

# **Napredno vođenje elektroenergetskoga sustava primjenom podržanoga učenja**

---

**Damjanović, Ivana**

**Doctoral thesis / Disertacija**

**2023**

*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:168:517074>

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

*Download date / Datum preuzimanja:* **2024-07-09**



*Repository / Repozitorij:*

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





Sveučilište u Zagrebu  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Ivana Damjanović

**NAPREDNO VOĐENJE  
ELEKTROENERGETSKOGA SUŠTAVA  
PRIMJENOM PODRŽANOGA UČENJA**

DOKTORSKI RAD

Zagreb, 2023.



Sveučilište u Zagrebu  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Ivana Damjanović

**NAPREDNO VOĐENJE  
ELEKTROENERGETSKOGA SUŠTAVA  
PRIMJENOM PODRŽANOGA UČENJA**

DOKTORSKI RAD

Mentor: Prof. dr. sc. Ivica Pavić

Zagreb, 2023.



University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Ivana Damjanović

# **ADVANCED POWER SYSTEM CONTROL BASED ON REINFORCEMENT LEARNING**

DOCTORAL THESIS

Supervisor: Professor Ivica Pavić, PhD

Zagreb, 2023

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

Doktorski rad ima: 95 stranica

Doktorski rad br.: \_\_\_\_\_

## O mentoru

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 prediplomskom 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 udružica IEEE i HRO Cigre, a od 2007. godine član je Akademije tehničkih znanosti Hrvatske (HATZ).

## **About the Supervisor**

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).

*Moj obitelji i prijateljima!*

## Sažetak

Vođenje elektroenergetskog sustava jedna je od brojnih zadaća operatora prijenosnog sustava čija je svrha osigurati siguran i pouzdan rad elektroenergetske mreže. Složenost sadašnjeg i očekivanog budućeg elektroenergetskog sustava sve je veća zbog integracije obnovljivih izvora energije i novih uređaja u mrežu. S rastućom složenošću struktura elektroenergetskog sustava, njegov pogon i vođenje postaju sve izazovniji. Promjene rezultiraju povećanjem složenosti sustava, pri čemu je broj aktivnih upravljačkih točaka u mreži prevelik da bi se njima upravljalo ručno te se kao moguće rješenje navedenog problema nameće primjena tehnologije umjetne inteligencije u elektroenergetskom sustavu.

Fokus ovog istraživanja je upravljanje tokovima snaga kako bi se spriječila preopterećenja u mreži koja mogu dovesti do kaskadnih ispada i raspada sustava. Tehnička metoda koja je odbранa za primjenu je promjena topologije mreže sekcioniranjem sabirnica. Kako bi razvijeni model upravljanja tokovima snaga imao brzi odziv prilikom donošenja odluka te sposobnost automatskog učenja iz podataka, predložena metoda zasnovana je na algoritmima strojnog učenja. Točnije, odabrani su algoritmi podržanog učenja (engl. *reinforcement learning* - RL) zbog njihove glavne karakteristike, a to je da agent uči strategiju odabira akcije kroz interakciju s okolišem.

Osim konačnog produkta istraživanja, autonomnog RL dispečera za upravljanje tokovima snaga korištenjem isključivo sekcioniranja sabirnica, u radu su detaljno prikazani svi elementi istraživanja koji su prethodili konačnom rezultatu. Prikazano je razvijeno okruženje za simulaciju rada EES-a i RL, detaljno je opisana korištena testna mreža i pogonski scenariji te je prikazan algoritam odabira topologija sabirnica koji je doveo do značajnog poboljšanja rada RL agenta. Analizom rezultata potvrđen je veliki potencijal primjene podržanog učenja u području vođenja EES-a.

**Ključne riječi:** vođenje elektroenergetskog sustava, upravljanje tokovima snaga, promjena topologije mreže, sekcioniranje sabirnica, podržano učenje.

# **ADVANCED POWER SYSTEM CONTROL BASED ON REINFORCEMENT LEARNING**

## **Extended summary**

The power system is one of the most important technical systems consisting of electricity generation, consumption, transmission, and distribution. As production centers are often far away from consumption centers, electrical energy is transported through transmission networks. To maintain the system's safe and efficient operation, system control functions need to be carried out. System control involves a wide range of actions and calculations for monitoring, analysis, planning, and management. With the development of the power system, control functions are becoming more complex, and automation is increasingly pursued wherever possible. The changes that are currently being recorded in the power system and those whose impact is still expected are presented below. Electricity consumption continues to increase each year, leading to the need for additional network and generation unit construction and the installation of new coordination devices. The adoption of low-carbon policies and market liberalization results in an increasing share of renewable energy sources in the total system generation, with a tendency for further growth. Solar and wind energy sources, for which production is not easily predictable, are leading in application. Renewable sources are predominantly connected to the distribution network, which can cause a change in the usual direction of energy flow from transmission to distribution in cases where the source's power at the observed location exceeds the load's requirements. The location of renewable source installation is often far from the grid connection point, necessitating additional network expansion. The restructuring of power companies and market liberalization push the system to its technical and economic limits. Increasing loads on power lines and transformers often cause congestion in the network, potentially leading to element failures and, in the worst-case scenario, system blackout. These changes significantly impact system security and necessitate a substantial change in the system's control approach. In larger transmission network areas, these changes have a more profound impact on traditional network control methods. Therefore, it is necessary to explore potential development possibilities of computational tools that could enhance the control and planning of power system operation, enabling power system control centers to respond to expected changes in power system operation. Compared to the current changes affecting the power system, technological changes

in control centers are relatively slow. The disparity between these changes potentially leads to an increasing number of unforeseen events. To address this challenge and ensure prompt recovery and continued normal functioning of the endangered system, research to develop widely applicable technologies is crucial and should be supported.

Artificial intelligence is a field of computer science that deals with programming computers to solve tasks or problems by imitating human behavior. Machine learning (ML) is a subset of artificial intelligence in which decision-making is based on a model trained by learning from data or observation. The main objective of machine learning is to create adaptive learning techniques capable of autonomously learning from data and effectively contributing to the decision-making process. Machine learning (ML) encompasses three main types based on the learning process: supervised learning, unsupervised learning, and reinforcement learning (RL). Reinforcement learning is a type of learning where the agent interacts with the environment, selecting actions to maximize the numerical reward signal. The agent is not provided with explicit instructions on which actions to take; instead, it must explore and learn through trial and error, receiving rewards for its actions. Notably, in more challenging scenarios, the agent's actions can impact not only immediate rewards but also future situations and subsequent rewards. These two key features, trial and error, and delayed reward, are fundamental to reinforcement learning. RL is widely applied in complex sequential decision-making problems, including gaming, robotics, autonomous navigation, and learning control strategies.

This research focuses on power flow control in the power system to prevent network congestions, cascade failures of elements, and, in the worst-case scenario, system blackouts. The chosen technical method for implementation is network topology change through bus splitting. This method was selected because it falls into the category of congestion prevention methods without incurring additional operational costs, and its potential has not been extensively explored in the literature. To enable the developed autonomous power flow control model to respond rapidly and learn from data automatically, reinforcement learning algorithms were employed in the research.

The doctoral thesis is organized into several chapters, each addressing different aspects of the research topic. These chapters provide a structured approach to present the findings and insights gained throughout the study. The division into chapters allows for a systematic exploration of the subject matter, leading to a comprehensive understanding of the research's

objectives and outcomes.

**Chapter 2** provides an overview of the current state of the development of power system control functions. It presents a concise historical development of control centers and describes the main functionalities related to the topic of this thesis. Through a literature review in the field of the current state of development of power system control, a trend towards proactive actions due to comprehensive changes affecting the power system was observed. The research focuses on power flow control, and the fundamental theoretical background of this area is presented, along with the calculation methods used in this research.

**Chapter 3** introduces the theoretical background of the selected machine learning algorithm. Reinforcement learning is described in the context of artificial intelligence and machine learning. The main components of reinforcement learning, the mathematical formulation of the reinforcement learning problem, and the pseudocode of the utilized algorithm are listed. The chapter concludes with a review of literature achievements in the field of applying reinforcement learning in power system control.

**Chapter 4** presents a simulation framework for studying the application of reinforcement learning for power system control. The developed framework is a prerequisite for exploring the mentioned topic. Standard open-source tools were selected to create the framework to ensure the results are verifiable and to provide easy accessibility for researchers in further investigations. All the used tools are described, and a schematic representation of how they are integrated into one system is provided. The chapter ends with the procedure for utilizing the proposed framework on high-performance computers.

**Chapter 5** describes the test network used and the prepared monthly records of operational scenarios. All elements of the observed power system control problem are elaborated from the perspective of the reinforcement learning application. The parameters and constraints related to the simulation of power system operation are presented to ensure simulations reflect real-world conditions.

During the research, difficulties were noticed in training an autonomous agent based on reinforcement learning algorithms for power system control, primarily due to the complexity of the problem. The problem that the dispatcher needs to solve and/or prevent is overloads in the power grid. The available method for the dispatcher is changing the network topology by bus splitting, and the number of potential bus topologies is vast. Therefore, in **Chapter 6**, the algorithm for selecting bus topologies, developed and used in this research, is presented,

and its application significantly improved the learning and operation of the autonomous dispatcher based on reinforcement learning. The topology selection algorithm consists of 8 steps, applying fundamental principles and requirements for power system control, such as reliability and safety. Numerous calculations are also used to analyze the power system's operation, such as power flow calculations, N-1 security analysis, and sensitivity analysis factors called Power Transfer Distribution Factors.

**Chapter 7** provides a detailed description of the presented framework for simulating power system control and reinforcement learning, as well as the developed model of the autonomous dispatcher based on reinforcement learning and the application of the bus topology selection algorithm from Chapter 6. The chapter includes a detailed description and schematic representation of the developed RL model of the autonomous dispatcher. First, the training phase for several RL algorithms is presented. Second, the testing and evaluation results of the agent are shown in 100 unseen scenarios. The evaluation process demonstrates that using the proposed RL agent for power flow control significantly improves performance. A comparison of results with RL agents from available literature dealing with the same problem is conducted to illustrate the benefits of the proposed approach. Third, the operation of the autonomous dispatcher and adaptability analysis after the reinforcement learning application is demonstrated. The agent's behavior under different network conditions is shown, considering several test scenarios with varying shares of renewable energy sources in the total generation. Fourth, known limitations of this approach and suitable solutions are presented. Subsections describe the capabilities and characteristics of the presented framework for simulating power system operation and reinforcement learning.

Finally, **Chapter 8** summarizes the research and discusses future application possibilities of the presented approach. Challenges, research methods, and technical and overall effects throughout the research process are presented, along with the contribution of the doctoral thesis.

The doctoral thesis identifies the changes affecting the power system, emphasizing the importance of effective system control and automation. The application of artificial intelligence, specifically reinforcement learning, is investigated as a potential solution to enhance power system control functions. The main contributions of the research are the development of a simulation environment for power system control and reinforcement learning, the introduction of a novel bus topology selection algorithm, and the creation of an autonomous power system

control model based on reinforcement learning.

The prerequisite for investigating the application of reinforcement learning in power system control is a software framework containing a power system simulator and an extension for implementing reinforcement learning. A framework integrates open-source tools, adapting the power system simulator for a wide range of state-of-the-art RL algorithms from standard libraries. The simulator is designed to run on high-performance computing (HPC) devices, also known as supercomputers, to handle the computationally and memory-intensive nature of RL applications. The scalability of RL algorithms on HPC clusters allows for parallelization of learning, significantly reducing the agent's training time.

The preliminary results of applying RL for power system control were not satisfactory due to the demanding nature of the bus sectioning problem. Under normal conditions, when the network is not overloaded, most actions related to bus topology changes have similar reward values, leading to unsatisfactory learning results for the RL model. To address this issue, a reduced set of possible topology changes was introduced in the developed algorithm, aiming for better and faster RL agent learning, considering real constraints of power system operation and analysis results.

The research also includes the development of an autonomous model for power system control based on reinforcement learning. The results demonstrate the potential of the proposed methods in this work. The developed RL model components are described in detail, including the chosen RL algorithm, neural network architecture, and hyperparameters. Training results reveal the selection criteria for the used algorithm, the Double Dueling DQN with prioritized experience replay. The RL agent's performance was evaluated using 100 unseen scenarios and compared with similar agents from existing literature. The proposed approach is significantly more efficient in managing the power system and simple as it does not require additional learning techniques, and the observation and action spaces are reduced compared to other relevant solutions from the literature. The RL dispatcher's performance was demonstrated for selected operational scenarios with varying shares of renewable energy sources, showcasing the effectiveness and adaptability of the proposed RL agent after reinforcement learning.

**Keywords:** power system control, power flow control, network topology change, bus splitting, reinforcement learning.

# Sadržaj

<b>1. Uvod</b>	1
1.1. Motivacija	1
1.2. Cilj	3
1.3. Pregled rada	3
<b>2. Vođenje elektroenergetskog sustava</b>	6
2.1. Razvoj sustava za vođenje EES-A	7
2.2. Pregled literature trenutnog razvoja EMS-a	11
2.3. Upravljanje tokovima snaga	12
2.3.1. Proračun tokova snaga	13
2.3.2. Faktori osjetljivosti raspodjele tokova snaga	15
<b>3. Podržano učenje</b>	18
3.1. Strojno učenje	18
3.2. Teorijski opis podržanog učenja	19
3.2.1. Glavni elementi podržanog učenja	20
3.3. Markovljev proces odlučivanja	20
3.3.1. Nagrada	21
3.3.2. Strategija	21
3.3.3. Funkcija vrijednosti	22
3.3.4. Optimalna strategija i optimalna funkcija vrijednosti	23
3.3.5. Bellmanova jednadžba optimalnosti	23
3.3.6. Q-učenje	23
3.4. Pregled literature primjene podržanog učenja	27

<b>4. Okruženje za simulaciju rada elektroenergetskog sustava i podržano učenje . . . . .</b>	<b>31</b>
4.1. Grid2Op . . . . .	31
4.2. OpenAI Gym . . . . .	33
4.3. Ray . . . . .	33
4.4. Isabella klaster . . . . .	33
4.5. Okvir za simulaciju rada EES-a i RL . . . . .	34
<b>5. Opis testne mreže . . . . .</b>	<b>35</b>
5.1. Testna mreža IEEE-14 čvorišta . . . . .	35
5.2. Analiza pogonskih stanja . . . . .	36
5.3. Model mreže predstavljen elementima podržanog učenja . . . . .	40
5.3.1. Okoliš . . . . .	40
5.3.2. Prostor opažanja . . . . .	41
5.3.3. Akcije . . . . .	42
5.3.4. Nagrada . . . . .	44
<b>6. Algoritam odabira topologije sabirnica . . . . .</b>	<b>45</b>
<b>7. Autonomni model vođenja EES-a temeljen na podržanom učenju . . . . .</b>	<b>54</b>
7.1. RL model . . . . .	54
7.1.1. Trening . . . . .	56
7.1.2. Evaluacija . . . . .	58
7.1.3. Učinkovitost . . . . .	61
7.1.4. Ograničenja prikazanog pristupa . . . . .	61
7.2. Karakteristike predloženog okvira za simulaciju EES-a i primjenu RL-a . . . . .	65
<b>8. Zaključak . . . . .</b>	<b>68</b>
<b>A. Opis analiziranih akcija . . . . .</b>	<b>71</b>
<b>Literatura . . . . .</b>	<b>82</b>
<b>Popis slika . . . . .</b>	<b>90</b>
<b>Popis tablica . . . . .</b>	<b>91</b>

**Životopis** . . . . . 92

**Biography** . . . . . 95

# Poglavlje 1

## Uvod

### 1.1 Motivacija

Elektroenergetski sustav (EES) jedan je od najvažnijih tehničkih sustava kojeg čine proizvodnja, potrošnja, prijenos te distribucija električne energije. Kako su centri proizvodnje redovito vrlo udaljeni od centara potrošnje, prijenos električne energije obavlja se visokonaponskom mrežom. Za održavanje pogona sustava sigurnim i ekonomičnim potrebno je provoditi funkcije vođenja sustava. Vođenje sustava podrazumijeva veliki skup akcija i proračuna kojima se provodi nadzor, analiza, planiranje i upravljanje sustava. Razvijanjem EES-a funkcije vođenja postaju sve komplikiranije te se teži primjeni automatizacije gdje god je to moguće.

Promjene koje se trenutno bilježe u EES-u te one čiji se utjecaj tek očekuje prikazane su u nastavku poglavlja. Porast potrošnje električne energije prisutan je iz godine u godinu, a kao posljedica javlja se potreba za dodatnom izgradnjom mreže i proizvodnih jedinica te ugradnjom novih uređaja za koordinaciju njihovog rada. Niskougljična politika i liberalizacija tržišta dove do sve značajnijeg udjela obnovljivih izvora u ukupnoj proizvodnji sustava s tendencijom dodatnog porasta. U primjeni prednjače izvori koji iskorištavaju energiju Sunca i vjetra čiju proizvodnju nije jednostavno predvidjeti. Obnovljivi izvori su većim dijelom priključeni na distribucijsku mrežu, što može dovesti do promjene uobičajenog smjera toka energije iz prijenosne u distribucijsku mrežu u slučaju kada snaga izvora na promatranom mjestu premaši potrebe tereta. Lokacija izgradnje obnovljivih izvora često je vrlo udaljena od mjesta spajanja na mrežu zbog čega je potrebno dodatno izgraditi mrežu. Restrukturiranjem elektroprivrednih tvrtki i liberalizacijom tržišta sustav se iskorištava do samih granica tehničkih i ekonomskih mogućnosti. Opterećenja vodova i transformatora sve su veća te su vrlo često uzrok zagušenjima u

mreži koja potencijalno mogu dovesti do ispada pojedinih elemenata sustava te u najgorem slučaju do raspada sustava. Navedene promjene utječu na sigurnost rada sustava te bitno mijenjaju način vođenja sustava. Promatranjem većeg područja prijenosne mreže navedene promjene više utječu na tradicionalne načine vođenja mreže. Iz tog razloga potrebno je istražiti potencijalne mogućnosti razvoja računskih alata koji bi poboljšali vođenje i planiranje pogona elektroenergetskog sustava kako bi dispečerski centri bili u stanju odgovoriti očekivanim promjenama u radu EES-a. U usporedbi s promjenama koje trenutno zahvaćaju elektroenergetski sustav, promjene u tehnologiji dispečerskih centara su relativno spore. Nesrazmjer navedenih promjena potencijalno bi mogao dovesti do sve većeg broja nepredviđenih dogadaja. Potrebno je podupirati istraživanja u svrhu što boljeg razvoja tehnologija široke primjene koje bi dale odgovor na navedeni problem te eventualno ugroženi sustav što prije dovele do oporavka i nastavka normalnog funkcioniranja.

