25	26	27	28	29	30
0.984	0.998	0.998	0.995	0.985	0.982	0.967	0.955	0.969	0.965


Iz tablice III vidljivo je da sustav neuronskih mreža najbolje klasificira sklopno mjesto broj 18, jer je mjera klasifikacije 1.00. To znači da sigurno postoji određeni prag, odnosno granična vrijednost, kod izlaza ANN sustava iznad kojeg će svi izlazni rezultati biti ispravno okarakterizirani kao uklopljeni, a ispod kojeg će biti ispravno okarakterizirani kao isklopljeni. Najgora klasifikacija postignuta je na sklopnom mjestu broj 28 gdje mjera klasifikacije iznosi 0.955.

U nastavku je prikazana slika 4.10 sa šest ROC krivulja koje odgovaraju pojedinim sklopnim mjestima. Na slici 4.10 a) prikazane su ROC krivulje za sklopna mjesta 18, 28, 13 i 26 gdje su 18 i 28 mjesta s najboljom i najgorom klasifikacijom. Također, slika 4.10 d), e) i f) prikazuje ROC krivulje s najboljom i najgorom klasifikacijom (18 i 28) te krivulje za sklopna


mjesta 5, 8, 11, 15, 22, 25 i 26 . Slike 4.10 b) i 4.10 c) prikazuju ROC krivulje za po 4 nasumično odabrana mjerna mjesta. Iz navedene tablice i popratnih slika može se zaključiti da predloženi sustav neuronskih mreža klasificira podatke s vrlo malim udjelom pogreške gdje mjera najveće uočene pogreške koja se javlja na sklopnom mjestu 28 nije veća od 0.045.




a)




b)




c)



d)



e)



f)

Slika 4.10 ROC krivulje - primjer

Za što bolju klasifikaciju potrebno je odabrati optimalnu graničnu vrijednost kod izlaznog vektora. Svaka vrijednost iznad granične vrijednosti poprima vrijednost 1 odnosno status zatvoren ili uključen dok svaka vrijednost ispod granične vrijednosti poprima vrijednost 0 odnosno status otvoren ili isključen. Primjenom predefiniranog koda u Python programskom jeziku moguće je optimizirati graničnu vrijednost koja će dati najbolje klasifikacijske rezultate. Optimalne granične vrijednosti prikazane su u tablici IV.

Tablica IV Optimalne granične vrijednosti za klasifikaciju izlaznog vektora


1	2	3	4	5	6	7	8	9	10
0.795	0.512	0.435	0.692	0.384	0.467	0.641	0.615	0.256	0.718
11	12	13	14	15	16	17	18	19	20
0.359	0.692	0.949	0.256	0.564	0.589	0.282	0.641	0.512	0.205
21	22	23	24	25	26	27	28	29	30
0.513	0.692	0.077	0.334	0.692	0.846	0.718	0.641	0.718	0.718

Koristeći optimalne granične vrijednosti iz tablice IV prilikom klasifikacije vrijednosti izlaznog vektora, ukupna efikasnost metode povećava se u odnosu na efikasnost pri kojoj je kao granična vrijednost uzet fiksni broj jednak za sva sklopna mjesta.


4.2.3.2 Efikasnost metode

Efikasnost metode provjerena je na 100 simulacija na prezentiranom modelu mreže pri čemu niti jedna od njih nije korištena u procesu učenja. Proces provjere efikasnosti metode na simuliranim podacima proveden je deset puta, a efikasnost je izračunata kao srednja vrijednost dobivenih rezultata. Greška je prikazana u obliku standardne devijacije i predstavlja prosječno odstupanje dobivenih vrijednosti od srednje vrijednosti. Prikazana efikasnost smije se tumačiti kao vjerojatnost da će prezentirani sustav prepoznati ispravno stanje svakog sklopnog mjesta unutar naznačene greške kao standardne devijacije. Rezultati su prikazani grafički i tablično, a analizirana je i tvrdnja iz prethodnog poglavlja da optimizirana granična vrijednost klasifikacije poboljšava ukupnu efikasnost metode. Prikazani histogrami obuhvaćaju srednju vrijednost i služe za usporedbu dobivenih rezultata.

Slika 4.11 predstavlja graf efikasnosti svakog pojedinog sklopnog mjesta s naznačenom vrijednosti pogreške.



Slika 4.11 Graf efikasnosti po sklopnom mjestu



Slika 4.12 Histogram efikasnosti po sklopnom mjestu


Točne vrijednosti naznačene grafom na slici 4.11 i histogramom na slici 4.12 prikazane su tablicom V. Tablica V prikazuje dobivene rezultate efikasnosti metode za svako pojedino sklopno mjesto, rezultati iako zapisani tablično čitaju se u obliku $eff = \bar{x} \pm \sigma$ gdje je $\bar{x}$ srednja vrijednost, a σ standardna devijacija.

Tablica V Rezultati efikasnosti po pojedinom sklopnom mjestu

s. m.	$\bar{x}$	σ
1	0.95	0.01
2	0.95	0.02
3	0.93	0.01
4	0.92	0.02
5	0.97	0,01
6	0.96	0.01
7	0.96	0.01
8	0.95	0.01
9	0.96	0.01
10	0.95	0.01
11	0.95	0.01
12	0.91	0.02
13	0.95	0.00
14	0.99	0.01
15	0.94	0.03
16	0.92	0.03
17	0.99	0.01
18	0.99	0.01
19	0.99	0.01
20	0.98	0.01
21	0.95	0.02
22	0.98	0.01
23	0.96	0.01
24	0.98	0.00
25	0.93	0.01
26	0.93	0.01
27	0.91	0.01
28	0.91	0.01

s. m.	$\bar{x}$	σ
29	0.90	0.01
30	0.89	0.01


Iz tablice je vidljivo da predložena metoda ispravno predviđa stanje svih sklopnih aparata s vjerojatnošću većom od 90 %, a na 19 od 30 mjesta sa vjerojatnošću većom i od 95 %. Ovi rezultati mogu biti dodatno poboljšani optimalnim odabirom granične vrijednosti kod klasifikacije. Na slici 4.13 prikazan je graf efikasnosti s optimalno odabranom graničnom vrijednosti, a na slici 4.14 usporedni histogram efikasnosti sa i bez optimizacije granične vrijednosti.



Slika 4.13 Graf efikasnosti s optimalno odabranom graničnom vrijednosti


Vidljivo je da su rezultati efikasnosti pri optimalnom odabiru granične vrijednosti klasifikacije u prosjeku bolji od 0.01, odnosno za 1%, od rezultata efikasnosti sa fiksno odabranom graničnom vrijednosti. Također, poboljšanje nije ravnomjerno raspoređeno po svakom sklopnom mjestu već su neka sklopna mjesta ostvarila bitno veće poboljšanje efikasnosti u odnosu na druga. Na histogramu sa slike 4.14 jasno se vide navedene tvrdnje gdje crvena boja označava rezultate efikasnosti sustava bez korektivnih poboljšanja, a plava boja s

korektivnim poboljšanjima. Kod sklopnih mjesta 2, 5, 14 javlja se gotovo identičan rezultat, a najveće poboljšanje vidljivo je na sklopnim mjestima 22, 24, 25.




Slika 4.14 Usporedni histogram efikasnosti

Ukupna efikasnost sustava ovisna je o broju podataka za učenje, a veća količina podataka za učenje rezultira većom ukupnom efikasnosti sustava. Na ovom primjeru analizirana je ovisnost efikasnosti sustava o broju podataka za učenje. Slika 4.15 prikazuje ukupnu efikasnost sustava ovisnu o broju izvedenih simulacija u procesu učenja sustava neuronskih mreža. Iz priloženog grafa vidljiva je progresija u razini efikasnosti kako se broj podataka za učenje, odnosno broj simulacija povećava. Već na 50 simuliranih topoloških slučajeva, što je iznimno malo u odnosu na ukupno moguć broj slučajeva razina efikasnosti sustava iznosi 0.82, a već na 200 slučajeva razina efikasnosti je veća od 0.9 odnosno 90%. Interpolirajući dobivene rezultate zamišljenom funkcijom može se tvrditi da razina efikasnosti u odnosu na broj izvedenih simulacija kontinuirano raste asimptotski se približavajući 1 uz zamjetno velik gradijent funkcije pri niskom broju ulaznih podataka za učenje. Na 400 simulacija koliko ih je u ovom istraživanju izvedeno za proces učenja, ukupna razina efikasnosti je 0.95 ± 0.01 što je za još uvijek mali broj simulacija u odnosu na ukupan broj mogućih slučajeva iznimno visoka razina efikasnosti.