Umjetna inteligencija (engl. *Artificial Intelligence* - AI) je područje računarske znanosti koje se bavi programiranjem računala da rješavaju zadatke ili probleme imitirajući ljudsko ponašanje. Strojno učenje (engl. *Machine Learning* - ML) je podskup umjetne inteligencije u kojem se donošenje odluka temelji na modelu obučenom učenjem iz podataka ili opažanjem [1]. Primarna svrha istraživanja strojnog učenja je razvoj metoda učenja s brzim odzivom koje mogu automatski učiti iz podataka i implementacija naprednih modela predviđanja koji se koriste u procesu donošenja odluka. ML se prema iskustvu tijekom faze učenja sastoji od: nadziranog učenja (engl. *supervised learning*), nenadziranog učenja (engl. *unsupervised learning*) i podržanog učenja (engl. *reinforcement learning* - RL). Podržano učenje je učenje u kojem agent uči kroz interakciju s okolišem tako da odabire akcije kako bi se maksimizirao brojčani signal nagrade [2]. Agentu koji odabire akcije nije rečeno koje radnje treba poduzeti, već sam treba otkriti na temelju pokušaja i pogrešaka te pripadnih nagrada. U najzanimljivijim i najizazovnijim slučajevima, akcije mogu utjecati ne samo na trenutne nagrade, nego i na sljedeću situaciju, i posljedično tome na sve naredne nagrade. Navedene dvije karakteristike, pokušaji i pogreške te odgođena nagrada, dvije su najvažnije značajke podržanog učenja. RL nalazi primjene u širokom području rješavanja složenih problema uzastopnog odlučivanja kao što su igranje igrica, robotika, autonomna navigacija te učenje kontrolnih strategija.

## 1.2 Cilj

Cilj istraživanja je uspostava autonomnog sustava za vođenje elektroenergetske mreže temeljenog na algoritmu podržanog strojnog učenja koji upravlja tokovima snaga u mreži koristeći samo promjenu topologije sekcioniranjem sabirnica.

Hipoteze istraživanja uključuju sljedeće tvrdnje:

- 1.Zbog nepredvidivih i iznenadnih promjena u elektroenergetskom sustavu dispe čeri često moraju u kratkom vremenskom periodu donositi važne odluke vezane uz sprječavanje mogućih zagušenja u mreži. Za rješavanje navedenih problema planiraju se koristiti metode podržanog dubokog učenja koje su svoju primjenu našle u različitim sustavima vođenja u kojima se važne odluke moraju brzo donositi.
- 2.Za ubrzanje procesa u čenja i donošenje što kvalitetnijih odluka agenta u novim, nepoznatim situacijama, razvit će se algoritam odabira potencijalnih sabirnica čijim se sekcioniranjem može utjecati na povoljniju raspodjelu tokova snaga i sprječavanje preopterećenja u mreži.

Znanstveni doprinos rada sastoji se u sljedećem:

- 1.Model za autonomno vođenje elektroeneretskog sustava u uvjetima nepredvidive proizvodnje iz obnovljivih izvora temeljen na algoritmu podržanog strojnog učenja.
- 2.Algoritam za određivanje topoloških stanja za preusmjeravanje tokova snaga temeljen na proračunima za analizu elektroeneretskog sustava.

## 1.3 Pregled rada

Rad je podijeljen u nekoliko poglavlja.

U poglavlju 2 dan je pregled trenutnog stanja razvoja funkcija vođenja sustava. Prikazan je sažet povijesni razvoj centara za vođenje te opis glavnih funkcionalnosti povezanih s temom ovog rada. Pregledom literature iz područja trenutnog stanja razvoja sustava za vođenje EES-a uočena je težnja za proaktivnim djelovanjem uslijed sveobuhvatnih promjena koje zahvaćaju EES. Fokus rada je na upravljanju tokovima snaga te je osnovna teorijska pozadina tog područja prikazana uz opis proračuna koji su se koristili u sklopu ovog istraživanja.

Poglavlje 3 prikazuje teorijsku pozadinu odabranog algoritma strojnog učenja. Podržano učenje opisano je u kontekstu umjetne inteligencije i strojnog učenja. Nabrojani su glavni elementi podržanog učenja, matematička formulacija problema podržanog učenja te pseudokod

korištenog algoritma. Na kraju poglavlja dan je pregled literature dostačnuća u području istraživanja primjene podržanog učenja u području vođenja elektroenergetskog sustava.

U poglavlju 4 prikazan je okvir za proučavanje primjene podržanog strojnog učenja za potrebe vođenja elektroenergetskog sustava. Opisani su svi korišteni alati te je shematski prikazan način na koji su integrirani u jedan sustav. Na kraju poglavlja je prikazana procedura za korištenje predloženog okvira na računalima s visokom učinkovitošću.

Poglavlje 5 daje opis korištene testne mreže i za nju pripremljenih mjesečnih zapisa pogonskih stanja. Detaljno su opisani svi elementi promatranog problema vođenja elektroenergetskog sustava sa stajališta primjene podržanog učenja. Prikazani su parametri i ograničenja povezani sa simulacijom rada elektroenergetskog sustava kako bi simulacije što više odrazile stvarne prilike.

Prilikom istraživanja zamijećene su poteškoće u učenju autonomnog dispečera primjenom algoritama podržanog strojnog učenja za potrebe vođenja EES-a koje su posljedica kompleksnosti samog problema. Problem koji dispečer treba riješiti i/ili spriječiti jesu preopterećenja u mreži. Sredstvo koje mu je pri tome dostupno je promjena topologije mreže sekcioniranjem sabirnica, čiji je broj i za odabranu testnu mrežu jako velik. Stoga je u poglavlju 6 prikazan algoritam odabira topologije sabirnica koji je razvijen i korišten u sklopu ovog istraživanja i čija je primjena dovela do znatnog poboljšanja učenja i rada autonomnog dispečera temeljenog na algoritmu podržanog učenja.

U poglavlju 7 detaljno su opisani predstavljeni okvir za simulaciju rada elektroenergetskog sustava i podržanog učenja te razvijeni model autonomnog dispečera na temelju podržanog učenja uz primjenu algoritma odabira topologija sabirnica prikazanog u poglavlju 6. U potpoglavlju 7.1 detaljno je opisan i shematski prikazan razvijeni RL model autonomnog dispečera. Prvo je prikazana faza obuke i rezultati treninga u usporedbi s nekoliko RL algoritama. Drugo, testiranje i evaluacija agenta prikazana je na 100 neviđenih scenarija. Proces evaluacije pokazuje kako upotreba predloženog RL agenta za kontrolu tokova snaga u mreži dovodi do znatno poboljšanih performansi. Provedena je i usporedba rezultata s RL agentima iz dostupne literature koji se bave istim problemom kako bi se ilustrirala korist predloženog pristupa. Treće su demonstrirani način rada autonomnog dispečera i analiza prilagodljivosti nakon primjene podržanog učenja. Prikazano je djelovanje agenta pri različitim uvjetima u mreži. Razmatrano je nekoliko testnih scenarija s različitim udjelima obnovljivih izvora energije u ukupnoj proizvodnji. Četvrto, predstavljena su poznata ograničenja ovog pristupa te prikladna rješenja. U

## Poglavlje 1. Uvod

---

potpoglavlju 7.2 prikazane su mogućnosti i karakteristike predstavljenog okvira za simulaciju rada elektroenergetskog sustava i podržano učenje.

Konačno, 8 poglavlje sažima istraživanje i raspravlja o budućim mogućnostima primjene predstavljenog pristupa. Izazovi, metode istraživanja te tehnički i ukupni učinci tijekom cijelog procesa istraživanja prezentirani su zajedno s doprinosom rada.

## Poglavlje 2

# Vođenje elektroenergetskog sustava

Pogonska stanja u kojima se elektroenergetski sustav može naći su sljedeća [3]:

- (a)normalni pogon
- (b)ugroženi normalni pogon
- (c)poremećeni pogon
- (d)raspad elektroenergetskog sustava
- (e)ponovna uspostava napajanja.

Stanja sustava razlikuju se prema tome zadovoljavaju li energetsku potražnju sustava, tehnička i ekomska ograničenja te analizu sigurnosti N-1. Stanja sustava i status navedenih kriterija za svako stanje prikazani su na slici 2.1. Prijelaz stanja sustava iz ugroženog normalnog pogona u normalni pogon ostvaruje se preventivnim akcijama dispečera kako bi se izbjegli daljnji razvoji poremećaja. Za sustav u poremećenom pogonu potrebno je izvršiti korektivne radnje koje su rezultat kompleksnog procesa donošenje odluka. Donošenje odluka prilikom korektivnih radnji je obično vremenski zahtjevno pri čemu su od iznimne važnosti sustavi i simulatori koji se primjenjuju u vođenju EES-a.

Za određivanje trenutnog stanja sustava potrebno je provoditi nadzor u stvarnom vremenu, a za održavanje sustava u željenom stanju potrebno je provoditi upravljanje sustavom. Navedene dvije zadaće zovu se jednim imenom vođenje sustava. Jedna je to od mnogobrojnih zadaća operatora prijenosnog sustava koja objedinjuje funkcije planiranja, upravljanja, nadzora i analize pogona EES-a. Funkcije vođenja sustava obavljaju se u za to namijenjenim centrima, koji se nazivaju dispečerski centri, kako bi pogon sustava bio siguran, neprekinut, pouzdan i učinkovit. Modernim dispečerskim centrima upravljaju visokokvalificirani dispečeri uz pomoć upravljačkih sustava temeljenih na računalima.





Fig. 1.2-1: Power system states  
 P : preventive measures  
 C : corrective measures

**Slika 2.1:** Stanja elektroenergetskog sustava [4]

## 2.1 Razvoj sustava za vođenje EES-A

Razvoj dispečerskih centara kroz povijest bio je u skladu s potrebama elektroenergetskog sustava te u korak s tehnologijama i inovativnim konceptima. Do 1940-ih dispečeri su bili smješteni u veće proizvodne jedinice i transformatorske stanice te su komunicirali telefonima. Razvojem analogne tehnike dolazi do evolucije u području prikupljanja podataka i primjene udaljene kontrole. U razdoblju od 1950.-1970. digitalna računala intenzivno se koriste u offline studijama planiranja rada sustava. Raspad sustava u New Yorku 1965. potaknuo je ubrzano prihvaćanje korištenja SCADA/EMS (engl. *Supervisory Control And Data Acquisition – SCADA, Energy Management Systems – EMS*) sustava u upravljanju sustavom u stvarnom vremenu. Nakon 1970-ih se razvijaju grafički prikaz stanja sustava te proračuni poput estimacije stanja i optimalnih tokova snaga. Incidenti u EES-ovima diljem svijeta tih godina pojačavaju važnost i ubrzavaju prihvaćanja primjene analize sigurnosti, dispečera kao stručnjaka bitnog u donošenju prediktivnih i korektivnih odluka, simulatora i treninga za stručno osoblje. Primjene do sad nabrojane tehnologije i proračuna pogodne su za promatranje i upravljanje sustava u statičkim stanjima. Restrukturiranje elektroenergetskih tvrtki 1990-ih godina, kao i pojava novih vrsta mjernih uređaja za mjerjenje fazora napona i struja u stvarnom vremenu (engl. *Phasor*

*Measurement Unit – PMU), dovode do razvoja sustava sistemskog nadzora (engl. Wide Area Monitoring – WAM). Najznačajniju prednost ovog sustava predstavlja GPS sinkronizacija prikupljenih podataka pri čemu su prikupljeni podaci velike točnosti i vremenski usklađeni te kao takvi pogodni su za prikaz, analizu i upravljanje dinamičkim pojavama u sustavu. Moderni dispečerski centri obično koriste prednosti obje navedene tehnologije SCADA/EMS i WAM sustava koji se izvode neovisno, zasebno i paralelno [5]. Pojednostavljeni shematski prikaz arhitekture modernih dispečerskih centara prikazan je na slici 2.2.*



Slika 2.2: Shematski prikaz arhitekture modernih dispečerskih centara [5]

Zeleno osjenčani dijelovi slike 2.2 predstavljaju osnovne softverske module koji su implementirani te na kojima se temelji rad dispečerskog centra. To su SCADA i EMS sustavi kojima se prikupljaju i analiziraju podaci za statička stanja sustava. Plavo osjenčani dio slike 2.2 predstavlja dodatne, poboljšane dijelove sustava za upravljanje sa stajališta dinamičkih pojava u sustavu te se bilježi porast primjene alata navedenog dijela sustava.

Dispečerski centri su opremljeni sustavima za upravljanje i nadzor (SCADA) koji izvještava o statusima prekidača (uključenosti elemenata mreže) te mjerjenjima napona, frekvencije, struje i snage. SCADA je raspodijeljeni računalni sustav za prikupljanje i analizu podataka u stvarnom vremenu. Proces prikupljanja podataka započinje u samim stanicama EES-a gdje se mjerena i signala iz transformatorskih stanica prenose putem daljinskih stanica (engl. *Remote Terminal Unit -RTU*) do dispečerskog centra. Komunikacija između RTU uređaja i SCADA sustava vrši

se svakih nekoliko sekundi (prema [6] i [7] svake 2 sekunde), pri promjeni topologije ili na zah-tjev. Prikupljeni podaci se arhiviraju te ih razne aplikacije koriste. Osnovna primjena obrade prikupljenih podataka je prikaz stanja sustava, alarma i mogućnosti upravljanja operatoru sus-tava.

Za potrebe vođenja elektroenergetskog sustava u stvarnom vremenu, krajem 1960-ih razvi-jeni su računalni sustavi pod nazivom sustav za upravljanje energijom (EMS) koji operatorima sustava omogućuju pouzdano i učinkovito upravljanje mrežom [8]. Tri su glavne uloge EMS-a:

- 1.nadgledanje sustava: SCADA sustavi prikupljaju podatke svakih nekoliko sekundi, a po primitku podataka u kontrolnom centru njihovu obradu izvršava EMS.
- 2.pomo Ć pri donošenju odluka: Za donošenje odluka EMS software sadrži različite alate, a tipična lista navedenih alata i proračuna prikazana je na slici 2.2. Neki od najvažnijih pro-računa su: estimacija stanja, proračun tokova snaga, analiza sigurnosti, optimalni tokovi snaga, proračun kratkog spoja. Procesiranje podataka u realnom vremenu dobivenih od SCADA sustava započinje estimacijom stanja kako bi se pročistile greške u mjeranjima i komunikaciji čime se dobiva prikaz stanja sustava u određenom trenutku. Izlaz iz estima-tora stanja je ulaz u analizu sigurnosti kojom se provjerava kako ispad elemenata utječu na stanje sustava. Analiza sigurnosti provodi se na način da se za svaki odabrani ispad provede proračun za stacionarno stanje mreže nakon simuliranog ispada.
- 3.izvo Ćenje akcija u svrhu vođenja sustava: Akcije vođenja sustava unutar EMS-a mogu se podijeliti prema ulozi dispečera u njima na:
  - (a)direktno upravljanje bez nadzora dispe ċera
  - (b)direktno upravljanje uz nadzor dispe ċera
  - (c)ru ċno upravljanje dispečera


SCADA/EMS pruža operatorima sustava potrebnu pomoć za ekonomično i sigurno vođenje EES-a. U tom području razvijene su brojne aplikacije i proračuni za nadzor i kontrolu sus-tava koji su već spomenuti u prethodnim poglavljima. Sustavi su to koji vrlo dobro nadziru i upravlju EES-om u normalnom ili blago poremećenom stanju. Poseban problem predstavlja kompleksni proces donošenja pravovremene i ispravne odluke o akcijama vođenja sustava kada se dogode teži, nepredviđeni poremećaji. Navedeni problem rješavaju dispečeri svojim ekspert-nim znanjem što ih nesumnjivo stavlja u centralnu, ključnu ulogu sustava za vođenje koja će uvijek biti potrebna [4]. Budući da su pojave takvih poremećaja relativno rijetke, iskustvo u rje-šavanju problema stječe se uglavnom treningom. Bitno je napomenuti kako u donošenju takvih

odluka nema ustaljenih i općeprihvaćenih algoritama odnosno procedura te da navedene pojave mogu prouzročiti teže posljedice na rad i sigurnost EES-a. Moderni koncepti EMS-a moraju za cilj imati smanjivanje opterećenja operatora kao i pružanje pomoći pri odlučivanju sugerirajući prediktivne, korektivne i popravne radnje ovisno o potrebama sustava.

Ekspertni sustavi su računalni sustavi koji imitiraju procedure i odluke koje donosi stručna osoba prilikom rješavanja definiranog problema. Namjena primjene ekspertnih sustava u vođenju elektroenergetskog sustava je u području razvijanja rješenja za probleme koje se ne uspijeva riješiti algoritamskim ili matematičkim pristupom unutar zahtijevanog vremena. Sustav za pomoći pri donošenju odluka trebao bi sadržavati znanja iz:

- domenskog područja
- prepoznavanja slučajeva koje je potrebno riješiti
- donošenja odluka.

Za praktičnu primjenu potrebno je takvom sustavu omogućiti pristup trenutnim i povijesnim informacijama i stanjima sustava te na razumljiv način prikazivati rezultate na grafičkom simulatoru. To znači da bi takav sustav odnosno aplikacija trebao biti integriran unutar samog EMS-a, kao što je to predloženo u [4] i prikazano na slici 2.3. Implementacija sustava za pomoći prilikom donošenja odluka u vođenju kao što je prikazana na slici 2.3 za cilj bi imala pomoći operatoru u odabiru alata za analiziranje sustava sadržanih u EMS-u koji pruža najviše korisnih informacija za promatrano stanje u kojem se EES nalazi.



**Slika 2.3:** EMS sustav s ekspertnom računalnom podrškom [4]

## 2.2 Pregled literature trenutnog razvoja EMS-a

Zbog promjena u radu EES-a, operatori prijenosnih sustava i istraživači razvijaju i istražuju nove mogućnosti koje bi bile primjenjive u sustavu za vođenje. Slijedi prikaz dostupnih podataka o trenutnim stavovima u vezi razvoja EMS-a u svijetu.

„EMS for the 21st Century“ [8] izdala je CIGRE radna grupa D2.24 2011. godine. Dokument se u potpunosti bavi zahtjevima arhitekture suvremenih EMS-ova koji su potrebni za vođenje sustava u stvarnom vremenu. Zahtjevi za arhitekturu sustava mogu se sažeti u 5 točaka:

- 1.uslužno orijentirana arhitektura (engl. *Service-Oriented Architecture - SOA*)
- 2.zajedni čki informacijski model (engl. *Common Information Model - CIM*)
- 3.ugrađena sigurnost
- 4.nezavisna platforma
- 5.jedinstveno grafičko sučelje.

Interdisciplinarna MIT studija iz 2011. godine [9] bavi se sveobuhvatnim promjenama koje su izgledne u američkoj prijenosnoj mreži do 2030. godine i razvojima strategija koje bi bile u korak s izazovima i problemima s kojima se mreža može susresti. U poglavlju koje se bavi poboljšanjem prijenosne mreže i sustava za vođenje, automatsko donošenje upravljačkih akcija u centrima za vođenje predstavljeno je kao jedan od najvećih izazova. Studija prepostavlja da će se razvoj navedenih algoritama uvelike oslanjati na podatke PMU uređaja te da zbog te činjenice razvoj i točnost algoritama ovisi o razvoju i implementaciji PMU uređaja.

Članak [10] daje pregled novih funkcionalnosti koje je francuski operator prijenosnog sustava planirao implementirati u EMS tijekom 2018. godine. Fokus je na dvije kategorije: nove funkcionalnosti EMS-a i novi koncept transformatorske stanice. Glavna motivacija u implementiranju novih alata u EMS je sve veći udio obnovljivih izvora u ukupnoj proizvodnji električne energije koji unose promjene u način vođenja mreže te stav da će uslijed ugradnje novih alata u EMS iznimnu korist doživjeti sveukupni rad i sigurnost sustava.

Autori uključeni u razvoj EMS-a u Kini pregled trenutnog stanja razvoja sustava daju u [11]. Članak daje pregled trenutnog razvoja EMS-a u Kini prema preporukama CIGRE-a [8] u kojem je do 2018. godine implementirano prosječno 56% zahtjeva. Cilj razvoja EMS-a autori vide u svrhu služenju velikom centraliziranom sustavu koji se sastoji od više manjih sustava s naglaskom na cyber sigurnost i standardizaciju. Veliki napredak vide korištenjem sinkrofazorske tehnologije kod pojedinih aplikacija te proučavaju kako integrirati SCADA i PMU mjerena tako da se nadopunjaju.

Članak [12] daje pregled problema u Japanu uzrokovanih reformama u elektroenergetskom sektoru čije su provedbe potaknute nesrećom u Nuklearnoj elektrani Fukushima Daiichi i brzim razvojem solarnih distribuiranih izvora. U ispunjavanju takvih zahtjeva EMS i DMS su integrirani. U glavnom dispečerskom centru povezani su s meteorološkom agencijom kako bi što bolje predvidjeli proizvodnju solarnih elektrana. Novi kontrolni i zaštitni sustav sprječava širenje kaskadnih ispada te je dio EMS/DMS dizajna.

## 2.3 Upravljanje tokovima snaga


Integracija obnovljivih izvora energije velikih razmjera dugo je bio cilj u Europskoj Uniji (EU). Od uvođenja Direktive o obnovljivoj energiji (2009/28/EZ) 2009. godine [13] korištenje obnovljivih izvora energije nastavilo je rasti svake godine, dosegnuvši više od 22% u 2020. Trenutna Direktiva o obnovljivoj energiji 2018/2001/EU [14] stupila je na snagu u prosincu 2018., s ciljem da EU ostane globalni lider u obnovljivim izvorima energije i da joj se pomogne da ispunи svoje obveze smanjenja emisija prema Pariškom sporazumu. Direktiva uspostavlja novi obvezujući cilj obnovljive energije za EU do 2030. od najmanje 32%, s klauzulom za moguću reviziju naviše do 2023. Ovaj cilj je nastavak cilja od 20% za 2020. godinu.

Obnovljivi izvori se obično nalaze daleko od centara potrošnje, a ciljevi integracije obnovljive energije europskih zemalja uvelike variraju u odnosu na nacionalnu potražnju za energijom, što rezultira sve češćom pojavom zagušenja i značajnim potrebama za prekograničnim prijenosom snage.

Jedan od zadataka operatora prijenosnog sustava je osigurati da grane u mreži ne budu preopterećene, odnosno upravljati tokovima snaga [15]. Preopterećenje grana se javlja kada su grane opterećene iznad termičkih granica. Neki od glavnih razloga pojave preopterećenja su neusklađenost između proizvodnje i potrošnje, nepredviđeno povećanje potrošnje, ispad jednog ili više generatora te kvar opreme sustava. Preopterećenja grana mogu potencijalno dovesti do isključenja preopterećene grane. Tada se snaga isključene grane preraspodjeli po ostalim grana u mreži što može dovesti do kaskadnih ispada, a u najgorem slučaju do raspada sustava. Izgradnja novih elemenata mreže je skupa i vremenski zahtjevna opcija zbog čega je potrebno upravljati zagušenjima ekonomičnim mjerama. Mjerama za upravljanje zagušenjima može se spriječiti ili smanjiti preopterećenje grana. Mjere za upravljanje zagušenjima u mreži prikazane na slici 2.4 te se u osnovi mogu podijeliti na tehničke i netehničke mjere. Neki autori dijele

mjere za upravljanje zagušenjima u mreži prema operativnom trošku prilikom primjene pojedine metode na metode s troškom i metode bez troška. U tom kontekstu podjele, tehničke metode prikazane na slici 2.4 spadaju u grupu metoda bez troška, dok netehničke metode spadaju u metode s troškom. U sklopu ovog istraživanja razmatraju se tehničke mjere, a to su: primjena FACTS uređaja, promjena položaja regulacijskih preklopki transformatora, isključenje preopterećenih grana te promjena konfiguracije mreže. Fokus ovog istraživanja je proučavanje primjene mjere za upravljanje zagušenjima koja se odnosi na sekcioniranje sabirnica, a koja pripada u grupu tehničkih metoda bez operativnog troška izvođenja koje utječu na promjenu konfiguracije mreže.

U nastavku poglavlja ukratko su prikazani osnovni proračuni potrebni prilikom analiziranja, planiranja i vođenja EES-a koji su korišteni u sklopu ovog istraživanja.



**Slika 2.4:** Podjela mjera za sprječavanje i upravljanje zagušenjima u mreži [16]

### 2.3.1 Proračun tokova snaga

Proračun tokova snaga osnovni je proračun za analizu i vođenje EES-a. Početna prepostavka proračuna je da se sustav nalazi u normalnom, stacionarnom, simetričnom pogonskom stanju

zbog čega se trofazni sustav može pojednostavljeno prikazati jednofaznim nadomjesnim sustavom. Problem proračuna tokova snaga može se definirati kao izračun radne i jalove snage kojom je opterećena svaka grana mreže, te iznosa i faznog kuta napona na svakoj sabirnici promatranoj prijenosnog sustava za određeno uklopno i pogonsko stanje EES-a. Informacije dobivene iz proračuna tokova snaga mogu se koristiti za planiranje, analizu, razvoj i vođenje EES-a, a proračun se provodi samostalno ili kao dio složenijih proračuna i analiza. Problem određivanja iznosa i kuta napona sabirnica je nelinearan problem zbog prirode ovisnosti napona i snage te se pri rješavanju koriste iterativne metode. Jedna od najpoznatijih i najčešće korištenih metoda proračuna tokova snaga je Newton-Raphson metoda.

U određenim analizama i proračunima elektroenergetskog sustava može biti potreban vrlo velik broj proračuna tokova snaga. Stoga se za takve analize koristi pojednostavljeni, linearni, neiterativni proračun tokova snaga koji se naziva istosmjerni model proračuna tokova snaga. Istosmjerni model proračuna tokova snaga temelji se na izmjeničnom modelu uz sljedeće pretpostavke [17]:

- iznosi napona svih sabirnica su približno isti te su jednaki nazivnim vrijednostima
- razlike kutova napona su male
- zanemarene su poprečne grane elemenata mreže
- uzdužni otpor grana je zanemaren jer je dominantan utjecaj uzdužne reaktancije.

Na temelju navedenih pretpostavki, može se zaključiti da se ovim proračunom gubi informacija o toku jalove snage i iznosima napona te da nema gubitaka djelatne snage u sustavu.

Primjenjujući ranije navedena pojednostavljenja prema pretpostavkama za istosmjerni model proračuna tokova snaga, tok djelatne snage grane između čvorišta  $i$  i  $j$  može se odrediti prema [17]:

$$P_{ij} = \frac{\delta_i - \delta_j}{x_{ij}} = b_{ij}(\delta_i - \delta_j) \quad (2.1)$$

gdje su:

$P_{ij}$  - tok djelatne snage promatrane grane

$x_{ij}$  - uzdužna reaktancija promatrane grane

$b_{ij}$  - uzdužna susceptancija promatrane grane

$\delta_i$  - kut napona čvorišta  $i$

$\delta_j$  - kut napona čvorišta  $j$ .

Matrični izraz za istosmjerni model proračuna tokova snaga glasi:

$$[P] = [B][\delta] \quad (2.2)$$

gdje su:

$P$  - vektor injekcije snaga u čvorišta mreže

$B$  - matrica admitancija za istosmjerni model proračuna tokova snaga

$\delta$  - vektor kutova napona u čvorištima mreže.

$B$  matrica za istosmjerni model proračuna tokova snaga određuje se na jednak način kao i  $Y$  matrica kod izmjeničnih proračuna tokova snaga, osim što se zanemaruju poprečni elementi u mreži i uzdužni otpori grana. Iz 2.2 se fazne vrijednosti kuta napona mogu odrediti na temelju zadanih injekcija djelatnih snaga  $P$  i inverzne  $B$  matrice prema:

$$[\delta] = [B]^{-1}[P] \quad (2.3)$$

Prethodni izraz 2.3 rješenja istosmjernog modela proračuna tokova snaga može se zapisati i kao:

$$[\delta] = [X][P]. \quad (2.4)$$

gdje je  $X$  matrica inverzna  $B$  matrica.

### 2.3.2 Faktori osjetljivosti raspodjele tokova snaga

Model istosmjernog proračuna tokova snaga može se koristiti i za izračunavanje osjetljivosti tokova snaga po granama na promjenu injekcije snage u čvorištima mreže ili na isključenje grane u mreži. Kod analiza sigurnosti analizira se velik broj mogućih ispada što je problem koji je teško riješiti i zahtijeva puno vremena. Linearni faktori osjetljivosti (engl. *Linear Sensitivity Factors*) koriste se kako bi se dobila brza procjena mogućih preopterećenja u mreži. Navedeni faktori procjenjuju promjenu toka snage po granama mreže te su izvedeni na temelju istosmjernog modela proračuna tokova snaga. U osnovi se linearni faktori osjetljivosti dijele na dva tipa [18]:

- faktor osjetljivosti raspodjele tokova snaga (engl. *Power Transfer Distribution Factor - PTDF*)
- faktor osjetljivosti isključenja grane (engl. *Line Outage Distribution Factor - LODF*).

Faktor osjetljivosti raspodjele tokova snaga daje osjetljivost promjene toka djelatne snage grana u ovisnosti o promjeni injekcije snaga u čvorištima. PTDF faktori izračunati na temelju istosmjernog modela proračuna tokova snaga ne ovise o pogonskom stanju, već samo o topologiji mreže. Na taj način može se vidjeti kako promjena topologije mijenja utjecaj injekcije snage u čvorištima mreže na tokove snaga po granama mreže.

$$PTDF = \frac{\Delta P_\ell}{\Delta P_i} \quad (2.5)$$

gdje su:

$\ell$  - indeks promatrane grane

$i$  - indeks promatrane sabirnice

$\Delta P_\ell$  - promjena toka djelatne snage grane  $\ell$

$\Delta P_i$  - promjena injekcije djelatne snage u sabirnicu  $i$ .

PTDF faktori spremaju se u matricu osjetljivosti  $n_\ell \times n_b$ , gdje je  $n_\ell$  broj grana u mreži, a  $n_b$  broj sabirnica u mreži. Element matrice u retku  $k$  i stupcu  $m$ , odnosno  $PTDF_{km}$  predstavlja osjetljivost promjene toka djelatne snage u grani  $k$  s obzirom na povećanje injekcije snage u čvorištu  $m$ .

Prema istosmjernom modelu proračuna tokova snaga, tok djelatne snage po grani mreže određuje se na temelju izračunatog iznosa kuta napona sabirnica koje spaja promatrana grana i reaktancije promatrane grane prema izrazu 2.1. Za određivanje ovisnosti promjene djelatne snage grane  $\ell$ , između sabirnica  $i$  i  $j$ , u odnosu na promjenu proizvodnje generatora na sabirnici  $m$ , izraz 2.1 se derivira po injekciji djelatne snage čvorišta  $m$ :

$$\frac{\partial P_{\ell,i-j}}{\partial P_m} = \left( \frac{\partial \delta_i}{\partial P_m} - \frac{\partial \delta_j}{\partial P_m} \right) \frac{1}{x_{i-j}}. \quad (2.6)$$

Izrazi unutar zagrada u formuli 2.6, odnosno derivacije kutova napona po injekciji snage u čvorištima, odgovaraju elementima  $X$  matrice, koja je, kao što je već spomenuto, inverzna  $B$  matrica iz istosmjernog modela proračuna tokova snaga. Konačno, slijedi općeniti izraz za proračun PTDF faktora:

$$\frac{\partial P_{\ell,i-j}}{\partial P_m} = (X_{im} - X_{jm}) \frac{1}{x_{i-j}} \quad (2.7)$$

gdje su:

$x_{i-j}$  - reaktancija grane

$X_{im}, X_{jm}$  - elementi inverzne matrice  $B$

$P_{\ell,i-j}$  - tok snage po grani  $\ell$ , koja se nalazi između čvorišta  $i$  i  $j$

$P_m$  - injekcija snage u čvorištu  $m$

Pozitivna vrijednost faktora osjetljivosti PTDF ukazuje na smanjenje toka snage promatrane grane  $\ell$  sa smanjenjem injekcije snage u promatranom čvorištu  $m$ . S druge strane, negativna vrijednost faktora osjetljivosti predstavlja smanjenje toka snage grane  $\ell$  s porastom injekcije snage u promatranom čvorištu  $m$ . Ovako izračunati faktori osjetljivosti su izračunati u odnosu na referentno čvorište, što znači da se analizirana promjena injekcije u promatranom čvorištu nadoknađuje u referentnom čvorištu. Stoga, faktori osjetljivosti promjene toka snage po granama u odnosu na referentno čvorište jednaki su 0. Općenito, PTDF faktori mogu poprimiti vrijednost između  $-1$  i  $1$ . Vrijednost PTDF faktora jednaka  $1$  označava da se sva promjena injekcije snage može prenijeti isključivo promatranom granom, odnosno da isključenje grane koja ima PTDF jednak  $1$  dovodi do razdvajanja sustava jer je navedena grana radijalno spojena. Poznavajući PTDF faktore i inicijalne tokove snage po mreži, mogu se analizirati tokovi snaga za promijenjene injekcije snage prema:

$$\hat{f}_\ell = f_\ell^0 + PTDF_{\ell i} \Delta P_i. \quad (2.8)$$

gdje je:

$\hat{f}_\ell$  - tok snage grane  $\ell$  nakon promjene injekcije snage u čvorištu  $i$

$f_\ell^0$  - inicijalni tok snage grane  $\ell$ .

Također, kako su faktori linearna procjena osjetljivosti promjene toka snage po granama, utjecaj istovremene promjene injekcije snaga u više čvorišta može se odrediti superpozicijom.

# Poglavlje 3

## Podržano učenje

U ovom poglavlju prikazat će se kratak i opći opis temeljne teorije strojnog učenja koja se koristi u istraživanju prilikom izrade ovog rada. Strojno učenje će se prikazati u kontekstu umjetne inteligencije te će se prikazati podjela metoda strojnog učenja. Zbog svojih karakteristika, za problem vođenja elektroenergetskog sustava, kao najprikladniji algoritam odabранo je podržano strojno učenje. Pristup koji se proučava, podržano strojno učenje, više je fokusirano na postizanje cilja kroz interakciju od ostalih koncepata strojnog učenja. Pregled teorije obuhvaća opis općenitog koncepta podržanog strojnog učenja, opis odabrane metode Q mreže te opis pseudo-koda korištenog u ovom radu. Opis koncepta podržanog strojnog učenja i ključnih pojmove u ovom poglavlju uglavnom su preuzeti iz knjiga [2] i [19]. Oznake korištene u ovom radu također prate oznake iz navedene literature te se u njima mogu naći detaljniji opisi i dodatna pojašnjenja.