Slika 4.15 Ovisnost efikasnosti o broju podataka za učenje

Ukupnu efikasnost sustava moguće je dodatno i povećati kada se uzmu u obzir korekcije prilikom detektiranog otočnog rada. Naime, ukoliko je prilikom procesa topološkog procesiranja detektiran otočni rad dijela mreže i ukoliko taj dio nema priključenih proizvodnih jedinica zaključuje se da je taj dio mreže ne energiziran. Tada je moguće izuzeti rezultate dobivene na sklopnim mjestima koji pripadaju čvorištima ne energiziranog dijela mreže jer nisu uključene u proces estimacije stanja u ostatku mreže. U nastavku su prikazani konačno dobiveni rezultati efikasnosti uzevši u obzir do sada navedena poboljšanja, a prikazan je i usporedni histogram na kojem je vidljiv doprinos u efikasnosti pri svakom od poboljšanja. Slika 4.16 prikazuje graf efikasnosti po pojedinom sklopnom mjestu sa svim navedenim poboljšanjima. Može se primijetiti da kod određenih sklopnih mjesta sustav ima veću efikasnost nego kod drugih te da je pogreška veća kod sklopnih mjesta s manjom efikasnošću. Razlog tome može biti taj što je kod tih sklopnih mjesta u procesu učenja promjena stanja bila manje zastupljena od drugih. Kod slabije zastupljenih promjena stanja smanjuje se broj kombinacija, odnosno zamjetnih refleksija u kojoj sudjeluje određeno sklopno mjesto što dovodi do smanjenog broja ulaznih podataka za isto.



Slika 4.16 Graf efikasnosti s korektivnim poboljšanjima

U tablici VI prikazani su rezultati efikasnosti sa slike 4.16. Rezultati se također čitaju u obliku $eff = \bar{x} \pm \sigma$ gdje je $\bar{x}$ srednja vrijednost, a σ standardna devijacija


Tablica VI Efikasnost s korektivnim poboljšanjima

s. m.	$\bar{x}$	σ
1	0.96	0.02
2	0.96	0.01
3	0.94	0.01
4	0.92	0.01
5	0.97	0.02
6	0.97	0.01
7	0.97	0.01
8	0.95	0.01
9	0.96	0.01
10	0.99	0.01
11	0.98	0.01

s. m.	$\bar{x}$	σ
12	0.92	0.02
13	0.95	0.01
14	0.99	0.01
15	0.94	0.03
16	0.94	0.02
17	0.99	0.01
18	1	0,00
19	0.99	0.01
20	0.98	0.01
21	0.99	0.01
22	0.98	0.01
23	0.98	0.00
24	0.98	0.00
25	0.94	0.01
26	0.94	0.01
27	0.95	0.01
28	0.91	0.02
29	0.91	0.02
30	0.93	0.02


Usporedbom rezultata vidljivo je da je u slučaju detekcije otočnog rada i korektivnog poboljšanja u tom smislu srednja vrijednost efikasnosti u odnosu na rezultate s optimalno odabranom graničnom vrijednosti klasifikacije poboljšana za nešto više od 0.01. Usporedni prikaz rezultata efikasnosti metode dan je slikom 4.17 na kojoj je prikazan histogram rezultata efikasnosti sa dvije razine poboljšanja. Crvena boja predstavlja efikasnost bez poboljšanja, plava boja predstavlja efikasnost s korektivnim poboljšanjem prilikom odabira optimalne granične vrijednosti klasifikacije, a žuta boja efikasnost pri izuzimanju pogrešnih rezultata prilikom detektiranog otočnog rada. Ovdje je također vidljivo da poboljšanje nije ravnomjerno raspoređeno po pojedinim sklopnim mjestima već da su na određenim dijelovima vrijednosti veće u odnosu na druga u kojima poboljšanja gotovo da i nema. Razlog tome je što u procesu validacije podataka na određenim mjestima testne mreže nije detektiran otočni rad stoga nema ni zamjetnog poboljšanja u tom smislu. Na mjestima na kojima je u validacijskom postupku

detektiran otočni rad izraženija je mjera efikasnosti u smislu poboljšanja. Kao konačni rezultat za mjeru efikasnosti predmetne metode uzimaju se oni koji uključuju oba navedena korektivna poboljšanja. Nakon svih poboljšanja konačna ukupna vrijednosti efikasnosti iznosi 0.96 ± 0.01 i izračunata je kao srednja vrijednosti efikasnosti na svih 30 sklopnih mjesta pojedinačno. Valja naglasiti da je navedena mjera efikasnosti izračunata kao srednja vrijednost efikasnosti dobivenih na 3000 podataka jer svaka od 100 simulacija napravljenih za validaciju sadrži 30 sklopnih mjesta.



Slika 4.17 Usporedni histogram efikasnosti s korektivnim poboljšanjima


Na slici 4.18 prikazan je histogram broja pogrešnih topologija gledajući zbirno cijeli testni model elektroenergetske mreže. Na histogramu je vidljiv raspored 100 različitih topologija dobivenih iz 100 simulacija za validaciju metode prema broju pogrešaka u svakoj od simulacija. Tako je vidljivo da je gotovo 45% topologija potpuno ispravno pogodoeno, odnosno da kod svake od tih simulacija nije bila niti jedna pogreška na bilo kojem od sklopnih mjesta u promatranom dijelu mreže. 30% simuliranih topologija sadržavalo je pogrešku na samo jednom od 30 promatranih sklopnih mjesta, a na 11% uočene su 2 pogreške. Više od 5 pogrešaka unutar jedne simulacije bilo je samo na 2 topologije od čega na jednoj 8, a na drugoj 9 pogrešaka.



Slika 4.18 Histogram ukupno pogrešnih topologija

4.2.3.3 Značaj DANN sustava neuronskih mreža


Više puta je spomenuto kako je najveći doprinos ovog istraživanja zapravo algoritam za dekompoziciju interferiranog signala pomoću sustava neuronskih mreža DANN. Taj sustav, koristeći prethodno tehničko znanje o prirodi i ponašanju elektromagnetskih valova u EES-u, razlaže superponirani signal na komponente od svake pojedine refleksije. K tome, u obzir uzima isključivo vrijednost amplitude, odnosno lokalnog ekstrema, koji jedini nosi topološku informaciju. Tako osmišljen i kreiran sustav bitno smanjuje broj ulaznih podataka u neuronsku mrežu, a time i broj podataka inicijalno potrebnih za učenje cijelog sustava. Ove tvrdnje potkrijepljene su usporednim rezultatima dobivenim iz sustava neuronskih mreža koji sadrži DANN dio i onim koji ga ne sadrži. Naime u sustavu koji ne bi sadržavao DANN uzorkovani signal išao bi u direktno neuronsku mrežu za prepoznavanje topologije (TANN). Na slici 4.19 prikazane su dvije usporedne ROC krivulje za dva navedena slučaja.



Slika 4.19 Usporedna ROC krivulja, sa DANN i bez DANN

Sa slike je vidljivo da je klasifikacija podataka znatno bolja sustavom koji sadrži DANN u odnosu na sustav koji ga ne sadrži. Kao mjera klasifikacije izlaznih podataka uzima se površina ispod ROC krivulje. Površina ispod ROC krivulje sa DANN sustavom iznosi 0.98, dok je površina ispod narančaste krivulje koja predstavlja mjeru klasifikacije bez DANN sustava iznosi 0.82. Iz navedenog već je vidljivo kako je klasifikacija izlaznih podataka značajno bolja u sustavu s DANN-om u odnosu na sustav bez DANN-a.

Efikasnost opisanog algoritma prikazana po pojedinom sklopnom mjestu bez sustava za dekomponiranje signala prikazana je slikom 4.20. U slučaju bez sustava za dekomponiranje signala, izmjereni reflektirani signal nakon procesa uzorkovanja direktno ulazi u neuronsku mrežu za prepoznavanje topologije. Takav signal sadrži mnoge superpozicije reflektiranih signala i jako ih je teško međusobno razlikovati što je i vidljivo na predmetnom grafu. Statusi pojedinih sklopnih mjesta predviđeni su s efikasnosti nižom od 0.6 s mogućnosti pogreške većom i od 0.2.