### 3.1 Strojno učenje

U širokom smislu, umjetna inteligencija (engl. *Artificial Intelligence* - AI) je područje računar-ske znanosti koje se bavi programiranjem računala da rješavaju zadatke ili probleme imitirajući ljudsko ponašanje. Strojno učenje (engl. *Machine Learning* - ML) je podskup umjetne inteligencije u kojem se donošenje odluka temelji na modelu obučenom učenjem iz podataka ili opažanjem [1]. Primarna svrha istraživanja strojnog učenja je razvoj metoda učenja s brzim odzivom koje mogu automatski učiti iz podataka i implementacija naprednih modela predviđanja koji se koriste u procesu donošenja odluka. Duboko učenje (engl. *Deep Learning* - DL) pristup je strojnom učenju temeljen na neuronским mrežama i velikoj količini podataka, a najpoznatiji

primjer ove vrste učenja je duboka neuronska mreža. ML se prema iskustvu tijekom faze učenja sastoји od: nadziranog učenja (engl. *supervised learning*), nenadziranog učenja (engl. *unsupervised learning*) i podržanog učenja (engl. *reinforcement learning* - RL). Kod nadziranog učenja, algoritam na ulazu dobiva skup podataka u kojem se svaki primjer sastoji od ulaznih vrijednosti i odgovarajuće oznake. Izlaz mreže uspoređuje se s postavljenim ciljevima i određuje se razlika. S ciljem smanjenja navedene razlike, korigiraju se težine. Najvažnije primjene nadziranog strojnog učenja su regresija (engl. *regression*) i klasifikacija (engl. *classification*). Algoritmi nenadziranog učenja uče iz skupova podataka koji nisu označeni. Cilj im je naučiti skrivenu strukturu u skupu neoznačenih podataka, odnosno naći pravilnost u podacima. Težine veza prilagođavaju se procesom samoorganiziranja koji uči korisna svojstva. Važna primjena nenadziranog strojnog učenja je grupiranje (engl. *clustering*). Podržano učenje se odnosi na agenta koji uči strategiju odabira akcije kroz interakciju s okolišem tako da maksimizira ukupnu nagradu. Tipični RL algoritmi uključuju dinamičko programiranje, Monte Carlo metodu, učenje vremenskih razlika (engl. *Temporal difference learning*). Primjene nalazi u igranju igrica, robotici, autonomnoj navigaciji, učenju kontrolnih strategija. Detaljniji opis ove podvrste strojnog učenja nalazi se u nastavku poglavlju. Duboko podržano učenje (engl. *deep reinforcement learning* - DRL) kombinacija je dubokog učenja i podržanog učenja, a primjenjuje se u širokom području rješavanja složenih problema uzastopnog odlučivanja.

## 3.2 Teorijski opis podržanog učenja


Podržano učenje je učenje u kojem se odabiru akcije kako bi se maksimizirao brojčani signal nagrade [2]. Agentu koji odabire akcije nije rečeno koje radnje treba poduzeti, već ih sam treba otkriti na temelju pokušaja i pogrešaka te pripadnih nagrada. U najzanimljivijim i najizazovnijim slučajevima akcije mogu utjecati ne samo na trenutne nagrade, nego i na sljedeće stanje, i posljedično tome na sve nagrade. Navedene dvije karakteristike, metoda pokušaja i pogrešaka te odgođena nagrada, dvije su najvažnije značajke podržanog učenja. Prilikom odlučivanja bez neposrednih povratnih informacija, agent mora održavati ravnotežu između iskorištavanja (engl. *exploitation*) i istraživanja (engl. *exploration*), što je još jedna od značajki koja podržano učenje razlikuje od ostalih vrsta učenja.

### 3.2.1 Glavni elementi podržanog učenja

Glavni elementi podržanog učenja obično uključuju:

- agenta (engl. *agent*)
- okoliš (engl. *environment* - e)
- stanje (eng. *state* - s)
- akcije (engl. *action* - a)
- nagradu (engl. *reward* - r)
- strategiju (engl. *policy* -  $\pi$ ),
- vrijednosnu funkciju (engl. *value function* - V ili Q).

Standardne postavke podržanog učenja sastoje se od agenta i okoliša o kojem agent dobiva potpune ili djelomične informacije. Trenutni položaj u okolišu u kojem se agent nalazi naziva se stanje. U svakom diskretnom vremenskom koraku agent donosi odluku u interakciji s neizvjesnim okolišem unutar kojeg želi postići cilj. Akcije agenta utječu na buduće stanje okoliša, čime se utječe na akcije koje su agentu kasnije na raspolaganju. Nagrada je brojčani signal kojeg okoliš šalje agentu u svakom koraku te određuje što je dobro, a što loše za agenta u promatranom trenutku. Cilj agenta je maksimizirati ukupnu nagradu.



Slika 3.1: Okvir podržanog učenja [2]

### 3.3 Markovljev proces odlučivanja

Markovljev proces odlučivanja (engl. *Markov Decision Process* - MDP), prikazan na slici 3.1, matematički je formuliran problem podržanog učenja, odnosno općeniti okvir za opis problema učenja interakcijom radi postizanja određenog cilja.

U svakom diskretnom vremenskom trenutku  $t = 0, 1, 2, 3, \dots$ , agent dobije reprezentaciju

sustava kroz stanje  $S_t \in S$  te odabire akciju  $A_t \in A$ . U sljedećem vremenskom koraku  $t + 1$  agent kao rezultat odabira akcije dobiva nagradu  $R_{t+1}$  te sustav prelazi u stanje  $S_{t+1} \in S$ . Opisani proces se ponavlja te MDP i agent tvore sekvencu stanja, akcija i nagrada:  $S_0, A_0, R_1, S_1, A_1, R_2, S_2, A_2, R_3 \dots$  Uz pretpostavku da su skupovi stanja  $S$ , akcija  $A$  i nagrada  $R$  konačni, nasumične varijable  $S_t$  i  $R_t$  imaju diskrete raspodjele vjerojatnosti koje ovise o prethodnom stanju i akciji. Vjerojatnost da ćemo završiti u stanju  $s'$  s obzirom na to da smo bili u stanju  $s$  i poduzeli akciju  $a$  definira se prema funkciji prijelaza p:

$$p(s', r | s, a) = \Pr\{S_t = s', R_t = r | S_{t-1} = s, A_{t-1} = a\} \quad (3.1)$$

za svaki  $s' \in S$ ,  $r \in R$  i  $a \in A(s)$ .

Funkcija prijelaza definira dinamiku MDP sustava.

### 3.3.1 Nagrada

Ranije je navedeno kako je cilj agenta maksimizirati ukupnu nagradu. Ukupna nagrada ili povrat (engl. *return*) u trenutku  $t$  definira se kao:

$$G_t = R_{t+1} + R_{t+2} + R_{t+3} + \dots + R_T \quad (3.2)$$

pri čemu je  $T$  konačni vremenski korak.

Kako bi se definirala ukupna umanjena nagrada (engl. *discounted return* – G) potrebno je uvesti faktor umanjenja  $\gamma$  (engl. *discount rate*). Faktor umanjenja je konstanta koja ima vrijednost između 0 i 1 te određuje relativnu vrijednost odgođene nagrade u odnosu na trenutnu nagradu. Slijedi izraz za ukupnu umanjenu nagradu:

$$G_t = R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots = \sum_{k=0}^{\infty} \gamma^k R_{t+k+1} \quad (3.3)$$

Na ovaj način agent uzima u obzir buduće nagrade tako da veću težinu daje trenutnim nagradama, dok težinu budućih nagrada zbog njihove neizvjesnosti umanjuje.

### 3.3.2 Strategija

Strategija definira način ponašanja agenta u određenom trenutku. Strategija je preslikavanje stanja okoliša na radnje koje se trebaju poduzeti u tim stanjima. U nekim slučajevima strate-

gija može biti jednostavna funkcija ili tablica pretraživanja, dok u drugim slučajevima može uključivati opsežnije izračune. Zadatak agenta je naučiti strategiju,  $\pi : S \rightarrow A$ , odabira akcije  $a_t$  na temelju trenutnog stanja  $s_t$  tako da maksimizira ukupnu nagradu. Strategija je srž agenta podržanog strojnog učenja u smislu da je sama dovoljna za određivanje ponašanja. Općenito, mogu biti determinističke i stohastičke. Deterministička strategija je funkcija koja za određeno stanje okoline, kao rezultata, daje akciju koju treba poduzeti u tom stanju:  $a = \pi(s)$ . Stohastička strategija definirana je kao vjerojatnost poduzimanja akcije  $a$  s obzirom na trenutno stanje  $s$ :  $\pi(a|s) = \mathbb{P}[A_t = a | S_t = s]$ . U kontekstu dubokog učenja, može se istrenirati neuronska mreža koja će donositi ove odluke. U procesu treniranja, agent će modificirati strategiju kako bi odabirala što bolje akcije.

### 3.3.3 Funkcija vrijednosti

Gotovo svi algoritmi podržanog učenja koriste funkciju vrijednosti kako bi procijenili koliko je dobro za agenta biti u promatranoj stanji ili koliko je dobro odabrati određenu akciju. Nagrade koje agent može očekivati u budućnosti ovise o tome koje će akcije poduzeti. U skladu s tim, funkcije vrijednosti definirane su s obzirom na strategiju. Razlikuju se dvije funkcije vrijednosti: funkcija vrijednosti stanja  $v_\pi(s)$  i funkciju vrijednosti akcije  $q_\pi(s, a)$ .

Funkcija vrijednosti stanja definira se kao očekivana ukupna nagrada s obzirom na trenutno stanje  $s$  i trenutnu strategiju  $\pi$ , odnosno računa se prema izrazu:

$$v_\pi(s) = \mathbb{E}_\pi [G_t | S_t = s] = \mathbb{E}_\pi [R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots | S_t = s] \quad (3.4)$$

Slično se definira i funkcija vrijednosti akcije koja procjenjuje koliko je dobro za agenta da odabere akciju  $a$  za promatrano stanje  $s$  prateći strategiju  $\pi$ .

$$q_\pi(s, a) = \mathbb{E}_\pi [G_t | S_t = s, A_t = a] = \mathbb{E}_\pi [R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots | S_t = s, A_t = a] \quad (3.5)$$

Prema konvenciji, funkcija vrijednosti akcije  $q_\pi$  se naziva Q-funkcijom i izlaz te funkcije za dani par stanje-akcija naziva se Q-vrijednost.

### 3.3.4 Optimalna strategija i optimalna funkcija vrijednosti

Rješavanje problema podržanog strojnog učenja zahtijeva traženje strategije koje maksimizira ukupnu nagradu. Za konačne MDP kažemo da je strategija  $\pi$  bolja od strategije  $\pi'$ , ako je funkcija vrijednosti dobivena prateći strategiju  $\pi$  za svako stanje  $s$  veća ili jednaka od funkcije vrijednosti za strategiju  $\pi'$ , odnosno  $\pi \geq \pi'$  ako i samo ako  $v_\pi(s) \geq v_{\pi'}(s)$  za svaki  $s \in S$ . Uvijek je barem jedna strategije jednaka ili bolja od ostalih i ona se naziva optimalnom strategijom. Može biti više optimalnih strategija no svima je zajednička funkcija vrijednosti koja se naziva optimalna funkcija vrijednosti i definira se prema:

$$v_*(s) = \max_{\pi} v_{\pi}(s), \text{ za svaki } s \in S. \quad (3.6)$$

Optimalne strategije, također dijele i iste funkcije vrijednosti akcija koje su optimalne i definiraju se kao:

$$q_*(s, a) = \max_{\pi} q_{\pi}(s, a), \text{ za svaki } s \in S \text{ i } a \in A(s) \quad (3.7)$$

### 3.3.5 Bellmanova jednadžba optimalnosti

Optimalna funkcija vrijednosti akcija obuhvaća važan identitet poznat pod nazivom Bellmanova jednadžba:

$$q_*(s, a) = \mathbb{E}[R_{t+1} + \gamma \max_{a'} q_*(s', a')], \text{ za svaki } s \in S \text{ i } a \in A(s). \quad (3.8)$$

Bellmanove jednadžbe do bile su ime po istraživaču Richardu Bellmanu [19], koji je također uveo i dinamičko programiranje. Bellmanove jednadžbe opisuju odnos između potproblema i glavnog problema, odnosno njima se opisuje funkcija vrijednosti stanja  $s_t$  pomoću funkcije vrijednosti za stanje  $s_{t+1}$ . Poznavajući funkciju vrijednosti za stanje  $s_{t+1}$ , jednostavno se iterativnim proračunom izračuna vrijednost stanja  $s_t$ , odnosno svih ostalih stanja.

### 3.3.6 Q-učenje

Eksplicitno rješavanje Bellmanove jednadžbe optimalnosti dovodi do pronalaska optimalne strategije, a time i rješavanja problema podržanog učenja. U praksi se izravno rješavanje rijetko koristi zbog čega se obično treba zadovoljiti približnim rješenjima [2]. Mnogo je različitih algoritama koji aproksimiraju rješenje Bellmanove jednadžbe optimalnosti, a dalje će se opisati

algoritam korišten u ovom istraživanju. Q-učenje (engl. *Q-learning*) je algoritam podržanog strojnog učenja bez modela i bez strategije definiran prema [20]:

$$Q(S_t, A_t) \leftarrow Q(S_t, A_t) + \alpha \left[ R_{t+1} + \gamma \max_a Q(S_{t+1}, a) - Q(S_t, A_t) \right] \quad (3.9)$$

pri čemu je  $\alpha \in [0, 1]$  parametar ovog algoritma koji se naziva stopa učenja (engl. *learning rate*). Navedeni parametar određuje u kojoj mjeri novostečene informacije nadmašuju stare informacije. Za  $\alpha = 0$  agent ništa ne nauči, odnosno iskorištava isključivo prethodna znanja, dok za  $\alpha = 1$  agent razmatra samo najnovije informacije pri čemu zanemaruje prethodno znanje. Izraz  $R_{t+1} + \gamma \max_a Q(S_{t+1}, a)$  naziva se cilj (engl. *target*), dok se izraz unutar uglate zagrade formule 3.9, odnosno  $R_{t+1} + \gamma \max_a Q(S_{t+1}, a) - Q(S_t, A_t)$ , naziva gubitak (engl. *loss* ili *error*).

U ovom slučaju, naučena funkcija vrijednosti akcija, odnosno Q-vrijednost, izravno aproksimira optimalnu funkciju vrijednosti  $q_*$ , neovisno o strategiji koja se slijedi. To pojednostavljuje analizu algoritma i omogućava rane dokaze konvergencije [2]. Ovaj algoritam je *off-policy* pri čemu koristi dvije mreže s različitim strategijama, odnosno odluke donosi na temelju ponašajne strategije (engl. *behavior policy*), dok nastoji optimirati drugu ciljnu strategiju (engl. *target policy*). Ponašajna strategija ne mora uvijek odabratи akciju s maksimalnom očekivanom nagradom, pri čemu koristi strategiju pod nazivom  $\epsilon$ -pohlepna strategija (engl.  *$\epsilon$ -greedy policy*). Parametar  $\epsilon \in [0, 1]$ , pod nazivom stopa istraživanja (engl. *exploration rate*), karakterističan je za podržano učenje te daje odnos između istraživanja i iskorištavanja akcija. Za  $\epsilon = 0$  akcije se odabiru tako da se preferira akcija koja maksimizira Q-vrijednost, dok se za  $\epsilon = 1$  akcije odabiru slučajno. Ravnotežom između istraživanja i iskorištavanja akcija izbjegava se problem lokalnih optimalnih rješenja. Ciljna strategija se koristi prilikom izračuna greške kod ažuriranja vrijednosti Q-funkcije. Ova strategija je uvijek pohlepna, odnosno uvijek odabire akciju  $a_{t+1}$  prema maksimalnoj očekivanoj nagradi.

Za jednostavnije probleme s malim brojem stanja i akcija proces učenja bi sadržavao Q-tablicu u kojoj bi se spremale Q-vrijednosti za sve kombinacije stanja i akcija. Inicijalno bi vrijednosti u tablici bile postavljene na 0 te bi se tijekom procesa učenja ažurirale prema gore navedenoj formuli 3.9 čime bi se približile optimalnim vrijednostima. Za probleme s velikim skupom stanja i akcija, tablica nije praktična i učinkovita te se kao aproksimacija optimalne funkcije vrijednosti akcija, odnosno Q-vrijednosti koriste neuronske mreže. Umjesto Q-tablice sada imamo Q-mrežu. Spajanjem podržanog učenja i dubokih neuronskih mreža dobivamo du-

boko podržano učenje (engl. *deep reinforcement learning*), odnosno za specifični algoritam Q-učenja dobivamo duboko Q-učenje (engl. *deep Q-learning*) s dubokom neuronskom mrežom koja aproksimira Q-funkciju i naziva se duboka Q-mreža (engl. *deep Q-network*). U slučaju korištenja neuronske mreže za aproksimaciju Q-funkcije, ta funkcija ima dodatan parametar, parametar neuronske mreže odnosno težine  $w$  (engl. *weights*):

$$\hat{q}(s, a, w) \approx q_\pi(s, a) \quad (3.10)$$

Problem Q-učenja u ovom slučaju prelazi u problem učenja neuronske mreže, odnosno problem ažuriranja težina neuronske mreže prema:

$$w_{t+1} = w_t + \alpha \left[ r_{t+1} + \gamma \max_a \hat{q}(s_{t+1}, a, w_t) - \hat{q}(s_t, a_t, w_t) \right] \nabla \hat{q}(s_t, a_t, w_t) \quad (3.11)$$

gdje je:  $w_t$  – vektor težina neuronske mreže,  $\nabla \hat{q}(s_t, a_t, w_t)$  – gradijent izračunat algoritmom širenja pogreške unazad.