Slika 4.20 Efikasnost sustava bez DANN komponente

Efikasnost sustava prikazana je i tablično u tablici VII. Iz naznačenih podataka vidljivo je da je efikasnost sustava bitno manja u odnosu na sustav koji sadrži DANN komponentu te iznosi u prosjeku iznosi 0.71 ± 0.11 . Osim efikasnosti puno je i veća standardna devijacija što daje i veliku nesigurnost pri procjeni točnog topološkog stanja.


Tablica VII Efikasnost sustava bez DANN komponente

s. m.	$\bar{x}$	σ
1	0.69	0.05
2	0.71	0.05
3	0.71	0.03
4	0.66	0.11
5	0.80	0.08
6	0.76	0.07
7	0.68	0.12
8	0.70	0.05
9	0.60	0.19

s. m.	$\bar{x}$	σ
10	0.62	0.07
11	0.65	0.14
12	0.66	0.09
13	0.75	0.21
14	0.82	0.16
15	0.63	0.03
16	0.66	0.04
17	0.84	0.12
18	0.72	0.16
19	0.81	0.13
20	0.78	0.15
21	0.76	0.02
22	0.71	0.12
23	0.71	0.23
24	0.84	0.18
25	0.76	0.02
26	0.68	0.18
27	0.78	0.05
28	0.71	0.06
29	0.58	0.09
30	0.69	0.02

Usporedni histogram efikasnosti metoda sustava s i bez dekompozicije ulaznog vektora prikazan je slikom 4.21. Na navedenom histogramu crvenom bojom označena je srednja vrijednost efikasnosti sustava bez dekompozicije ulaznog signala, a plavom bojom označena je srednja vrijednost efikasnosti sustava sa dekompozicijom ulaznog signala.

Iz histograma sa slike 4.21 vidljivo je da je sustav sa dekompozicijom ulaznog signala bitno efikasniji od sustava bez nje te da sustav bez dekompozicije ima ne-ravnomjernije razine efikasnosti te veću nesigurnost u prepoznavanju točne topologije što ga čini neprimjerenim u funkciji topološkog procesiranja.



Slika 4.21 Histogram efikasnosti sustava sa i bez DANN-a

Ovim rezultatima potvrđeno je da sustav za dekompoziciju ulaznog signala u svakom slučaju unaprjeđuje efikasnost sustava za prepoznavanje topologije elektroenergetske mreže te kao takav predstavlja značajan doprinos ovog istraživanja u smislu analize refleksije putujućih valova u svrhu topološkog procesiranja.

4.3 Analiza rezultata

Analizirajući prikazane rezultate može se zaključiti da je dokazana hipoteza istraživanja odnosno da je staničnu i mrežnu topologiju u svrhu estimacije stanja moguće odrediti pravilnom interpretacijom utisnutog testnog naponskog signala. Naime, teoretski je pokazano kako reflektirani signal nosi topološku informaciju s električki udaljenog mjesta skoro u realnom vremenu. Praktički, najveći napor uložen je u ekstrapolaciju topološke informacije iz izmjerenog reflektiranog signala što je učinjeno s dvostrukim sustavom neuronskih mreža. Prvi dio sustava razlaže izmjereni signal na sastavne dijelove dok drugi dio sustava iz sastavnih dijelova prepoznaje topologiju sustava. Pokazano je kako je sustavom za dekompoziciju izmjerenog reflektiranog signala bitno povećana efikasnost sustava u odnosu na sustav koji pomoću neuronske mreže prepoznaje topologiju direktno iz izmjerenog signala. Naime,

efikasnost direktnog sustava iznosi prosječno 0.71 ± 0.11 dok efikasnost sustava s dekompozicijom iznosi u prosjeku iznosi 0.96 ± 0.01 što je povećanje između 40% i 53%. Osim samog povećanja efikasnosti, umanjena je vjerojatnost pogreške gledana kroz standardnu devijaciju te bitno smanjena potrebna količina ulaznih podataka. Dokazano je na primjeru kako je za 1.073.741.824 mogućih stanja dovoljno samo 400 podataka za učenje kako bi se postigla efikasnost sustava od prosječnih 96%. Takva efikasnost omogućena je razvojem sustava neuronskih mreža za dekompoziciju signala temeljenim na sprezi praktičnog znanja i umjetne inteligencije. Pokazano je kako povećanje količine ulaznih podataka nužno povećava ukupnu i efikasnost sustava koja se asimptotski približava 1 odnosno potpunoj točnosti kako broj podataka za učenje raste. Također je pokazano kako se loss-funkcija sustava za dekompoziciju signala smanjuje povećanjem broja ulaznih podataka, ali i kako se loss-funkcija smanjuje u ovisnosti o epohi procesa učenja. Mjera klasifikacije pri pojedinom članu izlaznog vektora, odnosno pojedinog sklopnog mjesta bliska je ili u nekim slučajevima jednaka 1. To znači da postoji određena klasifikacijska mjera ili granična vrijednost pri kojoj je interpretacija izlaznog rezultata u svim slučajevima bila potpuno točna. Iz prikazanih rezultata vidljivo je da mjera klasifikacije u slučaju sustava bez dekompozicije signala iznosi oko 0.8 što se smatra vrlo niskom mjerom budući da sama random funkcija ima mjeru od 0.5. U ovom radu s namjerom nije otklonjena bilo kakva mogućnost grube pogreške pri očitavanju rezultata u procesu učenja i validacije neuronskih mreža budući da su i u potencijalno stvarnom sustavu grube pogreške moguće. Stoga ovi rezultati u perspektivi predstavljaju i svojevrsnu statističku projekciju stvarnog stanja. Sumnja u grubu pogrešku u ovim rezultatima javlja se u slučaju kada na određenoj topologiji ima više od 3-5 grešaka što je ovdje bio slučaj u 6 % obrađenih topologija. Naravno, smanjenje broja grubih pogrešaka dodatno će uzrokovati povećanje efikasnosti sustava.

Obzirom da metoda razvijena u okviru ovog doktorskog rada predstavlja sasvim novi pristup određivanju topologije elektroenergetske mreže te da je pregledom literature utvrđeno da je ovo prvi rad koji razrađuje funkciju topološkog procesiranja na ovaj način, teško je naći srodan rad za usporedbu dobivenih rezultata. Pojedini znanstveni radovi koji su kroz dugi niz godina unaprjeđivali klasične metode topološkog procesiranja i detekcije estimacijskih pogrešaka doveli su do toga da imaju i nešto veću relativnu efikasnost od metode predložene u ovom doktorskom radu. Međutim, ova metoda u neusporedivoj je prednosti u smislu sinkronizma i brzine odziva informacije. Naime putujući val obzirom da je elektromagnetske prirode koji se širi u svim smjerovima od mjesta utiskivanja gotovo trenutno donosi informaciju na mjesto svog utiskivanja, ali što je možda još i važnije sve informacije su međusobno

vremenski sinkronizirane same po sebi. Pri procjeni ukupnog trajanja samog procesa potrebno ga je podijeliti na dva dijela: jedan dio odnosi se na vrijeme povratka signala od najudaljenije sabirnice, a drugi dio odnosi se na vrijeme potrebno za obradu signala. U konkretnom primjeru, vrijeme za refleksiju od najudaljenije sabirnice iznosi 1,25 ms, a naučenoj elektroenergetskoj mreži koja se izvodi na prosječnom komercijalnom računalu potrebno je nešto manje od 2 ms za prikaz topološkog vektora na izlazu. To znači da bi ukupan proces obrade signala iznosio nešto više od 3 ms, Uzevši u obzir i vrijeme potrebno za prijenos informacije u centralno postavljen estimator stanja dolazi se na ukupno vrijeme potrebno da estimator stanja primi topološku informaciju koje iznosi oko 5 ms. To je tek četvrtina periode sinusne frekvencije od 50 Hz, a k tome bitno manje od vremena djelovanja sklopnih aparata. Navedeno svojstvo velika je prednost ove metode i čini je vrlo potentnom za buduća istraživanja koja bi ju zasigurno trebala dovesti i do razine implementacije u EES. Obzirom da je ovime učinjen prvi korak ka unaprjeđenju funkcije topološkog procesiranja u sasvim novom smjeru može se zaključiti da je cilj ovog istraživanja postignut.

5 ZAKLJUČAK

U tržišnim uvjetima koji su prisutni i u polju elektroenergetike, nesporna je težnja unaprijediti sustave za podršku vođenju EES-a. Takvi sustavi sve više moraju biti autonomni u odlučivanju i brzi u odzivu. U ovom istraživanju razvijena je potpuno nova metoda za utvrđivanje topologije EES-a temeljena na analizi refleksije putujućih valova primjenom umjetne inteligencije, a sve u svrhu unaprijeđenja procesa estimacije stanja. Naime, pokazano je kako je topologiju dijela ili cijele elektroenergetske mreže moguće utvrditi u realnom vremenu isključivo mjerenjem i analizom utisnutog naponskog signala bez prethodnog poznavanja stanja sklopnih aparata. U istraživanju koje je rezultiralo ovom doktorskom disertacijom prezentirani su i dokazani znanstveni doprinosi koji su se odnosili na razvoj potpuno nove metode topološkog procesiranja, razvoj i dokazivanje funkcionalnosti algoritma za prepoznavanje topologije elektroenergetske mreže iz izmjenjenog testnog naponskog signala te pronalazak optimalnih lokacija utiskivanja i mjerenja testnog naponskog signala. Dokazano je da izmjereni reflektirani signal nosi informaciju o topološkoj strukturi elektroenergetske mreže te da je prezentiranim algoritmom sa određenom preciznošću moguće ekstrapolirati navedenu informaciju. Sam dokaz funkcionalnosti prezentirane metode je stupanj efikasnosti algoritma primijenjen na pojednostavljenom modelu mreže. Ukupna točnost predstavljenog algoritma ovisi o broju ulaznih podataka za učenje u odnosu na broj svih mogućih stanja, a dobiveni rezultati pokazuju da se primjenom ovog algoritma može čak i na relativno malom broju ulaznih podataka za učenje postići zadovoljavajuću točnost. Razlog ovako malom broju podataka potrebnih za učenje leži u tome što je u sklopu istraživanja razvijen sustav neuronskih mreža za dekompoziciju izmjenjenog signala u kojem je osim samog strojnog učenja primijenjeno određeno tehničko znanje o svojstvima elektromagnetskih putnih valova koje je bitno doprinijelo smanjenju nužnog broja podataka za učenje. Ta sprema strojnog učenja s tehničkim znanjima i iskustvima opisana u ovoj disertaciji predstavlja najveći doprinos znanosti ovog istraživanja i daje pravi put budućima. Ukupna efikasnost u topološkom procesiranju od prosječnih 96% također predstavlja doprinos u procesu estimacije stanja obzirom na vrijeme odziva algoritma i dobivanja konačnog topološkog rezultata što je i bio cilj ovog istraživanja. Također, prezentiranom se metodom smanjuje ukupno potrebna infrastruktura u procesu topološkog procesiranja obzirom da se testni signali utiskuju i mjere samo u optimalno odabranim čvorištima elektroenergetskog sustava. Informacija o topološkoj strukturi iz preostalih čvorišta, unatoč tome što ne sadrže nikakvo sklopovlje za topološko procesiranje,

stiže na obradu u realnom vremenu. Algoritam i metoda optimizacije izbora čvorišta također je jedan od definiranih doprinosa ovog istraživanja koji je ovim radom i dokazan.

Valja naglasiti da ovdje prezentirani rad predstavlja sasvim novi pristup određivanju topologije elektroenergetske mreže i da je predložena metoda izvorna metoda koja je provjerena isključivo u laboratorijskim uvjetima na pojednostavljenom modelu elektroenergetske mreže. Unatoč tome što zasada nije razvijena do razine spremnosti za implementaciju u elektroenergetski sustav, predstavlja čvrst temelj, daje jasan smjer i otvara put budućim istraživanjima na polju topološkog procesiranja. Također, ovdje prezentiranu metodu dekompozicije interferiranog signala na njegove sastavne dijelove pomoću umjetne neuronske mreže moguće je koristiti i u drugim sferama elektrotehnike, ali i ostalih znanstvenih disciplina koje se koriste valnom tehnikom što također predstavlja veoma značajan doprinos ovog istraživanja.

LITERATURA

- [1] G. Andersson, et al. "Causes of the 2003 major grid blackouts in North America and Europe, and recommended means to improve system dynamic performance," Power Systems, IEEE Transactions on, vol.20, no.4, pp. 1922- 1928, 2005.
- [2] J.D. McDonald, "The next-generation system," IEEE Power and Energy Magazine, vol.7, no.2, pp. 26-94, 2009.
- [3] Worldwide electricity production from renewable energy sources - Chapter 1. Electricity production in the world: general forecasts, 2009. Online: <http://www.energies-renouvelables.org/> 28. 4.2010.
- [4] A. Abur, A. G. Exposito, „Power System State Estimation: Theory and Implementation“. Power Engineering Series, vol. 24, Marcel Dekker, New York, 2004.
- [5] A. Monticelli, "Electric power system state estimation," Proceedings of the IEEE, Vol. 88, No. 2, pp. 262 – 282, 2000.
- [6] F.C. Schweppe, “Real time static estimator for bulk power generation-transmission system”, 1968.
- [7] F.C. Schweppe, J.Wildes, D. Rom, "Power System Static-State Estimation, Parts I, II and III," Power Apparatus and Systems, IEEE Transactions on Power Systems, vol. 89, no.1, pp.120-135, 1970.
- [8] A.M. Sasson, S.T. Ehrmann, P. Lynch, L.S. Van Slyck, “Automatic Power System Network Topology Determination”, IEEE Journals, Vol. PAS-92, 1973.
- [9] A. Bose, K.A. Clements, “Real-time Modeling of Power Networks”, IEEE Journals, Vol. 75, 1987.
- [10] F.C. Schweppe, E.J. Handschin, “Static State Estimation in Electric Power Systems” IEEE Trans. On Power Systems, Vol. 62, NO. 7, 1974.
- [11] A.G. Phadke, J.S. Thorp, K. Karimi, “State Estimation with Phasor Measurement”, IEEE transactions on Power Systems, 1986.
- [12] A.G. Phadke, “Synchronized phasor measurements in power systems”, IEEE Computer Applications in Power, Vol. 6, Issue 2, pp. 10-15, 1993.

- [13] A.G. Phadke and J.S. Thorp, "Synchronized Phasor Measurements and their Applications", Springer, New York, 2008.
- [14] A.G. Phadke, J.S. Thorp, R.F. Nuqui, M. Zhou, "Recent developments in state estimation with phasor measurements" Power Systems Conference and Exposition, 2009. PSCE '09. IEEE/PES, vol., no., pp.1-7, 2009.
- [15] J. Thorp, A. Abur, M. Begovic, J. Giri, R. Avila-Rosales, "Gaining a Wider Perspective," Power and Energy Magazine, IEEE, vol.6, no.5, pp.43-51, 2008.
- [16] R. Zivanovic and C. Cairns, "Implementation of PMU technology in state estimation: an overview," IEEE AFRICON 4th, Vol. 2, , pp. 1006-1011 1996
- [17] R. Jercic, I. Pavic, D. Peharda; "Identifying Network Topology Using Travelling Wave Reflections of the Test Signal" Tehnicki vjesnik/Technical Gazette., 1378-1383. 25 No. 5, 2018.
- [18] M. Gol., A. Abur.; „A robust PMU based three-phase state estimator using modal decoupling“; IEEE Transactions on Power Systems ,29 (5); 2292–2299
- [19] F.F. Wu, A. Monticelli, "Network Observability: Theory," Power Apparatus and Systems, IEEE Transactions on Power Systems, vol. PAS-104, no.5, pp.1042-1048, 1985
- [20] J. Wildes, "A static state estimator for a power system network", M.S. Thesis, MIT, 1968. Online: <http://dspace.mit.edu/handle/1721.1/45189> (15.2.2011.)
- [21] K.A. Clements, B.F. Wollenberg, "An algorithm for observability determination in power system state estimation", paper A75 447-3, IEEE/PES Summer Meeting, San Francisco, CA, 1975.
- [22] K.A. Clements, P.W. Davis, "Multiple Bad Data Detectability and Identifiability, A Geometric Approach," Power Engineering Review, IEEE vol.PER-6, no.7, pp.73, 1986.
- [23] M. Ožegović, K. Ožegović, Električne energetske mreže IV, FESB Split, ISBN: 953-6114-12-7, 1999.
- [24] R. C. K. Lee, Optimal Estimation, Identification, and Control. Cambridge, Mass.: M.I.T. Press, 1964.