Korištenje neuronskih mreža za aproksimaciju optimalne funkcije vrijednosti akcija može biti nestabilno ili čak divergirati. Kao mjere za navedeni problem, prema [21], predlažu se tehnike: iskusno ponavljanje (engl. *experience replay*) i fiksna ciljna mreža (engl. *fixed target network*). Metoda iskusnog ponavljanja pohranjuje iskustvo agenta u interakciji s okolinom u svakom vremenskom trenutku  $t$ , a ti se podaci dohvaćaju prilikom ažuriranja težina neuronske mreže. Podaci o stanjima, akcijama i nagradama se spremaju u memoriju u obliku  $\{S_t, A_t, R_{t+1}, S_{t+1}\}$  te se nasumično uzimaju grupe podataka iz memorije kako bi se trenirala mreža. Odabirući nasumična iskustva, sprječavamo mrežu da uči samo ono što je bilo neposredno te joj dopuštamo da uči iz raznolikih nizova prošlih iskustava. Kod računanja gubitka (izraz u uglatim zgradama formule 3.9) potrebne su dvije neuronske mreže u fazi treniranja, već spomenute ponašajna i ciljna mreža. Tijekom treninga se ciljna mreža privremeno fiksira, odnosno njene težine se ne ažuriraju u svakom vremenskom koraku. Navedena tehnika se zove fiksna ciljna mreža, a njome se smanjuje korelacija između ponašajne i ciljne mreže. Zbog toga se uvodi novi hiperparametar za ovaj algoritam učenja koji govori nakon koliko vremenskih perioda će se ažurirati težine ciljne mreže. Ciljna mreža se ažurira na način da se nakon zadanih  $n$  vremenskih koraka kopiraju i arhitektura i težine ponašajne mreže i proces se ponavlja. Time

pravilo ažuriranja težina prelazi u slijedeći izraz:

$$\mathbf{w}_{t+1} = \mathbf{w}_t + \alpha \left[ r_{t+1} + \gamma \max_a \tilde{q}(s_{t+1}, a, \mathbf{w}_t) - \hat{q}(s_t, a_t, \mathbf{w}_t) \right] \nabla \hat{q}(s_t, a_t, \mathbf{w}_t) \quad (3.12)$$

gdje je:  $\tilde{q}$  – ciljna (engl. *target*) mreža koja se periodički ažurira.

Pseudokod algoritma Q-učenja, u kojem se koristi DQN te navedene tehnike iskusno ponavljanje i fiksna ciljna mreža, prikazan je u nastavku.

**Algoritam Q-učenja za procjenu  $\pi \approx \pi_*$  uz pretpostavku da je riječ o tabličnom problemu [2]**

Parametri algoritma: stopa učenja  $\alpha \in (0, 1]$ , stopa istraživanja  $\varepsilon > 0$ ;

Inicijalizacija  $Q(s, a)$ , za svaki  $s \in \mathcal{S}^+, a \in \mathcal{A}(s)$ , proizvoljno osim za zadnje stanje za koje je  $Q(\text{terminal}, \cdot) = 0$ ;

**za epizodu čini**

Inicijaliziraj  $S$ ;

**za svaki korak u epizodi čini**

Izaberi  $A$  za  $S$  koristeći  $Q$  ponašajnu strategiju koja je  $\varepsilon$ -pohlepna;

Izvrši akciju  $A$ , promatraj nagradu  $R$  i priđi u novo stanje  $S'$ ;

$Q(S, A) \leftarrow Q(S, A) + \alpha[R + \gamma \max_a Q(S', a) - Q(S, A)]$ ;

$S \leftarrow S'$ ;

**kraj za svaki**

**kraj za**

Q-mreža je značajna prekretnica u području umjetne inteligencije, odnosno podržanog učenja te je DQN odabran kao temeljni algoritam za obuku agenta za kontrolu elektroenergetskog sustava u ovom istraživanju. Međutim, uvedena su dodatna proširenja DQN algoritma kako bi se nadišla poznata ograničenja. Iscrpno istraživanje u tom području prikazano je u [22]. Kako bi se prevladalo precjenjivanje (engl. *overestimation*) algoritma, predlaže se algoritam dvostrukе duboke neuronske mreže (engl. *Double DQN*) [23]. Da bi se generaliziralo učenje kroz akcije i poboljšala evaluacija strategije u prisutnosti mnogih akcija sličnih vrijednosti bez bilo kakve promjene u temeljnog algoritmu podržanog učenja, predstavljen je algoritam dualne duboke Q mreže (engl. *Dueling DQN*) [24]. Prioritetno ponavljanje iskustva (engl. *prioritized experience replay*) je algoritam koji se koristi u DQN-u i Double DQN-u.

*ence replay*) omogućuje RL agentima da se prisjete i ponovno koriste iskustva iz prošlosti kako bi češće ponavljali važne prijelaze i stoga učinkovitije učili [25]. Algoritam koji objedinjuje sva navedena poboljšanja naziva se algoritam dvostrukе dualne duboke Q mreže (DDDQN) s prioritetnim ponavljanjem iskustava (engl. *Double Dueling DQN with prioritized replay - PDDQN*).

### 3.4 Pregled literature primjene podržanog učenja

Pregled literature započinje pregledom dostignuća u području istraživanja primjene strojnog učenja u području vođenja elektroenergetskog sustava. Članak [26] daje opći pregled ideje o korištenju algoritama i tehnika strojnog učenja u izazovima elektroenergetskog sustava. Pregled članaka podijeljen je po algoritmima strojnog učenja koji se koriste u EES-u. Navedeni algoritmi su iz područja nadziranog i nenadziranog strojnog učenja. Iz navedenog pregleda literature, svojom povezanošću s ovim radom ističe se članak [27]. Obrađuje se tema kaskadnog širenja kvara, koji najčešće dovodi do raspada sustava. Za predikciju kaskadnih ispada, koristi se Bayesova mreža.

U skladu s rastućom zabrinutosti u vezi s promjenama koje zahvaćaju elektroenergetski sustav i posljedično dispečerske centre, veliki broj preglednih radova u literaturi predstavio je detaljan opis problema i značajnih rješenja, uključujući pristupe koji primjenjuju podržano učenje [28–31]. Oni istražuju primjenu RL-a u raznim područjima poput upravljanja proizvodnjom, upravljanja potrošnjom, tržišta električne energije, vođenja, kibernetičke sigurnosti i tako dalje. Razvijanjem prve aplikacije umjetne inteligencije koja je pobijedila čovjeka u nekoj igri 2016. godine, poznatije pod nazivom AlphaGo, dolazi do popularizacije DRL-a [32]. Rad [32] daje pregled ključnih komponenti AlphaGo algoritma te opis potencijalnih područja primjene navedenog procesa učenja u EES-u. Od navedenih mogućih primjena, povezanost s vođenjem EES-a imaju: online analiza sigurnosti, određivanje mjesta kvara, predikcija kaskadnih ispada.

U [28] je prikazan pregled literature objavljene iz područja primjene podržanog strojnog učenja i dubokog učenja u pametnim mrežama. Pregled članaka, koji su većinom objavljeni od 2016. godine, podijeljen je po poljima primjene na: predviđanje potrošnje (engl. *load forecasting*), mikromreže (engl. *microgrid*), upravljanje potrošnjom (engl. *demand response*), detektiranje kvara električne opreme (engl. *fault detection of electrical equipment*), analiza i vođenje EES-a (engl. *power system analysis and control*), kibernetička sigurnost (engl. *cyber*

*security*), predviđanje proizvodnje obnovljivih izvora (engl. *renewable energy generation prediction*). Od navedenih članaka neki se izdvajaju jer su povezani s temom ovog rada, odnosno povezuju primjenu podržanog učenja s funkcijama i proračunima za potrebe vođenja EES-a. U [33] promatra se implementacija DQL (engl. *dimensional Q-learning*) algoritma pri optimizaciji tokova jalove snage čiji je cilj u ovom slučaju minimizirati gubitke djelatne snage u prijenosu. Optimizacija jalove snage se vrši pomoću kontrolnih varijabli: iznosi napona generatora, položaji regulacijskih preklopki transformatora te jalove snage kondenzatorskih baterija. Kako bi se verificirao rad DQL algoritma za navedeni problem, uspoređen je s dva algoritma i u oba slučaja je davao rezultate u kojima su gubici manji.

Pregled literature primjene podržanog strojnog učenja i vođenja EES-a, daje članak [34] iz 2017. godine. Pregled literature je sažet u tablicu koja je podijeljena po području primjene, stanju u kojem se EES nalazi te korištenom algoritmu RL-a. Za sustav u normalnom pogonu, [35, 36] proučavaju primjenu RL-a za optimizaciju tokova jalove snage, odnosno kontrolu napona. Za sustav u poremećenom pogonu, [37] daje prijedlog rješavanja preopterećenja, odnosno zagušenja vodova podešavanje izlazne snage generatora uz primjenu RL-a kako bi se spriječili kaskadni ispad i eventualni raspad sustava. [38] razmatra mogućnosti primjene RL-a prilikom ponovnog uspostavljenja pogona sustava. Članci nisu zasebno analizirani, nego je cijelokupnim pregledom dano zaključno mišljenje o dostignućima prikazanima u dostupnoj literaturi. Neka od zapažanja koja su proizašla analiziranjem literature su: primjena RL-a razmatrana je u različitim područjima vođenja sustava te za različita operativna stanja sustava što potvrđuje potencijalnu primjenu, najčešće je korišten RL algoritam Q-učenje, domensko znanje ima važnu ulogu u rješavanju problema. Osim pregleda literature, iznosi se i potencijalna primjena i daljnji razvoj RL-a za potrebe vođenja sustava.

U [29] dan je pregled članaka koji proučavaju primjenu dubokog podržanog strojnog učenja u elektroenergetskom sustavu, a većina članaka objavljena je od 2018. godine. Proučavani članci podijeljeni su prema poljima primjene, sustavu na kojem je predviđena primjena, primjenjenim algoritmima DRL-a te krajnjem cilju. Ovisno o poljima primjene, dana je usporedba primjene DRL-a u odnosu na tradicionalno korištene metode. U području primjene DRL-a za vođenje sustava, kao glavna prednosti navodi se mogućnost primjene DRL-a za upravljanje nepredviđenim situacijama, gdje tradicionalne metode ne postižu zadovoljavajuće rezultate. Iz pregleda članaka, temom bliskom ovom radu izdvaja se [39].

Najnoviji pregledni rad primjene podržanog učenja za odabrane ključne primjene u elek-

troenergetskom sustavu predstavljen je u [40]. Autori cjelovito analiziraju status istraživanja primjene podržanog učenja u elektroenergetski sustav. Studije [28–31, 40] dolaze do zaključka da RL nije zamišljen da u potpunosti zamijeni postojeće metode temeljene na modelu, već služi kao održiva alternativa za specifične zadatke. RL i druge metode vođene podacima obećavaju kada su modeli presloženi da bi bili korisni ili kada je probleme teško modelirati. Osim toga, ova je tema nova i još uvijek u razvoju te zahtijeva još mnogo studija.

Primjena RL-a razmatra se za različite probleme pri vođenju elektroenergetskog sustava te za različita pogonska stanja elektroenergetskog sustava. Za sustave u normalnom radnom stanju [36, 41] proučavaju korištenje RL-a za optimizaciju tokova jalove snage i regulaciju napona. Za poremećeni sustav, [37] predlaže metodu temeljenu na RL-u za sprječavanje kaskadnih ispada i raspada sustava upravljanjem proizvodnjom generatora. Studija [38] razmatra mogućnosti primjene RL za ponovnu uspostavu napajanja elektroenergetskog sustava. Velik broj istraživanja usmjeren je na redispečing proizvodnje [42, 43], kontrolu napona [44, 45] ili upravljanje potrošnjom [46, 47].

Među njima, nekoliko je studija iskoristilo ekonomičniju metodu za upravljanje zagušenjem i prevenciju kaskadnih ispada s velikim potencijalom, rekonfiguraciju topologije mreže [48–50]. Autori iz [51] predstavljaju simulator Grid2Op za upravljanje elektroenergetskom mrežom s proširenjem za moguću primjenu RL-a. Ovaj simulator nudi priliku za istraživanje primjene RL u upravljanju elektroenergetskim sustavom. Da je istraživanje primjene RL-a i DRL-a u funkcijama vođenja elektroenergetskog sustava pobudilo interes istraživača diljem svijeta potvrđuje i izvještaj s natjecanja pod nazivom L2RPN (engl. *Learning to run a power network*) iz 2019. godine [51]. Cilj natjecanja bio je razviti RL agenta koji će spriječiti eventualne kaskadne ispade. Promatrala se testna mreža IEEE-14 čvoršta. Rad agenta simulirao se vođenjem sustava unutar nekoliko dana, s rezolucijom učitavanja novih stanja sustava svakih 5 minuta. Problem preopterećenja u mreži moguće je bilo riješiti isključivo topološkim promjenama. Prostor mogućih akcija činile su promjena statusa uključenosti linija i/ili sekcioniranje sabirnica pri čemu se jedna sabirnica mogla razdvojiti u najviše dvije sekcije. Promatrani scenariji pogonskih stanja mreže, postavljeni su tako da prate karakteristike francuske prijenosne mreže. U obzir su uzeta termička ograničenja vodova, kao i vrijeme reagiranja i broj reakcija dispečera. Članak [51] daje pregled istraživanja natjecatelja te su ranije navedeni članci [48–50] nastali kao rezultat sudjelovanja na navedenom natjecanju. Članak [48] predstavlja unakrsnu entropijsku metodu, jednostavan duboki RL pristup kontrolu mreže IEEE-14 čvoršta u traj-

nju od jednog tjedna pritom koristeći samo sekcioniranje sabirnica. Koristili su jednostavnu neuronsku mrežu s dva skrivena sloja, svaki s 300 neurona, i smanjili su radni prostor na 98 jedinstvenih akcija. Autori u [49] uhvatili su se u koštač s problemom koristeći dualnu duboku Q-mrežu, prethodnu obuku pomoću strojnog učenja i vođeno istraživanje. Bilo je potrebno 1200 epizoda za treniranje dualnog DQN agenta s vođenim istraživanjem za neprekidno vođenje mreže IEEE-14 čvorišta u 288 vremenskih koraka (1 dan). Eksperimenti u [50] su provedeni na tri elektroenergetske mreže: IEEE-5 čvorišta, IEEE-14 čvorišta i L2RPN WCCI 2020 mreža (mreža s 36 sabirnica). Implementirali su tri algoritma koji djeluju samo na promjenu topologije mreže sekcioniranjem sabirnica za potrebe vođenja električne mreže tijekom 3 dana (864 vremenska koraka). Jedan od promatranih algoritama bio je dvostruki DQN, a autori izvješćuju da je izvedba agenta nešto bolja s njihovom metodologijom nego agent koji ne radi ništa. Kao razlog loše izvedbe navode problem ostanka u lokalnom optimumu.


# Poglavlje 4

## Okruženje za simulaciju rada elektroenergetskog sustava i podržano učenje


U ovom poglavlju prikazat će se svi alati korišteni za potrebe ovog istraživanja te će se prikazati okvir za simulaciju rada elektroenergetskog sustava i podržano učenje u kojem su integrirani svi korišteni alati.

### 4.1 Grid2Op

Grid2Op (engl. *Grid To Operate*) je python otvorenog koda pomoću kojeg se može razviti, trenirati i evaluirati značajke RL agenta, odnosno RL dispečera koji upravlja elektroenergetskom mrežom [52]. Simulator imitira rad elektroenergetske mreže bilo koje veličine i karakteristika u diskretnim vremenskim koracima. Može simulirati kaskadne ispade, pri čemu se preopterećene grane isključuju i dalje se provodi proračun uzimajući u obzir sljedeća pogonska stanja. Osim topoloških promjena u mreži nudi mogućnost upravljanja proizvodnjom djelatne snage generatora. Topološke promjene u mreži mogu se izvesti sekcioniranjem sabirnica i promjenom statusa uključenosti grana. Za sekcioniranje sabirnica je bitno naglasiti da se sabirnica može razdvojiti u dvije sekcije. Glavna mu je namjena testiranje naprednih kontrolnih algoritama. Grid2Op posjeduje podatke za nekoliko testnih mreža različitih veličina i kompleksnosti uz koje su pripremljene arhive pogonskih stanja mreže u rezoluciji 5 minuta na razini mjeseca.



Slika 4.1: Arhitektura sustava Grid2Op - 1.dio [53]



Slika 4.2: Arhitektura sustava Grid2Op - 2.dio [53]

Na slikama 4.1 i 4.2 prikazana je ilustracija arhitekture sustava Grid2Op. U vremenskom trenutku  $t$ , okoliš predaje nagradu (skalar) i stanje sustava (engl. *observation space*), agentu (1). Agent odabire određenu akciju (2). Akcija se šalje okolišu (3). Okoliš se dodatno osvježava podacima iz slijedećeg vremenskog koraka prema podacima iz arhivskih pogonskih stanja (engl. *chronics*) (4). PandaPower ili neki drugi backend započinje proračun tokova snaga (5). Proračun tokova snaga se pokreće (6). Okoliš dohvata podatke o stanju mreže putem API-a (7). Također, provjerava je li neka akcija valjana ili nije te je ovisno o tome izvršava ili ne izvršava. Novo stanje i nagradu okoliš šalju agentu u vremenskom koraku  $t + 1$  (8). U slučaju kraja, za zadnji

podatak iz arhive pogonskih stanja mreže ili zbog raspada sustava, interakcija se prekida.