- [25] F. C. Schweppe, "Power system static-state estimation, pt. III: implementation" IEEE Trans. Power Apparatus and Systems, vol. PAS-89, pp. 130-135, 1970.
- [26] R.A.M. Van Amerongen "On convergence analysis and convergence enhancement of power-system least-squares state estimators", IEEE Trans. Power Syst., Vol. 10, No.4, pp. 2038-2044, 1995.
- [27] M. Meriem et. al., "Study of state estimation using weighted-least-squares method (WLS)" International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM), Marrakech, 2016
- [28] J. Chen, Y. Liao, B. Gou, and K. Yocum, "Impacts of load levels and topology errors on WLS state estimation", North American Power Symposium (NAPS), Champaign, IL, 2012.
- [29] J. Grainger and W. Stevenson, "Power System Analysis", New York: McGraw-Hill, 1994
- [30] J. Chen, Y. Liao, B. Gou, "Study of WLS state estimation convergence characteristics under topology errors," Proceedings of IEEE Southeastcon, Jacksonville, FL, USA, 2013.
- [31] R. Ebrahimian, R. Baldick, "State estimator condition number analysis," IEEE Trans. Power Syst., vol. 16, no. 2, pp. 273-279, 2001.
- [32] K. Levenberg, "A method for the solution of certain nonlinear problems in least squares," *Q. Appl. Math.*, vol. 2, no. 2, pp. 164-166, 1944.
- [33] F. R. Hampel, E. M. Ronchetti, P. J. Rousseeuw, W. A. Stahel, "Robust Statistics: The Approach Based on Influence Functions". New York, NY, USA: Wiley, 2011.
- [34] D.S. Watkins, "Fundamentals of Matrix Computations", John Wiley and Sons, New York, 1991.
- [35] F. Aboytes, B.J. Cory, "Identification of measurement and configuration errors in static estimation", Proc. 9th Power Industry Computer Application Conference, New Orleans, June 1975, pp. 298-302.
- [36] H. Duran, "Surrogate measurements make faster state estimation optimal and general", Paper A 77 598-6, IEEE PES Summer Meeting, Mexico City, 1977.

- [37] A. Garcia, A. Monticelli, P. Abreu, "Fast decoupled state estimation and bad data processing", IEEE Trans. Power App. and Syst., Vol. 98, No.5, pp. 1645-1652, 1979.
- [38] L. Mili, T. Van Cutsem, M. Ribbens-Pavella, "Hypothesis testing identification: A new method for bad data analysis in power system state estimation", IEEE Trans. Power App. and Syst., Vol. 103, No. 11, pp. 3239-3252, 1984.
- [39] A. Monticelli, A. Garcia, "Reliable bad data processing for real time state estimation", IEEE Trans. Power App. and Syst., Vol. 102, No.5, pp. 1126-1139, 1983.
- [40] N. D. Xiang, S. Y. Wang, E.K. Yu, "Estimation and identification of multiple bad data in power system state estimation", Proc. 7th Power System Computation Conference, PSCC, Lausanne, 1981.
- [41] F.F. Wu, E.H.E Liu, S.M. Lun, "Observability analysis and bad data processing for state estimation with equality constraints", IEEE Trans. Power Syst., Vol. 3, No.2, pp. 541-578, 1988.
- [42] T.E. Dy Liacco, K.A. Ramarao, A.W. Weiner, "Network status analysis for real-time systems", in 8th PICA Conf. Proc., pp 356-362, 1973.
- [43] F. F. Wu, W.H.E Liu, "Detection of topology errors by state estimation", IEEE Trans. Power System, Vol. 4, pp. 176-183, 1989.
- [44] O. Alsac, N. Vempati, B. Stott, A. Monticelli, "Generalized State Estimation", IEEE Conferences, 1997.
- [45] R. Kussel, R. Chrustowski, and C. Jaborowicz, "The Topology Engine: A new Approach to Initializing and Updating the Topology of an Electrical Network", ABB Netzleittechnik GmbH, Germany.
- [46] J. Chen, A. Abur, "Enhanced Topology Error Processing via Optimal Measurement Design", IEEE Trans. Power System, Vol. 23, No. 3, 2008.
- [47] P. D. Yehsakul, I. Dabbaghchi, "A topology-based algorithm for tracking network connectivity", IEEE Trans. on Power Systems, Vol. 10, No.1, pp. 339-364, 1995.
- [48] B. Xu and A. Abur, "Observability analysis and measurement placement for system with PMUs," in Proc. IEEE Power Eng. Soc. Power Systems Conf. Expo., New York, Oct. 10-13, 2004.

- [49] C. Grigg et al, "The IEEE Reliability Test System-1996. A report prepared by the Reliability Test System Task Force of the Application of Probability Methods Subcommittee" IEEE Transactions on Power Systems, Vol. 14, 1999.
- [50] B. Gou, A. Abur, "An Improved Measurement Placement Algorithm for Network Observability Ability", IEEE transactions on Power Systems, 1998.
- [51] A. Bose and M. Prais, "A Topology Processor That Tracks Network Modifications Over Time", IEEE transactions on Power Systems, Vol. 3, 1988.
- [52] M.G. Cheniae, L. Mili, and P.J. Rousseeuw, "Identification of multiple interacting bad data via power system decomposition," IEEE Transactions on Power Systems, vol. 11, pp. 1555-1563, 1996
- [53] P. Bonanomi, G. Gramberg, "Power system data validation and state calculation by network search techniques," IEEE Transactions on Power Apparatus and Systems, vol. 102, no. 1, pp. 238-249, 1983.
- [54] R.L. Lugtu, D.F. Hackett, K.C. Liu, D.D. Mittle, "Power system state estimation: Detection of topological errors," IEEE Transactions on Power Apparatus and Systems, vol. 99, no. 6, pp. 2406-2412, 1980.
- [55] K.A. Clements, P.W. Davis, "Detection and Identification of Topology Errors in Electric Power Systems", IEEE Transactions on Power Systems, vol. 3, no. 4, pp. 1748-1753, 1988.
- [56] A.G. Phadke, J.S. Thorp, "History and applications of phasor measurements," Power Systems Conference and Exposition, PSCE 2006. 2006 IEEE PES , vol., no., pp.331-335, 2006.
- [57] Selvan M.P., Swarup K.S., "Object Methodology Method and Design for Topological Processing," IEEE Power and Energy, 6(1):18-29, 2005.
- [58] A. G. Phadke, J. S. Thorp, "Computer Relaying for Power Systems", Research Studies Press, 1988
- [59] K. A. Clements, G. R. Krumpholtz, P. W. Davis, "State estimator measurement system reliability evaluation-an efficient algorithm based on topological observability theory, "Trans. PAS, Vol. PAS-101, No. 4, pp 997-1004, 1982.