## 4.2 OpenAI Gym

Korak koji prethodi primjeni standardnih okvira za RL algoritme je priprema okoliša na potreban način. Zbog toga se koristi OpenAI Gym [54]. OpenAI Gym je Python biblioteka otvorenog koda za razvoj i usporedbu algoritama za podržano učenje [55]. Pruža standardni API za komunikaciju između okruženja i algoritama. To je najpopularniji izbor za implementaciju okruženja za obuku RL agenata. Širok raspon okruženja dostupan je unutar OpenAI gym-a te pruža jednostavan API za implementaciju prilagođenih okruženja. Svrha pretvaranja Grid2op okruženja u Gym okruženje je omogućiti korištenje standardnih RL okvira.

## 4.3 Ray

Ray je okvir otvorenog koda koji pruža jednostavan API za izgradnju distribuiranih aplikacija i široko je korištena platforma za podržano učenje [56]. Ray može uvelike ubrzati obuku i olakšati početak s dubokim podržanim učenjem. Dolazi s bibliotekama za ubrzavanje radnih opterećenja strojnog učenja. Biblioteke korištene u ovom istraživanju su RLlib, biblioteka za algoritme podržanog učenja, i Tune, biblioteka za podešavanje hiperparametara. Širok raspon najsuvremenijih algoritama dostupan je putem RLLib-a i može im se lako pristupiti i mijenjati. Osim dostupnih algoritama, kao velika prednost korištenja Ray-a je mogućnost paralelizacije učenja i skalabilnost koji su jednostavni za korištenje i omogućuju python programima skaliranje bilo gdje, od osobnog računala do velikog klastera.

## 4.4 Isabella klaster

RL aplikacije mogu biti prilično računalno i memorijski zahtjevne i često se moraju proširiti na klaster. Klaster omogućuje korištenje značajnih računalnih resursa u zahtjevnoj obradi podataka. Računarstvo s visokom učinkovitošću (engl. *high-performance computing* - HPC) grana je računarstva koja se bavi znanstvenim i inženjerskim zadacima koji su računalno toliko zahtjevni da se izračun ne može obaviti uz pomoć računala opće namjene. Strojevi koji se upotrebljavaju u HPC-u često se nazivaju superračunalima. Računalni klasteri sastoje se od više međusobno povezanih računala koja pomoći softwarea funkcioniraju poput jednog superračunala. Proces

učenja za ovo istraživanje proveden je na računalnom klasteru "Isabella". Klaster je razvijen 2002. godine s ciljem da koristi računarstvo s visokom učinkovitošću (HPC) za obrazovanje. Isabella se sastoji od 135 radnih čvorova s 3100 procesorskih jezgri, 12 GPU-a i 756 TiB podatkovnog prostora.


## 4.5 Okvir za simulaciju rada EES-a i RL

Predloženi programski okvir za obuku RL agenata za upravljanje elektroenergetskim sustavom prikazan je na slici 4.3 . U njemu su integrirani svi gore navedene alati i okviri. Procedura za integraciju Grid2Op-a sa standardnim okvirom za podržano učenje sastoji se od sljedećih koraka:

1. Stvoriti Grid2Op okoliš.
2. Pretvoriti Grid2Op okoliš u gym okoliš.
3. Koristiti standardne RL algoritam iz RLLib-a za obuku agenta.

Koraci za pokretanje integriranog okvira na HPC klasteru su:

1. Napraviti virtualno okruženje na klasteru sa svim potrebnim python modulima.
2. Kopirati podatke o pogonskim stanjima za elektroenergetsku mrežu na klasteru.
3. Pripremiti python skriptu za učenje RL agenta.
4. Pripremiti skriptu za pokretanje posla.



Slika 4.3: Programski okvir za simulaciju rada EES-a i podržano učenje [57]

# Poglavlje 5


## Opis testne mreže

U ovom poglavlju opisat će se korištena testna mreža i za nju dostupna pogonska stanja. Za početak će se opisati elementi mreže, a zatim analizirati pogonska stanja pripremljena za promatrano testnu mrežu. Zatim će se prikazati komponente okvira podržanog učenja za promatrani problem vođenja elektroenergetskog sustava uz primjenu podržanog učenja.

### 5.1 Testna mreža IEEE-14 čvorista

Modificirani testni sustav IEEE-14 čvorista prikazan na slici 5.1 odabran je za procjenu performansi RL agenta za sigurno upravljanje elektroenergetskom mrežom u značajno poremećenim radnim uvjetima. U odnosu na izvornu mrežu IEEE-14 čvorista, sinkroni kompenzatori zamijenjeni su generatorima. Promjena je izvedena kako bi se postojeća proizvodnja proširila obnovljivim izvorima, koji u današnjim mrežama zauzimaju sve veći udio u ukupnoj proizvodnji EES-a. Model mreže uključuje 14 sabirnica, 20 grana, 11 tereta i 6 generatora. Proizvodnja uključuje hidroelektranu, nuklearnu elektranu, termoelektranu, vjetroelektranu i dvije solarne elektrane čime je izvorna test mreža prilagođena sadašnjim stvarnim mrežama. Model električne mreže dostupan je pod imenom “l2rpn\_case14\_sandbox” u python modulu Grid2Op [52]. Uz ovaj modul dolazi i skup podataka koji predstavlja realnu vremensku seriju pogonskih stanja. Skup podataka za testni sustav IEEE-14 čvorista sadrži 1004 mjesečna scenarija od kojih svaki predstavlja 28 kontinuiranih dana u vremenskim intervalima od 5 minuta. Svaki scenarij uključuje unaprijed definirane varijacije opterećenja i rasporede proizvodnje, prikazane na slikama 5.2a i 5.2b. Varijacije opterećenja i proizvodnje odabrane su tako da predstavljaju opterećenje tipičnih zimskih mjeseci u francuskom energetskom sustavu, za koje se bilježe maksimalna


opterećenja [51].




**Slika 5.1:** Modificirana IEEE-14 čvorišta testna mreža.

## 5.2 Analiza pogonskih stanja

Za daljnju analizu i istraživanje koriste se arhivski zapisi pogonskih stanja za promatrano mrežu pod imenom "l2rpn\_case14\_sandbox" dostupni u sklopu Grid2Op [52]. U ovom poglavlju analiziraju se sadržaji arhivskih zapisa o stanjima mreže. U sljedećim analizama, preopterećenjem grane u mreži smatra se opterećenje grane iznad 95% zadane termičke granice. Prva provedena analiza je analiza rada dispečera koji ne intervenira bez obzira na stanje mreže. Ovom analizom se prvenstveno želi utvrditi koliko dugo se može očekivati da mreža vodi sama sebe, odnosno da ne dođe do raspada sustava za dane scenarije. Rezultati navedene analize prikazani su pomoću histograma grafa na slici 5.3. Na x osi su prikazani rasponi vremenskih koraka u kojima je mreža uspješno vođena, a na y osi je broj mjesecnih zapisa koji su povezani s pojedinim rasponom. Prosječni broj vremenskih koraka u kojima je uspješno vođena mreža za sve promatrane mjesecne zapise iznosi oko 1089, odnosno 90.75 sati ili manje od 4 dana (3.8). Minimalni broj vremenskih koraka u kojima je mreža uspješno vođena prije raspada je 3 te je ovakav slučaj zabilježen za 9 mjesecnih zapisa. Maksimalni broj vremenskih koraka u kojima je mreža uspješno vođena je 8064 (odnosno cijeli mjesec) te je ovakav slučaj zabilježen kod tri mjesecna zapisa.




**Slika 5.2:** Mjesečni dijagram proizvodnje (a) i potrošnje (b).




**Slika 5.3:** Broj scenarija s pridruženim rasponom vremenskih koraka bez djelovanja dispečera prije raspada sustava.

Kako bi se analizirali svi dostupni podaci unutar svakog mjesecnog zapisa stanja mreže, odnosno kako bi se prošlo kroz sve vremenske korake za koje su dostupni podaci o mreži, pravila i ograničenja prilikom simulacije rada EES-a postavljena su tako da ne isključuju preopterećene grane. Ovako postavljenim parametrima osigurava se prolazak kroz sve vremenske korake unutar svakog mjeseca. Nakon održenih simulacija u kojoj mrežu ne vodi dispečer i s parametrima postavljenim kako su opisani, rezultati analize govore koje probleme inicijalno možemo susresti u mreži. Učestalost pojave preopterećenja u analiziranim scenarijima prikazan je u postotnom iznosu vremenskih trenutaka koji su preopterećeni za svaki mjesec na slici 5.4. Maksimalni iznosi preopterećenja za svaki mjesec prikazani su na slici 5.5. Odnos učestalosti pojave preopterećenja unutar jednog mjeseca te iznos maksimalnog zabilježenog preopterećenja za promatrani mjesec prikazan je na slici 5.6.


Za zadana stanja mreže i bez intervencije dispečera, bilježe se preopterećenja po granama: 4, 7, 9 i 17. Najveći broj preopterećenja bilježi se na granama 9 i 17, dok su rjeđe preopterećene grane 4 i 7. Prosječan broj preopterećenja grane 9 po mjesecu je 421 vremenski korak, odnosno, nešto više od 35 sati ili oko jedan i pol dan. Prosječan broj preopterećenja grane 17 je 394 vremenska koraka, odnosno nešto manje od 33 sata.



**Slika 5.4:** Postotak preopterećenih vremenskih koraka za svaki mjesec



**Slika 5.5:** Maksimalni iznosi preopterećenja za svaki mjesec



**Slika 5.6:** Odnos maksimalnog iznosa preopterećenja i postotka vremenskih koraka u kojima su se dogodila preopterećenja za svaki mjesec

## 5.3 Model mreže predstavljen elementima podržanog učenja

U ovom poglavlju opisat će se detaljno svi elementi promatranog problema vođenja elektroenergetskog sustava sa stajališta primjene podržanog učenja. Prikazat će se komponente okvira podržanog učenja u sklopu ovog problema. Opisat će se način kreiranja okoliša s parametrima i ograničenjima povezanim sa simulacijom rada EES-a, način na koji se informacije o stanju EES-a prikazuju unutar modela RL-a te način na koji se predstavljaju akcije. Sve navedeno se odnosi na dostupne mogućnosti prilikom korištenja alata Grid2Op [52].

### 5.3.1 Okoliš

Prilikom kreiranja okoliša mogu se zadati određeni parametri koji definiraju pravila i ograničenja simulacije rada EES-a. Pomoću navedenih parametara simulacija rada se želi približiti stvarnim uvjetima rada EES-a. Pravila i ograničenja koja se uzimaju u obzir prilikom simulacija su vezana uz mogućnost odabira akcija, djelovanje zaštite na preopterećenja grana i sigurnosna pravila rada sustava.

Neželjena stanja koja dovode do proglašenja raspada sustava prilikom simulacije rada EES-a su stanja u kojima dolazi do:

- isklju čenja tereta
- isklju čenja generatora
- izoliranja dijela mreže
- divergencije prora čuna tokova snaga
- raspada sustava uslijed kaskadnih ispada.

Pravila povezana uz preopterećenja grana u mreži povezana su s termičkim granicama grana.

Grana u mreži je preopterećena kad je snaga grane veća od dozvoljene termičke snage grane. Termička ograničenja za sve grane u promatranoj mreži su zadane i prikazane u tablici 5.1. Ako je grana jako preopterećena (iznad 200% termičke granice) tada se ona automatski isključuje. Ako je preopterećenje grane manje, onda grana može biti u 2 uzastopna vremenska koraka preopterećena nakon čega se automatski isključuje. Između dva vremenska trenutka može se napraviti akcija nad jednom granom, jednom sabirnicom ili kombinacija navedene dvije akcije.

**Tablica 5.1:** Termičke granice grana

Grana	Termička granica [A]	Grana	Termička granica [A]
0	541	10	442
1	450	11	641
2	375	12	840
3	636	13	156
4	175	14	664
5	285	15	235
6	335	16	119
7	657	17	179
8	496	18	1986
9	827	19	1572

### 5.3.2 Prostor opažanja

Prostor opažanja (engl. *observation space*) pronalazi se iz okoliša te ga koristi agent. Detaljan opis značajki kojima je opisan prostor opažanja prikazan je u tablici 5.2. Sadrži brojne informacije o mreži, između ostalog podatke o trenutnoj proizvodnji, potrošnji, tokovima po granama i topologiji mreže. U promatranom slučaju, relevantne informacije o stanju sustava dobivaju se opisom 11 značajki. Tip podataka i veličina za svaku od pojedinih značajki navedeni su u tablici

5.2. Tipovi podataka su cijeli brojevi, realni brojevi i logičke vrijednosti. Ukupno je dostupno 368 vrijednosti. Cilj je odabrati, odnosno koristiti one od kojih će se dobiti najviše informacija relevantnih za uspješno učenje agenta za vođenje EES-a.

### 5.3.3 Akcije

Akcije se odnose na radnje kojima se upravlja mrežom. U sklopu simulatora Grid2Op omogućene su slijedeće akcije kojima je cilj upravljati opterećenjima u mreži: promjena statusa uključenosti grane, sekcioniranje sabirnice i podešavanje proizvodnje generatora.

U sklopu ovog istraživanje koriste se isključivo akcije kojima se sekcioniraju sabirnice te se stoga ostale akcije neće ni opisivati. Za akcije vezane uz sabirnice, bitno je napomenuti da se u odnosu na osnovno stanje mreže sabirnice mogu sekcionirati na dvije sekcije. U promatranoj mreži je inicialno 14 sabirница, što znači da bi se sekcioniranjem sabirnica moglo doći do stanja mreže s 28 sabirnicama. Naredba za sekcioniranje sabirnica unutar simulatora Grid2Op "postavi sabirnicu" (engl. *set\_bus*) je naredba pomoću koje se postavlja element (grana, teret, generator) povezan na sabirnicu na sekciju 1, sekciju 2 ili se ne mijenja trenutna povezanost elementa. Analizirana mreža ima 14 čvorišta i 20 grana. Broj elemenata spojenih na svaku od sabirnica i broj jedinstvenih kombinacija prilikom sekcioniranja svake od sabirnica navedeni su u tablici 5.3. Broj različitih kombinacija sekcioniranja sabirnica određen je brojem elemenata spojenih na sabirnicu i brojem mogućih sekcija. U promatranom slučaju sabirnicu je moguće podijeliti na 2 sekcije te se broj mogućih kombinacija sekcioniranja određuje prema  $2^{n-1}$ , pri čemu je  $n$  broj elemenata spojenih na promatranu sabirnicu, a  $-1$  u eksponentu dolazi zbog simetričnosti kombinacija.

Klasa akcije predstavlja način na koji agent stupa u interakciju s okolišom. Može se predstaviti ili kao objekt ili kao vektor. Za promatranu mrežu od 14 čvorišta prikaz vektora akcija sadrži 160 komponenti za svaku akciju. Prilikom učenja neuronske mreže, učenje mreže da odbire akcije predstavljene pomoću vektora bi bilo gotovo nemoguće. Zbog navedenog razloga koristi se konverter akcija kako bi se olakšalo učenje mapiranjem akcija pomoću cijelih brojeva jedinstvenih za svaku akciju. Time neuronska mreža na izlazu daje cijeli broj, a konverter navedeni broj prevodi u odgovarajući vektor akcije.

**Tablica 5.2:** Detaljan opis značajki kojima je opisano stanje okoliša

Značajka	Naziv	Tip	Veličina	Opis
Datum	'year' 'month' 'day' 'hour_of_day' 'minute_of_hour' 'day_of_week'	int	6	Vremenska oznaka.
Radna snaga	'gen_p' 'load_p' 'p_or' 'p_ex'	float	57	Iznos radne snage.
Jalova snaga	'gen_q' 'load_q' 'q_or' 'q_ex'	float	57	Iznos jalove snage.
Napon	'gen_v' 'load_v' 'v_or' 'v_ex'	float	57	Iznos napona.
Struja	'a_or' 'a_ex'	float	40	Iznos struje.
Postotno opterećenje grane	'rho'	float	20	Kapacitet grane definiran kao omjer između trenutne struje grane i termičke granice.
Vektor topološke konfiguracije	'topo_vect'	int	57	Vektor koji za svaki element u mreži (teret, generator, grane) označava na koju je sekciju spojen.
Status grana	'line_status'	bool	20	Logička oznaka statusa uključenosti grana.
Broj uzastopnih preopterećenja	'timestep_overflow'	int	20	Broj uzastopnih vremenskih koraka u kojima se dogodilo preopterećenje.
Broj vremenskih koraka prije ponovnog djelovanja na sabirnice	'time_before_cooldown_sub'	int	14	Oznaka broja vremenskih trenutaka za svaku sabirnicu prije nego što je opet dopušteno djelovanje na istu.
Broj vremenskih koraka prije ponovnog djelovanja na grane	'time_before_cooldown_line'	int	20	Oznaka broja vremenskih trenutaka za svaku granu prije nego što je opet dopušteno djelovanje na istu.

**Tablica 5.3:** Broj jedinstvenih kombinacija prilikom sekcijoniranja svake od sabirnica

Sabirnica	Broj elemenata	Kombinacije	Sabirnica	Broj elemenata	Kombinacije
0	3	4	7 <sup>1</sup>	2	-
1	6	32	8	5	16
2	4	8	9	3	4
3	6	32	10	3	4
4	5	16	11	3	4
5	7	64	12	4	8
6	3	4	13	3	4
Ukupno kombinacija					200

<sup>1</sup> Navedenu sabirnicu nije moguće sekcijonirati jer je na nju spojen jedan vod i generator.

### 5.3.4 Nagrada

Osim akcijskog prostora i prostora opažanja, potrebno je još dotaknuti se nagrada. U sklopu simulatora Grid2Op postoji nekoliko predefiniranih nagrada, ali i postoji mogućnost definiranja vlastite nagrade. Neke od predefiniranih nagrada u sklopu simulatora su: *L2RPNReward*, *IncreasingFlatReward* i *DistanceReward*. *IncreasingFlatReward* se temelji na broju vremenskih koraka u kojima je agent uspješno vodio mrežu, odnosno na broju vremenskih koraka prije nego što je došlo do raspada sustava. *L2RPNReward* se temelji na preostalom kapacitetu grana u mreži. *DistanceReward* se temelji na razlici topologije mreže u odnosu na inicijalnu topologiju.

U vođenju elektroenergetskog sustava postoji mnogo zadataka. Pravilno projektiran i upravljan elektroenergetski sustav treba zadovoljiti zahtjev pouzdanosti koji se sastoji od dvije komponente: adekvatnosti napajanja i sigurnosti prijenosa. Siguran rad elektroenergetske infrastrukture vrlo je važan za gospodarstvo. Trošak većih nestanaka struje je ogroman, u ljudskom i finansijskom smislu. Stoga je održavanje pouzdanosti elektroenergetskog sustava uvijek najvažniji cilj planiranja i rada elektroenergetskog sustava. Nakon što je ovaj zahtjev zadovoljen, možemo govoriti o optimizaciji nekih drugih ograničenja, ali optimizacija ne smije dovesti do narušavanja pouzdanosti prijenosa. Dakle, može se reći da svaka funkcija cilja u upravljanju elektroenergetskim sustavom implicitno mora imati funkciju cilja pouzdanosti. Stoga se kao početna nagrada u ovom istraživanju uzima *IncreasingFlatReward*.

# Poglavlje 6

## Algoritam odabira topologije sabirnica

Sekcioniranjem sabirnica, odnosno promjenom topologije mreže, želi se utjecati na povoljniju raspodjelu tokova snaga u mreži kako bi se spriječila preopterećenja grana i kaskadni ispad. U normalnim uvjetima, kada nema preopterećenja u mreži, većina ovih akcija neće pogoršati stanje mreže, odnosno u kontekstu podržanog učenja, većina akcija će imati sličnu vrijednost pripadajuće nagrade zbog čega će RL model loše učiti. Stoga je odabran pristup u kojem će se uzimajući u obzir stvarna ograničenja u radu EES-a i rezultate proračuna za analizu rada EES-a odabrati manji broj mogućih akcija s ciljem boljeg i bržeg učenja RL agenta.

U ovom poglavlju će se prikazati algoritam odabira topologija sabirnica, odnosno u terminima podržanog učenja, algoritam odabira akcija. Cilj sužavanja akcijskog prostora, odnosno mogućih topologija u mreži je bolje učenje i rad RL modela. Navedenu proceduru moguće je primijeniti na bilo koju elektroenergetsku mrežu. Početne pretpostavke su:

- 1.inicijalna topologija mreže ne sadrži sekcionirane sabirnice
- 2.sabirnica se može sekcionirati na dvije sabirnice
- 3.u jednom vremenskom trenutku može se postaviti topologija (sekcionirati) samo jedne sabirnice.

Broj jedinstvenih akcija prilikom sekcioniranja svake od sabirnica promatrane testne mreže prikazan je u tablici 5.3 te iznosi 200. Sabirnicu je prema navedenim pretpostavkama moguće podijeliti na 2 sekcije te se broj mogućih kombinacija sekcioniranja u tom slučaju određuje prema  $2^{n-1}$ , pri čemu je  $n$  broj elemenata spojenih na promatranu sabirnicu, a  $-1$  u eksponentu dolazi zbog simetričnosti kombinacija. Za odabranu mrežu od samo 14 sabirnica navedeni broj mogućih kombinacija je previelik za uspješno učenje algoritma podržanog učenja te taj problem sve više dolazi do izražaja kod mreža s većim brojem sabirnica i većim brojem elemenata mreže

spojenih na sabirnice.

**(Korak 1)** Kao prvi korak u redukciji akcijskog prostora odabrana je procedura izbacivanja neželjenih akcija sa stajališta zahtjeva vođenja elektroenergetskog sustava. Kako je težnja da pogon EES-a bude pouzdan te da je potražnja za električnom energijom pravovremeno zadovljena, žele se spriječiti slučajevi u kojima se djelovanjem na topologiju mreže isključuju generatori ili tereti. Broj takvih kombinacija topologija određuje se prema  $2^B - 1$ , pri čemu je  $B$  broj generatora i tereta spojenih na promatranu sabirnicu. Određivanje broja neželjenih kombinacija prikazano je u tablici 6.1. Za promatranu mrežu prikazanu na slici 5.1 broj neželjenih akcija u kontekstu isključenja generatora ili tereta iznosi 22. Nakon primjene redukcije, trenutni broj ukupnih kombinacija promjena topologija iznosi 178.

**Tablica 6.1:** Broj neželjenih kombinacija prilikom sekcioniranja svake od sabirnica

Sabirnica	Broj generatora i tereta	Kombinacije	Sabirnica	Broj generatora i tereta	Kombinacije
0	1	1	7	1	-
1	2	3	8	1	1
2	2	3	9	1	1
3	1	1	10	1	1
4	1	1	11	1	1
5	3	7	12	1	1
6	0	0	13	1	1
Ukupno kombinacija					22

**(Korak 2)** U drugom koraku se razmatra primjena pravila i ograničenja analize sigurnosti  $n - 1$ . Žele se izbjegći slučajevi u kojima su tereti ili generatori spojeni radikalno te slučajevi u kojima su grane mreže u praznom hodu. Zbog navedene težnje za postizanjem sigurnosti poldona, odabiru se samo sabirnice na koje su spojene barem 4 grane te se iz navedenog skupa u obzir uzimaju samo akcije čijim su sekcioniranjem na svakoj sabirnici spojene barem 2 grane. Ovo osigurava da ako dođe do ispada jedne grane zbog nepredviđene situacije, postojat će još jedan put za spajanje ove sabirnice na mrežu. Zbog specifičnosti promatrane mreže ne razmatra se sabirnica 8 koja je dio tronamotnog transformatora. Primjenom navedenog ograničenja, akcijski skup se reducira na 66 akcija.

**(Korak 3)** U trećem koraku se ukupan broj promatralih akcija reducira s ciljem da se zadrže

samo one kombinacije koje generatore zadržavaju na inicijalno spojenim sabirnicama. Razlog tome su potencijalni problemi s naponskom i frekvencijskom sigurnosti u mreži prilikom prespajanja generatora na novu sekciju. U ovom koraku ostaju 42 kombinacije za razmatranje, a opis promatranih akcija može se pronaći u dodatku A. Akcije od 1 do 7 odnose se na postavljanje topologije sabirnice 1. Akcije od 8 do 28 odnose se na postavljanje topologije sabirnice 3. Akcije od 29 do 35 odnose se na sekcioniranje sabirnice 4. Akcije od 36 do 42 odnose se na sekcioniranje sabirnice 5.

**(Korak 4)** U trenutnom skupu akcija nalaze se akcije koje prema prethodno navedenim pravilima sekcioniraju sabirnice 1, 3, 4 i 5. Unutar promatranog skupa nalaze se akcije u kojima agent postavlja inicijalnu topologiju sabirnica 1, 3, 4 i 5 u kojoj su svi elementi promatrane sabirnice spojeni na jednu, početnu sabirnicu. Primjenom navedene četiri akcije na osnovno uklopljeno stanje mreže, neće doći do promjene topologije. Nakon što se odaberu akcije, odnosno topologije sabirnica, treba voditi računa da se akcijskom skupu dodaju i pripadne akcije koje postavljaju inicijalnu topologiju sabirnica kako bi postajala mogućnost povratka uklopljenog stanja mreže u inicijalno stanje.

**(Korak 5)** Za odabrane promjene topologija provodi se analiza tokova snaga za osnovno stanje mreže. Proračunom tokova snaga utvrđuje se da djelovanje pojedinih akcija nije zadovoljavajuće jer proračun tokova snaga divergira ili promjene topologija uzrokuju preopterećenja u mreži. Navedene akcije su označene brojevima: 9, 10, 14, 16, 22, 37, 38, 39 i 40. Velik broj akcija koje su povezane sa sekcioniranjem sabirnice 5 nije zadovoljavajući već u inicijalnim analizama, stoga se dalje sekcioniranje sabirnice 5 ne razmatra. Nakon navedene redukcije, u ovom koraku akcijski skup čini 30 akcija.

**(Korak 6)** Za preostale akcije iz koraka (5) rade se analize osjetljivosti na temelju istosmjernog proračuna tokova snaga. Istosmjerni proračun tokova snaga odabran je jer se proučava problem zagušenja u mreži koja nastaju dominantnim utjecajem toka djelatne snage. Osim toga, istosmjernim proračunom se problem proračuna tokova snaga linearizira te se zbog toga znatno brže i jednostavnije provodi. Primjenjuje se analiza osjetljivosti temeljena na istosmjernom proračunu tokova snaga opisana u poglavlju 2.3.2, a rezultati provedene analize nazivaju se PTDF faktori.

Promatraju se PTDF faktori za kritične grane 9 (između čvorišta 5 i 12) i 17 (između čvorišta 4 i 5) koje su prema analizi pogonskih stanja iz poglavlja 5.2 najčešće preopterećene. PTDF faktori izračunati na temelju istosmjernog proračuna tokova snaga ne ovise o pogonskom stanju,

već samo o topologiji mreže. Na taj način možemo vidjeti kako promjena topologije mijenja utjecaj injekcije snage u čvorištima mreže na tokove snaga po granama mreže. Prvenstveno se promatraju sabirnice u kojima su spojeni generatori (1, 2, 5 i 7) uz napomenu da je čvorište 0 referentno čvorište. Rezultati analize osjetljivosti prikazani su u tablicama 6.2- 6.9. Prva akcija u svakoj od navedenih tablica odgovara inicijalnoj topologiji promatrane sabirnice, odnosno topologiji sabirnice u kojoj su svi elementi spojeni na jednu sekciju.

**Tablica 6.2:** PTDF faktori za granu 9 i odabrane akcije sekcioniranja sabirnice 1

Sabirnica	akcija_1	akcija_2	akcija_3	akcija_4	akcija_5	akcija_6	akcija_7
1	-0.0047	-0.0072	-0.0072	0.0079	0.0079	-0.0553	-0.0553
2	-0.0179	-0.0186	-0.0186	-0.0095	-0.0095	-0.0553	-0.0553
5	-0.6714	-0.6729	-0.6729	-0.6661	-0.6661	-0.6917	-0.6917
7	-0.2004	-0.2019	-0.2019	-0.1953	-0.1953	-0.2248	-0.2248

**Tablica 6.3:** PTDF faktori za granu 17 i odabrane akcije sekcioniranja sabirnice 1

Sabirnica	akcija_1	akcija_2	akcija_3	akcija_4	akcija_5	akcija_6	akcija_7
1	-0.0014	-0.0022	-0.0022	0.0024	0.0024	-0.0171	-0.0171
2	-0.0056	-0.0057	-0.0057	-0.0029	-0.0029	-0.0171	-0.0171
5	0.1017	0.1012	0.1012	0.1033	0.1033	0.0954	0.0954
7	-0.0620	-0.0625	-0.0625	-0.0604	-0.0604	-0.0695	-0.0695

Na temelju rezultata analize osjetljivosti odabiru se akcije koje promjenom topologije mreže utječu na povoljniju raspodjelu tokova snaga u mreži. U kontekstu promatranog problema pre-opterećenja grana 9 i 17, odabiru se topologije mreže koje utječu na smanjenje toka snage kritičnih grana u ovisnosti o proizvodnji promatranih generatorskih čvorišta.

Analizom PTDF faktora za razmatrane topologije sabirnice 1, koji su prikazani u tablicama 6.2 i 6.3, odabiru se najpovoljnije topologije. Akcija u prvom stupcu odgovara inicijalnoj topologiji sabirnice te se PTDF faktori ostalih topologija ocjenjuju prema inicijalnim PTDF faktorima. Najpovoljnije topologije sabirnice 1, prema rezultatima analize osjetljivosti, su topologije koje se dobiju akcijama 6 i 7 jer su njihovi PTDF faktori najmanji u odnosi na inicijalnu topologiju. To znači da će za isto pogonsko stanje u mreži, grane 9 i 17 biti manje opterećene ako je sabirnica 1 sekcionirana prema načinu postavljanja topologije akcije 6 ili 7.

**Tablica 6.4:** PTDF faktori za granu 9 i odabrane akcije sekcioniranja sabirnice 3 - dio I

Sabirnica	akcija_8	akcija_11	akcija_12	akcija_13	akcija_15	akcija_17	akcija_18	akcija_19
1	-0.0047	-0.0146	-0.0146	-0.0094	0.0000	-0.0077	-0.0077	-0.0096
2	-0.0179	-0.0559	-0.0559	-0.0360	0.0000	-0.0730	-0.0730	-0.1094
5	-0.6714	-0.6520	-0.6520	-0.6574	-0.6917	-0.6717	-0.6717	-0.6892
7	-0.2004	-0.2237	-0.2237	-0.1848	-0.2248	-0.2031	-0.2031	-0.2987

**Tablica 6.5:** PTDF faktori za granu 9 i odabrane akcije sekcioniranja sabirnice 3 - dio II

Sabirnica	akcija_20	akcija_21	akcija_23	akcija_24	akcija_25	akcija_26	akcija_27	akcija_28
1	-0.0096	-0.0130	-0.0182	-0.0182	-0.0121	-0.0121	-0.0087	-0.0087
2	-0.1094	-0.1836	0.0236	0.0236	0.0033	0.0033	-0.0071	-0.0071
5	-0.6892	-0.7486	-0.6920	-0.6920	-0.6658	-0.6658	-0.6622	-0.6622
7	-0.2987	-0.4421	-0.3295	-0.3295	-0.2464	-0.2464	-0.1908	-0.1908

**Tablica 6.6:** PTDF faktori za granu 17 i odabrane akcije sekcioniranja sabirnice 3 - dio I

Sabirnica	akcija_8	akcija_11	akcija_12	akcija_13	akcija_15	akcija_17	akcija_18	akcija_19
1	-0.0015	-0.0045	-0.0045	-0.0029	0.0000	-0.0024	-0.0024	-0.0030
2	-0.0056	-0.0173	-0.0173	-0.0111	0.0000	-0.0226	-0.0226	-0.0338
5	0.1017	0.1077	0.1077	0.1060	0.0954	0.1016	0.1016	0.0962
7	-0.0620	-0.0692	-0.0692	-0.0572	-0.0695	-0.0629	-0.0629	-0.0924

**Tablica 6.7:** PTDF faktori za granu 17 i odabrane akcije sekcioniranja sabirnice 3 - dio II

Sabirnica	akcija_20	akcija_21	akcija_23	akcija_24	akcija_25	akcija_26	akcija_27	akcija_28
1	-0.0030	-0.0040	-0.0056	-0.0056	-0.0038	-0.0038	-0.0027	-0.0027
2	-0.0338	-0.0568	0.0073	0.0073	0.0010	0.0010	-0.0022	-0.0022
5	0.0962	0.0778	0.0953	0.0953	0.1034	0.1034	0.1045	0.1045
7	-0.0924	-0.1368	-0.1019	-0.1019	-0.0762	-0.0762	-0.0590	-0.0590

Tablica 6.8: PTDF faktori za granu 9 i odabrane akcije sekcioniranja sabirnice 4

Sabirnica	akcija_29	akcija_30	akcija_31	akcija_32	akcija_33	akcija_34	akcija_35
1	-0.0047	0.0000	0.0000	0.0162	0.0162	-0.0548	-0.0548
2	-0.0179	0.0000	0.0000	-0.0315	-0.0315	-0.0931	-0.0931
5	-0.6714	-0.6365	-0.6365	-0.5671	-0.5671	-0.5756	-0.5756
7	-0.2004	-0.1695	-0.1695	-0.2044	-0.2044	-0.2458	-0.2458

Tablica 6.9: PTDF faktori za granu 17 i odabrane akcije sekcioniranja sabirnice 4

Sabirnica	akcija_29	akcija_30	akcija_31	akcija_32	akcija_33	akcija_34	akcija_35
1	-0.0015	0.0000	0.0000	0.0050	0.0050	-0.0170	-0.0170
2	-0.0056	0.0000	0.0000	-0.0097	-0.0097	-0.0288	-0.0288
5	0.1017	0.1125	0.1125	0.1339	0.1339	0.1313	0.1313
7	-0.0620	-0.0524	-0.0524	-0.0632	-0.0632	-0.0760	-0.0760

Analizom PTDF faktora za razmatrane topologije sabirnice 4, koji su prikazani u tablicama 6.8 i 6.9, odabiru se najpovoljnije topologije. Akcija u prvom stupcu odgovara inicijalnoj topologiji sabirnice te se PTDF faktori ostalih topologija ocjenjuju prema inicijalnim PTDF faktorima. Najpovoljnije topologije sabirnice 4, prema rezultatima analize osjetljivosti, su topologije koje se dobiju akcijama 34 i 35 jer su njihovi PTDF faktori najmanji u odnosi na inicijalnu topologiju. To znači da će za isto pogonsko stanje u mreži, grane 9 i 17 biti manje opterećene ako je sabirnica 1 sekpcionirana prema načinu postavljanja topologije akcije 34 ili 35.

Analizom PTDF faktora za razmatrane topologije sabirnice 3, koji su prikazani u tablicama tablicama 6.4- 6.7 ne dobivaju se očigledna rješenja kao u slučajevima sekpcioniranja sabirnica 1 i 4. Razlog tome je specifičnost promatrane testne mreže, odnosno načina modeliranja tronatomog transformatora u istoj. Za odabir željenih topologija sabirnice 3 provode se proračuni tokova snaga za karakteristične pogonske scenarije.