- [60] W.H.E. Liu and F.F. Wu, "Detection of topology errors by using state estimation", IEEE Transactions on Power Systems. Vol. 4, No. 1, pp. 176-183, 1989.
- [61] A. Monticelli, „Modelling circuit breakers in weighted least squares state estimation“, IEEE Transactions on Power Systems, 8(3), 1993
- [62] H.J. Koglin, D. Oeding, K.D. Scmitt, „Identification of topological errors in state estimation“, 2nd PSMC IEE Durham, pp.140-144, 1986
- [63] A.G.Phadke, J.S.Thorp; "History and Applications of Phasor Measurements"; IEEE PES Power Systems Conference and Exposition, Atlanta, 2006
- [64] IEEE Power Engineering Society, "IEEE standard for synchrophasors for power systems," IEEE Std C37.118TM-2005
- [65] V. Krinčić, S.Skok, A.Marušić; "Estimacija stanja elektroenergetskog sustava korištenjem sinkroniziranih mjerenja fazora"; 10. Savjetovanje HRO CIGRE, Cavtat, 2011.
- [66] S. Chakrabarti, E. Kyriakides, "PMU measurement uncertainty considerations in WLS state estimation" IEEE Trans. Power Systems, vol. 24, no. 2, pp. 1062-1071, 2009.
- [67] S. Chakrabarti, E. Kyriakides, G. Ledwich, A. Ghosh, "A comparative study of the methods of inclusion of PMU current phasor measurements in a hybrid state estimator," Power and Energy Society General Meeting, IEEE , pp.1-7, 2010.
- [68] S. Skok, I. Pavic, A. Barta, I. Ivankovic, N. Baranovic, Z. Čerina, R. Matica: „Hybrid state estimation model based on PMU and SCADA measurements“, 2nd international conference of Monitoring of power system dynamics performance, Saint Petersburg, Russia, 2008.
- [69] Z. Hongga, X. Yusheng, W. Dexing, et al., „State Estimation Model with PMU Current Phasor Measurements“, Automation of Electric Power Systems, vol. 28, no. 17, pp.37-40, 2004.
- [70] D. Junce, C. Zexiang, W. Keying, "Influence of Measured Values from Phasor Measurement Units on Equivalent Current Based Measurement Transform Algorithm in State Estimation," Power System Technology, vol. 29, no. 5, pp.47-51, 2005.
- [71] F. Aboytes, B. J. Cory, "Identification of measurement parameter and configuration errors in static state estimation," Proceedings of the PICA Conf.,1975

- [72] Irving, M.R., and Sterling, M.J.H., "Substation data validation", IEEE Proc., Vol. 129, pt C, No.3, pp. 119-122, 1982.
- [73] R. E. Larson, W. F. Tinney and J. Poschon, "State Estimation in Power Systems, Part I: Theory and Feasibility", IEEE Trans. PAS-89, pp. 345-352, 1970.
- [74] J. F. Dopazo, O. A. Klitin and A. M. Sasson, "State Estimation For Power Systems: „Detection and Identification of Gross Measurement Errors", Paper X-2, PICA Conference, Minneapolis, 1973.
- [75] E. Handschin, F.C. Schweppe, J. Kohlas, A. Fiechter; „Bad data analyses for power system state estimation“; IEEE Trans. Power Apparatus and Systems, PAS-94, 329-337. 1975.
- [76] J. Kohlas, „On bad data suppression in estimation“; IEEE Trans, Autom. Control, AC-17, 827-828. 1972.
- [77] H. M. Merrill, F. C. Schweppe; „Bad data suppression in power system static state estimation“; IEEE Trans. Power Apparatus and Systems, PAS-90, 2718-2725. 1971.
- [78] L. Mili, T. Van Cutsem, M. Ribbens-Pavella; „Bad data identification methods in power system state estimation - A Comparative study“; IEEE Trans. Power Apparatus and Systems, PAS-104, 3037-3049, 1985.
- [79] M.A.M. Hassan, A. Mansour, H. Nour Eldin; „Direct Detection and Identification of Topological Errors in EPS Data Base“; IEEE Trans., PWR-4, (1), pp. 176-183, 1989
- [80] R. F. Nuqui, A. G. Phadke; “Hybrid linear state estimation utilizing synchronized phasor measurements”, IEEE Power Tech Conference, Lausanne, Switzerland, p. 1665–9, 2007.
- [81] P. Rabha, C. C. Shyam, A. K. Sinha, "Hybrid state estimation of power system using conventional and phasor measurements", 2015 International Conference on Energy Power and Environment: Towards Sustainable Growth (*ICEPE*), pp. 1-6, 2015.
- [82] G.R. Krumpholz, K.A. Clements, P.W. Davis, „Power system state estimation residual analysis: an algorithm using network topology“, *ibid.* PAS-100, 1779-1787, 1981.
- [83] G.R. Krumpholz, K.A. Clements, P.W. Davis, „Power system observability: a practical algorithm using network topology“, *ibid.* PAS-99, 1534-1542. 1980.

- [84] L. Mili, Th. Van Cutsem "Implementation of Hypothesis Testing Identification in Power System State Estimation" IEEE-Transaction on Power Apparatus and Systems, Vol. 3, No. 3, August 1988.
- [85] N. Singh, H. Glavitsch; „Detection and Identification of Topological Errors in Online Power System Analysis“; IEEE Transactions on Power Systems, Vol 6. No. 1, 1991.
- [86] A. S. Costa, J. A. Leao; „Identification of Topology Errors in Power System State Estimation“; IEEE Transactions on Power Systems, Vol 8. No. 4, 1993.
- [87] M. H. Wuong, S. Lefebvre, X. D. Do; „Detection and Identification of Topological Errors from Real-Time Measurements Recognition“ IEEE Power Engineering Society Summer Meeting, Vol.3, July 2002 pp. 1565-1569, 2002.
- [88] F. Garcia-Lagos, G. Joya, F. J. Marin et al., "Modular power system topology assessment using Gaussian potential functions", IEEE Proc. Gener. Transm. Distrib., vol. 150, no. 5, pp. 635-640, 2000.
- [89] Y. Hassaine, E. Walter, M. Dancre, B. Delourme, P. Panciatici, "Estimation of the topology state of power system networks via interval analysis," IEEE Bologna Power Tech Conference, 2003.
- [90] R. Lukomski, "New approach to power system topology verification", The International Conference on Modern Electric Power Systems, Wroclaw, Poland, pp. 517—521, 2002.
- [91] R. Lukomski, K. Wilkosz, „Combining theoretical knowledge and artificial neural networks for power system topology verification“, Proceedings of the 9th International Conference on Neural Information Processing, ICONIP '02. Singapore, 2002.
- [92] R. Lukomski, K. Wilkosz, "Power system topology verification: assessment of different approaches", Proceedings of the 4-th International Conference on Control of Power Systems, pp. 269-274, 2000.
- [93] E. M. Lourenco, A. Simoes Costa, K. A. Clements, and R. A. Cernev, "A Topology Error Identification Method Directly Based on Collinearity Tests," IEEE Trans. Power Systems, vol. 21, pp. 1920-1929, 2006.
- [94] R. Lukomski, K. Wilkosz, "Power System Topology Verification Using Artificial Neural Networks: Maximum Utilization of Measurement Data", IEEE Bologna Power Tech Conference, 2003.

- [95] J. C. Pereira, J. T. Saraiva, V. Miranda, A. J. Simoes Costa, E. M. Lourenco, K. A. Clements, "Comparison of Approaches to Identify Topology Errors in the Scope of State Estimation Studies", in Proc. IEEE Porto Power Tech, Porto, Portugal, Paper EDT3-176, 2001.
- [96] T. Tian, M. Zhu, B. Zhang, "An Artificial Neural Network-Based Expert System for Network Topological Error Identification", in Proc. 1995 IEEE International Conference on Neural Networks Proceedings, Perth, WA, Australia, vol. 2, pp. 882-886, 27, 1995.
- [97] N. Vempati, S. Silva, O. Alsaç, B. Stott, "Topology Estimation", PES General Meeting, 2005.
- [98] R. Lukomski and K. Wilkosz, „Modeling of multi-agent system for power system topology verification with use of petri nets“ In 2010 Modern Electric Power Systems, pages 1-6, Wroclaw, Poland, 2010.
- [99] K. Wilkosz, Z. Kruczkiewicz, and T. Rojek, "Multiagent systems for power system topology verification. LNCS, vol. 5788, Springer, Heidelberg, 2009, pp. 815–822.
- [100] K. Wilkosz, Z. Kruczkiewicz, T. Babczynski, and W. Penar, "Performance evaluation of multiagent systems for power system topology verification," LNCS (LNAI), vol. 6070, Springer, Heidelberg, 2010, pp. 430-439.
- [101] K. Wilkosz, and Z. Kruczkiewicz, "Multiagent-system oriented models for efficient power system topology verification," LNCS (LNAI), vol. 6591, pp. 486-495, Springer, Heidelberg, 2011.
- [102] K. Wilkosz, Z. Kruczkiewicz, and T. Babczynski, "Performance evaluation of multiagent-system oriented models for efficient power system topology verification," LNCS (LNAI), vol. 7196, pp. 11-20, Springer, Heidelberg, 2012.
- [103] R. Lukomski, K. Wilkosz, "Identification of topology errors with use of unbalance indices and neural networks" IEEE Bucharest International Conference PowerTech, Bucharest, Romania, pp. 1-8, 2009
- [104] M. Ožegović, K. Ožegović, Električne energetske mreže I, FESB Split, ISBN: 953-6114-19-4, 1997.
- [105] L. van der Sluis, „Transients in Power Systems“, Chichester: John Wiley&Sons Ltd, 2001.

- [106] J. J. Grainger, W. D. Stevenson Jr; „Power System Analysis“; McGraw Hill Internatoonal Editions, Electrical Engineering Series, Singapore, 1994,
- [107] R. Rojas: „Neural Networks“, Springer-Verlag, Berlin, 1996.
- [108] S.Haykin; „Neural Networks, Comprehensive Foundation“, Prentice Hall, 2nd ed. 1999.
- [109] LJ. Teklić; „Određivanje vrste i mjesta kvara u elektroenergetskoj prijenosnoj mreži primjenom umjetnih neuronskih mreža“, Doktorska disertacija, FER, Zagreb 2017.
- [110] S. Lončarić, Neuronske mreže, predavanja, <http://nm.zesoi.fer.hr>
- [111] M. Čupić. B. Dalbelo Bašić, M. Golub, „Neizrazito, evolucijsko i neuroračunarstvo“, FER, 2013.,
- [112] M. Tarafdar Haque, A.M. Kashtiban, “Application of Neural Networks in Power Systems; A Review“, World Academy of Science, Engineering and Technology 6 2005.
- [113] „Mrežna pravila prijenosnog sustava“, Hrvatski operator prijenosnog sustava d.o.o. NN 67/17
- [114] L. H. Dieter "The Origins of the Sampling Theorem" *IEEE Communications Magazine*. **37** (4); doi:10.1109/35.755459. April 1999.
- [115] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-based learning applied to document recognition", Proc. IEEE, vol. 86, no. 11, pp. 2278-2324, 1998.
- [116] Keras: The Python Deep Learning Library; URL: <https://keras.io/layers/core/>
- [117] A. Ali, F. Yangyu, "k-sparse autoencoder-based automatic modulation classification with low complexity", IEEE Commun. Lett., vol. 21, no. 10, pp. 2162-2165, 2017.
- [118] A. Makhzani, B. Frey, „k-sparse Autoencoders“ International Conference on Learning Representations, ICLR, 2014
- [119] R. Hecht-Nielsen, "Theory of the backpropagation neural network", Int. Joint Conference Neural Network, vol. 1, pp. 593-605, 1989
- [120] Y. LeCun, Y. Bengio, "Convolutional networks for images speech and time series", The handbook of brain theory and neural networks, vol. 3361, no. 10, pp. 1995.
- [121] R. Diestel “Matching Covering and Packing”. In: Graph Theory. Graduate Texts in Mathematics, vol 173. Springer, Berlin, Heidelberg, 2017.

- [122] A. Schrijver “Theory of linear and integer programming”, John Wiley and Sons, New York, 1998.
- [123] R. E.; Stone, C. A. Tovey, "The simplex and projective scaling algorithms as iteratively reweighted least squares methods", SIAM Review. 33 (2): 220–237, 1991.
- [124] J. Clausen, “Branch and Bound Algorithms—Principles and Examples” Technical report, University of Copenhagen, 1999.
- [125] MATLAB Help; *linprog* function; <https://www.mathworks.com/help/optim/linear-programming-and-mixed-integer-linear-programming.html>
- [126] EMTP –EMTPWorks 3.1. Help: Simulation options, J.Mahseredjian, 2014.

Dodaci

Popis slika

<i>Slika 2.1 Funkcije estimatora stanja</i>	<i>5</i>
<i>Slika 2.2 Ulazni model sa sklopnim aparatima (bus-section/switching device model)</i>	<i>16</i>
<i>Slika 2.3 Konekcijski model s čvorištima i linijama (bus-branch model)</i>	<i>17</i>
<i>Slika 2.4 Primjer sabirničkog sustava.....</i>	<i>18</i>
<i>Slika 2.5 Jednostavna elektroenergetska mreža.....</i>	<i>20</i>
<i>Slika 2.6 Prikaz nekih mogućih pozicija mjernih uređaja</i>	<i>22</i>
<i>Slika 2.7 Utjecaj redukcije mreže na mjerna mjesta</i>	<i>23</i>
<i>Slika 2.8 Grafički prikaz Gauss-ove eliminacije na Jakobijevoj matrici.....</i>	<i>24</i>
<i>Slika 2.9 Četveropolni element modela prijenosnog voda.....</i>	<i>29</i>
<i>Slika 2.10 Prijenosni vod povezan s elementom sa koncentriranim parametrima</i>	<i>35</i>
<i>Slika 2.11 Prikaz umjetnog neurona</i>	<i>38</i>
<i>Slika 2.12 Principijelna shema neuronske mreže.....</i>	<i>39</i>
<i>Slika 2.13 Tipovi aktivacijskih funkcija.....</i>	<i>41</i>
<i>Slika 3.1 Dijagram toka predimplementacijskog dijela</i>	<i>44</i>
<i>Slika 3.2 Dijagram toka postimplementacijskog dijela.....</i>	<i>45</i>
<i>Slika 3.3 Propagacija testnog signala vodom u praznom hodu.....</i>	<i>48</i>
<i>Slika 3.4 Propagacija testnog signala na sabirnici s više incidentnih vodova</i>	<i>49</i>
<i>Slika 3.5 Propagacija testnog signala na sabirnici s incidentnim transformatorom.....</i>	<i>50</i>
<i>Slika 3.6 Propagacija testnog signala u upetljanoj mreži</i>	<i>51</i>
<i>Slika 3.7 Blok shema sustava ANN za prepoznavanje topologije EES-a.....</i>	<i>54</i>
<i>Slika 3.8 Blok shema sustava ANN za dekompoziciju vektora izmjerenih vrijednosti.....</i>	<i>57</i>
<i>Slika 3.9 Shema Locally Connected sloja</i>	<i>58</i>
<i>Slika 3.10 Shematski prikaz trostrukog Dense sloja u DANN-u</i>	<i>59</i>
<i>Slika 3.11 Tanh funkcija.....</i>	<i>61</i>
<i>Slika 3.12 Proces dekompozicije vektora izmjerenih vrijednosti.....</i>	<i>62</i>
<i>Slika 3.13 Sigmoidalna funkcija korištena kao aktivacijska funkcija posljednjeg sloja.....</i>	<i>66</i>
<i>Slika 3.14 Arhitektura TANN-a.....</i>	<i>67</i>
<i>Slika 3.15 Ilustrativan primjer grafa.....</i>	<i>71</i>
<i>Slika 4.1 Model mreže za validaciju metode</i>	<i>80</i>

<i>Slika 4.2 Model mreže za validaciju metode izrađen u EMTP programu.....</i>	<i>84</i>
<i>Slika 4.3 Reflektirani i rekonstruirani signal sa dekomponiranim vektorom - 1</i>	<i>86</i>
<i>Slika 4.4 Reflektirani i rekonstruirani signal sa dekomponiranim vektorom - 2</i>	<i>86</i>
<i>Slika 4.5 Reflektirani i rekonstruirani signal sa dekomponiranim vektorom - 3</i>	<i>87</i>
<i>Slika 4.6 Reflektirani i rekonstruirani signal sa dekomponiranim vektorom – 4</i>	<i>87</i>
<i>Slika 4.7 Reflektirani i rekonstruirani signal – pogreška</i>	<i>88</i>
<i>Slika 4.8 Trend Loss-funkcije</i>	<i>89</i>
<i>Slika 4.9 Loss funkcija u ovisnosti u epohi učenja</i>	<i>90</i>
<i>Slika 4.10 ROC krivulje - primjer</i>	<i>92</i>
<i>Slika 4.11 Graf efikasnosti po sklopnom mjestu</i>	<i>94</i>
<i>Slika 4.12 Histogram efikasnosti po sklopnom mjestu</i>	<i>94</i>
<i>Slika 4.13 Graf efikasnosti s optimalno odabranom graničnom vrijednosti.....</i>	<i>96</i>
<i>Slika 4.14 Usporedni histogram efikasnosti.....</i>	<i>97</i>
<i>Slika 4.15 Ovisnost efikasnosti o broju podataka za učenje</i>	<i>98</i>
<i>Slika 4.16 Graf efikasnosti s korektivnim poboljšanjima</i>	<i>99</i>
<i>Slika 4.17 Usporedni histogram efikasnosti s korektivnim poboljšanjima</i>	<i>101</i>
<i>Slika 4.18 Histogram ukupno pogrešnih topologija.....</i>	<i>102</i>
<i>Slika 4.19 Usporedna ROC krivulja, sa DANN i bez DANN</i>	<i>103</i>
<i>Slika 4.20 Efikasnost sustava bez DANN komponente</i>	<i>104</i>
<i>Slika 4.21 Histogram efikasnosti sustava sa i bez DANN-a.....</i>	<i>106</i>

Popis tablica

<i>Tablica I Parametri prijenosnih vodova korišteni u modelu</i>	<i>78</i>
<i>Tablica II Karakteristične impedancije transformatora u modelu</i>	<i>79</i>
<i>Tablica III Mjera klasifikacije po pojedinom sklopnom elementu</i>	<i>91</i>
<i>Tablica IV Optimalne granične vrijednosti za klasifikaciju izlaznog vektora</i>	<i>93</i>
<i>Tablica V Rezultati efikasnosti po pojedinom sklopnom mjestu</i>	<i>95</i>
<i>Tablica VI Efikasnost s korektivnim poboljšanjima</i>	<i>99</i>
<i>Tablica VII Efikasnost sustava bez DANN komponente.....</i>	<i>104</i>

Popis kratica

<i>ADAM</i>	- eng. <i>Adaptive Moment Estimation</i>
<i>ANN</i>	- eng. <i>Artificial Neural Network</i>
<i>DANN</i>	- eng. <i>Decomposer Artificial Neural Network</i>
<i>DPV</i>	- eng. <i>DANN Processed Vector</i>
<i>EMS</i>	- eng. <i>Energy Management System</i>
<i>EMTP</i>	- eng. <i>ElectroMagnetic Transient Program</i>
<i>eng.</i>	- engleski jezik
<i>ESS</i>	- <i>Elektroenergetski sustav</i>
<i>ICCP</i>	- eng. <i>Inter-Control Center Communications Protocol</i>
<i>KCL</i>	- eng. <i>Kirchhoff's Current Law</i>
<i>KVL</i>	- eng. <i>Kirchhoff's Voltage Law</i>
<i>LC</i>	- eng. <i>Locally Connected</i>
<i>LNR</i>	- eng. <i>Largest Normalized Residual</i>
<i>MLP</i>	- eng. <i>Multilayer Perceptrons</i>
<i>MV</i>	- eng. <i>Measurement Vector</i>
<i>PDF</i>	- eng. <i>Probability Density Function</i>
<i>PMU</i>	- eng. <i>Phasor Measurement Unit</i>
<i>ROC</i>	- eng. <i>Receiver Operating Characteristic</i>
<i>SCADA</i>	- eng. <i>Supervisory Control And Data Acquisition</i>
<i>TANN</i>	- eng. <i>Topology Artificial Neural Network</i>
<i>TL</i>	- eng. <i>Transmission Line</i>
<i>TR</i>	- <i>Transformator</i>
<i>WLS</i>	- eng. <i>Weighted Least-Squares</i>
<i>ZB</i>	- eng. <i>Zero Branch</i>

Životopis

Roko Jerčić rođen je 4. prosinca 1986. godine u Splitu. Osnovnu školu i srednju Opću gimnaziju završio je u Omišu, a diplomirao je 2010. godine na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu gdje je stekao naziv magistar inženjer elektrotehnike i informacijske tehnologije. Poslijediplomski doktorski studij na istom fakultetu upisao je 2012. godine. Od 2010. zaposlen je u Hrvatskom operatoru prijenosnog sustava, Prijenosnom području Zagreb, gdje radi i danas. U dosadašnjoj profesionalnoj karijeri radio je na poslovima planiranja, implementacije, eksploatacije i održavanja mjernih sustava u prijenosnoj mreži. Znanstveni interesi vezani su mu uz tehniku visokog napona te analizu i automatizaciju pogona elektroenergetskog sustava. Kao autor i koautor objavio je više stručnih i znanstvenih radova u zbornicima skupova s međunarodnom i domaćom recenzijom, a autor je i jednog rada objavljenom u časopisu s međunarodnom recenzijom. Ima položen stručni ispit i član je Hrvatske komore inženjera elektrotehnike u svojstvu ovlaštenog inženjera elektrotehnike. Član je hrvatskog ogranka CIGRE.

Curriculum Vitae

Roko Jerčić was born on December 4, 1986 in Split. He completed elementary and high school in Omiš, and graduated in 2010 on Faculty of Electrical Engineering and Computing, University of Zagreb, where he received his master's degree in electrical and information engineering. He enrolled postgraduate doctoral studies at the same faculty in 2012. Since 2010, he has been employed at the Croatian Transmission System Operator, Transmission Area Zagreb, where he works today. In his professional career, he has worked in the planning, implementation, exploitation and maintenance of metering systems in the transmission network. His scientific interests are related to high voltage technique and analysis and automation of power system. He is author of one paper published in an international peer-reviewed journal and co-author of several professional and scientific papers in conference proceedings with international and domestic peer review. He is a member of the Croatian Chamber of Electrical Engineers as a certified electrical engineer and also a member of the Croatian branch of CIGRE.

POPIS OBJAVLJENIH RADOVA

Radovi u časopisu:

1. R. Jerčić, I. Pavić, D. Peharda, "Identifying network topology using travelling wave reflections of the test signal", *Tehnički vjesnik-Technical Gazette*, vol. 25, no. 5, pp. 1378-1383, Sept-Oct 2018.

Radovi na konferencijama s međunarodnom recenzijom:

2. R. Jerčić, I. Pavić, I. Damjanović, „New Algorithm for Identifying Network Topology Based on Artificial Neural Networks“, 2019 2nd International Colloquium on Smart Grid Metrology (SMAGRIMET), Split , April 09-12, 2019. Paper 103.
3. Lj. Teklić, B. Filipović-Grčić, I. Pavić, R. Jerčić, „Detection of high impedance faults in power transmission network with nonlinear loads using artificial neural networks“, International Colloquium on Lightning and Power Systems, September 18 - 20, 2017. Paper 156
4. V. Bečirović, S. Smaka, R. Jerčić, S. Hanjalić, V. Helac, „A New Simple Algorithm for Power System Harmonic's Phasor Estimation“, 2018 International Symposium on Power Electronics, Electrical Devices, Automation and Motion (SPEEDAM), Amalfi, Italy, 20-22 June 2018.

Ostali radovi na konferencijama:

5. R. Jerčić, I. Duraković, A. Župan, “Sustav za trajni nadzor kakvoće električne energije u službi vođenja EES-a; Izvedeno stanje u Prp Zagreb”, 10. Simpozij o sustavu vođenja EES-a, Opatija 2012.
6. R. Jerčić, A. Pavić, „Mjerenje i analiza prisutnosti viših harmonika napona u prijenosnoj mreži“, 11. savjetovanje HRO Cigre, Cavtat, 2013.
7. R. Jerčić, “Optimalni broj i lokacija uređaja za monitoring kvalitete električne energije u prijenosnoj mreži”, 11. simpozij o sustavu vođenja EES-a, Opatija 2014.

8. I. Tolić, R. Jerčić, I. Duraković, V. Angebrandt, “Vrednovanje parametara kvalitete električne energije u prijenosnoj mreži sukladno odredbama mrežnih pravila elektroenergetskog sustava” 11. savjetovanje HRO Cigre, Cavtat, 2013.
9. D. Ljubičić, R. Jerčić, T. Bobetko, A. Elez, “Analiza induciranih struja u ekranima kableske veze 110 kV TE-TO – Ferenščica i mogućnosti uzemljenja ekrana kabela”, 12. Savjetovanje HRO Cigre, Šibenik 2015.