**(Korak 7)** Kako bi se konačno odabrale akcije, odnosno topologije, najpodobnije za upravljanje zagušenjima u promatranoj mreži i pripadnim pogonskim scenarijima, provode se proračuni tokova snaga. Kako se za sabirnice 1 i 4, analizom osjetljivosti iz prethodnog koraka, dobiju po dvije topologije s istim faktorima PTDF, proračunom tokova snaga određuje se koja topologija konačno odabire. Na temelju proračuna tokova snaga, konačno su odabrane akcija 7 i akcija 34.

Za topologije sabirnice 3 provode se detaljnije analize proračuna tokova snaga. Odabiru se različiti pogonski scenariji te se konačno odabiru akcije 12, 24 i 26.

**(Korak 8)** Na kraju se popisu akcija dodaje akcija koja odgovara akciji u kojoj agent ne poduzima ništa. Konačni popis akcija te njihov utjecaj na rekonfiguraciju sabirnica prikazan je na slici 6.1.

Akcija	Topologija
Akcija 1	
Akcija 2	
Akcija 3	
Akcija 4	
Akcija 5	
Akcija 6	Inicijalna topologija sabirnice 3
Akcija 7	Inicijalna topologija sabirnice 4
Akcija 8	Inicijalna topologija sabirnice 1
Akcija 9	Ne radi ništa

Slika 6.1: Odabране topologije sabirnica na temelju navedenog algoritma

# Poglavlje 7

## Autonomni model vođenja EES-a temeljen na podržanom učenju


U ovom poglavlju će se prikazati rezultati istraživanja. U prvom dijelu detaljno će se opisati i shematski prikazati razvijeni RL model autonomnog dispečera. Prikazat će se faza obuke i rezultati treninga u usporedbi s nekoliko RL algoritama. Rezultati testiranja i evaluacije agenta prikazat će se na 100 neviđenih scenarija. Demonstrirat će se način rada autonomnog dispečera i analizirati prilagodljivosti nakon primjene podržanog učenja. Prikazat će se djelovanje agenta za različite uvjete u mreži. Za kraj će se navesti poznata ograničenja ovog pristupa te prikladna rješenja. U drugom dijelu poglavlja opisat će se karakteristike i prednosti razvijenog okvira za simulaciju rada elektroenergetskog sustava i podržanog učenja opisanog u poglavlju 4.

### 7.1 RL model

U ovom poglavlju će se opisati konačni predloženi RL model proizašao iz ovog istraživanja koji je predstavljen u radu [58]. Za početak će se opisati arhitektura i hiperparametri modela.

Zbog prirode odabranog prostora opažanja i akcija koji su diskretni, kao i zbog jednostavnosti algoritma, za ovo istraživanje odabrani su DQN algoritam i njegove izvedenice. Duboki algoritam Q mreže i njegove izvedenice korišteni u istraživanju su iz standardne RL biblioteke RLlib [59]. Odabrani algoritmi implementiraju sva DQN poboljšanja predstavljena u [22]. DQN okvir razvijen u sklopu ovog istraživanja prikazan je na slici 7.1. Među izvedenicama DQN-a, algoritam s najboljom izvedbom je algoritam dvostrukе dualne duboke Q mreže s prioritetnim ponavljanjem iskustava i on se koristi u ovom istraživanju. Prostor opažanja je

opis električne mreže koju percipira agent. Prostor opažanja sa svim dostupnim značajkama u jednom vremenskom koraku ima 368 značajki kao što je prikazano u tablici 5.2. U sklopu istraživanja, prostor opažanja je reducirani s ciljem da sadrži samo najrelevantnije informacije potrebne RL agentu za učenje. Primijenjena je redukcija na prostor opažanja, tako da konačno sadrži iznose napona i struja na obje strane grana, postotno opterećenje grana i vektor topologije koji za svaki objekt (teret, generator, krajevi dalekovoda) daje informaciju na koju je sabirnicu ovaj objekt spojen u svojoj transformatorskoj stanici. Reducirani prostor opažanja sadrži 157 značajki, a odabrane značajke podebljane su u tablici 5.2. Ulazni sloj neuronske mreže kod RL modela sa slike 7.1 ima veličinu prostora opažanja, odnosno 157. Veličina izlaznog sloja odgovara veličini akcijskog prostora te iznosi 9. Redukcija akcijskog prostora napravljena je prema algoritmu iz poglavlja 6. Neuronska mreža ima i dva skrivena sloja, svaki sa 128 neurona. Korištena je jednostavna funkcija nagrađivanja koja broji vremenske korake u kojima je agent uspješno vodio mrežu te dodaje stalnu nagradu za svaki uspješno obrađen vremenski korak.



Slika 7.1: Konačni okvir podržanog učenja [58]

Na temelju brojnih ispitivanja utvrđene su vrijednosti hiperparametara RL modela [58]. Hiperparametri korišteni u ovom istraživanju za obuku RL agenta temelje se na zadanim vrijednostima parametara u Ray RLLib-u za odabrani DQN algoritam, osim hiperparametara koji su

podešeni kako je navedeno u tablici 7.1.

**Tablica 7.1:** Hiperparametri RL modela [58]


Hiperparametar	Naziv hiperparametra u RLlib-u	Vrijednost
Skriveni slojevi neuronske mreže	model_fcnet_hiddens	[128,128]
Aktivacijska funkcija	model_fcnet_activation	relu
Broj radnika	num_workers	4
Početak učenja	learning_start	5000
Veličina serije podataka kod učenja	train_batch_size	64
Frekvencija ažuriranja ciljne mreže	target_network_update_freq	256
Krivulja stope učenja	learning_rate_schedule	$lr_{start} = 10 \times 10^{-5}$ $lr_{end} = 10 \times 10^{-6}$ $lr\_time = 100000$
Stope istraživanja	exploration	$initial\_epsilon = 0.4$ $final\_epsilon = 1/2016$ $epsilon\_timesteps = 100000$

U nastavku poglavlja analizira se izvedba predloženog pristupa. Prvo je prikazana faza obuke i rezultati za nekoliko agenata temeljenih na različitim algoritmima. Drugo, evaluacija agenta prikazana je na 100 neviđenih scenarija. Proces testiranja opisan je kako bi se pokazalo da upotreba predloženog RL agenta za kontrolu mreže dovodi do znatno poboljšanih performansi. Provedena je usporedba rezultata s dostupnim agentima iz literature koji se bave istim problemom kako bi se ilustrirala prednost predloženog pristupa. Treće, prikazana je učinkovitost predloženog agenta za odabранe pogonske scenarije mreže s različitim izazovima i udjelima proizvodnje iz obnovljivih izvora energije. Četvrto, prikazana su poznata ograničenja predloženog pristupa.

### 7.1.1 Trening

Epizoda je slijed koji sadrži podatke o prostoru opažanja, odabranoj akciji i pripadnoj nagradi od početnog stanja do završnog stanja unutar mjesecnog zapisa, pri čemu je krajnje stanje ili trenutak u kojem je došlo da raspada sustava ili trenutak u kojem je uspješno završen mjesecni scenarij tijekom treniranja modela. Za fazu obuke korišten je skup od 800 scenarija dostupnih


iz skupa podataka za modificiranu IEEE-14 čvorišta mrežu korištenu u istraživanju, preuzeti iz [52]. Prosječna duljina epizode prati se tijekom treninga jer je glavna zadaća agenta upravljati električnom mrežom što je duže moguće. Duljina epizode mjeri se u vremenskim koracima koji predstavljaju 5 minutne intervale. Tijekom treninga je korištena tehnika ranog zaustavljanja (engl. *early stopping*) za prekid treninga kada je učinak agenta zadovoljavajući. Zbog prirode odabranih tipova prostora opažanja i akcija (oba diskretna) i jednostavnosti algoritma, DQN i njegove izvedenice odabrani su za analizu. Trening je proveden u trajanju od 1000 epizoda, a rezultati su na slici 7.2. DQN algoritmi razmatrani u ovom radu dostupni su u paketu RLlib pod nazivom DQN, dvostruki DQN (na slici Double DQN), dualni DQN (na slici Dueling DQN), dvostruki dualni DQN (na slici Double Dueling DQN) i dvostruki dualni DQN s prioritetskim ponavljanjem (na slici Prioritized DDDQN). Prema rezultatima, DDDQN s prioritetskim ponavljanjem ima najbolju izvedbu, pa su daljnje analize provedene koristeći taj algoritam.



Slika 7.2: Usporedba konvergencije odabranih RL algoritama prilikom učenja upravljanjem tokova snaga u EES-u [58]

Slika 7.3 prikazuje napredak treninga odabranog agenta temeljnog na PDDDDQN algoritmu podržanog učenja za nekoliko prostora opažanja. Žuta krivulja predstavlja konačnog agenta čija će se izvedba ocjenjivati u neviđenim scenarijima. U ovom slučaju obuka je trajala 1096

epizoda. U usporedbi s ostalim agentima, odabrani agent može kontrolirati elektroenergetsku mrežu dulje vrijeme (veći broj vremenskih koraka) u ranijim fazama procesa obuke. Promatrania metrika agenata monotono raste, što ukazuje da agent uči. Naučenom agentu je dodana heuristika kojom je određeno da agent djeluje samo u situacijama kada je tok snage određene grane u mreži veći od zadano praga (u ovom slučaju 95% termičke granice) i kada topologija elektroenergetske mreže nije optimalna.




Slika 7.3: Usporedba konvergencije odabranog RL algoritma za nekoliko odabralih prostora opažanja [58]

### 7.1.2 Evaluacija

Za procjenu agenta upotrebljeno je 100 scenarija koji nisu korišteni u fazi obuke kako bismo vidjeli kako bi se agent ponašao u neviđenim scenarijima. Rezultati evaluacije predloženog RL agenta uspoređuju se s agentom koji ne radi ništa (engl. *Do Nothing agent*). Rezultat testa prikazan je na slici 7.4. Rezultati za agenta koji ne radi ništa pokazuju da će priključeni obnovljivi izvori energije dovesti do velikog preopterećenja u elektroenergetskom sustavu ako se ne poduzmu nikakve kontrolne mjere. U tom slučaju, u prosjeku će doći do raspada sustava za oko 1528 vremenskih koraka (oko 5 dana). Korištenje predloženog RL agenta za upravljanje tokovima snaga u EES-u dovodi do znatnih poboljšanja. Za sve scenarije, predloženi RL

agent automatski upravlja elektroenergetskom mrežom dulje od jednog dana (288 vremenskih koraka) bez stručne pomoći. Za samo 11 scenarija upravlja mrežom manje od tjedan dana i za 62 scenarija uspješno upravlja mrežom kroz cijeli mjesec (8064, maksimalan broj vremenskih koraka). U prosjeku uspješno upravlja elektroenergetskom mrežom 6574 vremenska koraka, odnosno gotovo 23 dana (28 je maksimalni broj dana u mjesecnim zapisima).



**Slika 7.4:** Rezultati evaluacije RL agenta na 100 testnih scenarija [58]

Za relevantnu usporedbu, predloženi agent je uspoređen s agentima iz literature koji imaju za cilj kontrolirati mrežu IEEE-14 čvorišta samo topološkim akcijama i/ili koriste isti RL algoritam (Double Dueling DQN). Pojedinosti za promatrane agente iz literature i rezultati predloženog agenta iz ovog istraživanja sažeti su u tablici 7.2. Osim puno duljeg vremena u kojem uspješno upravlja elektroenergetskom mrežom, predloženi pristup je puno jednostavniji jer ne zahtijeva dodatne tehnike učenja. Prostori opažanja i akcijski prostor su znatno smanjeni u odnosu na ostala relevantna rješenja iz dostupne literature. Neuronska mreža predloženog agenta sadrži puno manje komponenti u odnosu na ostala dostupna rješenja.

Predloženi RL agent upravlja mrežom tako da određuje optimalnu topologiju elektroenergetske mreže i postavlja je na početku epizode kako bi se spriječili kaskadni ispad i raspad elektroenergetskog sustava. RL agent je naučio da početna topologija mreže nije optimalna i da se optimalna topologija može postaviti kombinacijom akcija 3 i 5 sa slike 6.1. Postavljanje optimalne topologije na početku epizode učinilo je kontrolu elektroenergetskog sustava puno

**Tablica 7.2:** Pregled prikazanih pristupa iz literature i usporedba s predloženim RL sredstvom u ovom istraživanju

Algoritam	Dodatak na učenje	Topološke akcije	Akcijski prostor	Prostor opažanja	Vrsta i arhitektura neuronske mreže	Vrijeme koje je RL agent sposoban autonomno voditi mrežu
metoda unakrsne entropije (engl. <i>cross-entropy method</i> ) [48]	uzorkovanje po važnosti (engl. <i>importance sampling</i> )	sekcioniranje sabirnica	112	324	Unaprijedna mreža (engl. <i>feed-forward</i> ) [324; 300; 300; 112]	do jednog dana
DDDQN [50]	prethodna obuka pomoću strojnog učenja i vođeno istraživanje	sekcioniranje sabirnica i promjena statusa uključenosti grana	251	538	Unaprijedna mreža (engl. <i>feed-forward</i> ) [538; 256; 128; 251; 251]	288 vremenskih koraka (1dan)
DDDQN [51]	neuronske mreže na grafovima (eng. <i>graph neural network</i> - GNN)	sekcioniranje sabirnica	160	194	sloj umetanja (engl. <i>embedding layer</i> ) koji se sastoji od 6 GNN blokova i DDDQN iz literature [50] [538; 256; 128; 251; 251]	ne puno bolje od agenta koji ne poduzima ništa (scenariji za trening od 3 dana)
PDDQN [58]	-	sekcioniranje sabirnica	9	157	Unaprijedna mreža (engl. <i>feed-forward</i> ) [157; 128; 128; 9]	do jednog mjeseca (nikada manje od jednog dana)

lakšom jer slijed radnji donošenja odluka mnogo je kraći u uvjetima poremećenog pogona. Ovaj pristup pripada kontroli na razini sustava i uzima u obzir samo modificiranje konfiguracije sabirnica. Kontrola je dizajnirana za rad u normalnim radnim stanjima sustava i primjenjuje radnje upravljanja tokovima snaga u mreži.

### 7.1.3 Učinkovitost


Kako bi se u potpunosti procijenila izvedba predloženog RL agenta, odabrana su četiri scenarija s različitim udjelom obnovljivih izvora prikazanih na slici 7.5. Slučajevi 2 i 3 imaju slične energetske profile proizvodnje, ali slučaj 3 je zanimljiv jer dolazi do raspada sustava nakon trećeg vremenskog koraka (za 15 minuta) ako se ništa ne poduzme. Slučaj 4 je zanimljiv zbog većeg udjela energije iz obnovljivih izvora, gdje energija vjetra i sunca čine gotovo 20% ukupne proizvodnje.

Za demonstraciju rada i prilagodljivosti RL agenta, istražuje se učinak kontrole agenta za svaki odabrani scenarij. Budući da je cilj agenta kontrola tokova snaga u mreži kako bi se spriječili kaskadni ispad i raspad sustava, razmatra se maksimalno opterećenje grana. Bilježi se maksimalno opterećenje grana za odabrane slučajeve. Napravljena je usporedba između agenta koji ne radi ništa i predloženog RL agenta iz ovog istraživanja. Kao što je prikazano na slikama 7.6 i 7.7, u svim je slučajevima predloženi RL agent duže kontrolirao mrežu i smanjio maksimalno opterećenje grana od agenta koji nije radio ništa. Slučaj 3 bio je vrlo izazovan jer se preopterećenje dogodilo na početku mjesecnog scenarija i agent je morao brzo reagirati kako bi eliminirao preopterećenje i spriječio raspad sustava. Ovo pokazuje prilagodljivost predložene metode kontrole i mogućnost brzog djelovanja RL agenta.


### 7.1.4 Ograničenja prikazanog pristupa

Na kraju poglavlja s rezultatima istraživanja bitno je naglasiti ograničenja predloženog pristupa primjene podržanog učenja u vođenju elektroenergetskog sustava. Ograničenje predložene metode je ograničenje RL algoritma korištenog u ovom istraživanju. DQN algoritmi podržavaju samo diskretne akcije. To znači da buduća proširenja s kontinuiranim radnjama, kao što je redispečing generatora, treba provoditi pažljivo. U slučaju da se akcijski prostor predloženog pristupa želi proširiti s akcijama povezanim s promjenom proizvodnje generatora, prethodno navedeno ograničenje predloženog modela bi se moglo ublažiti tako da se kontinuirane akcije pretvore u diskretne akcije. Kontinuirane značajke u tom slučaju trebaju podvrgnuti tehnikama


grupiranja koje svrstavaju kontinuirane vrijednosti u diskretne segmente, čime se kontinuirane značajke diskretiziraju.



**Slika 7.5:** Profili proizvodnje za odabrane scenarije.




(a) Učinak RL agenta za scenarij 1.




(b) Učinak RL agenta za scenarij 2.

**Slika 7.6:** Maksimalna opterećenja grana za odabrane scenarije 1 i 2 pri djelovanju RL agenta (crveno) i agenta koji ne poduzima ništa (plavo)



(a) Učinak RL agenta za scenarij 3.



(b) Učinak RL agenta za scenarij 4.

**Slika 7.7:** Maksimalna opterećenja grana za odabrane scenarije 3 i 4 pri djelovanju RL agenta (crveno) i agenta koji ne poduzima ništa (plavo)

## 7.2 Karakteristike predloženog okvira za simulaciju EES-a i primjenu RL-a

U ovom poglavlju će se prikazati karakteristike i prednosti okruženja za simulaciju rada elektroenergetskog sustava i podržano učenje koje je razvijeno u sklopu ovog istraživanja. Opis arhitekture predloženog okvira i korištenih alata prikazan je u poglavlju 4 te objavljen u radu [57].

Simulator elektroenergetskih mreža Grid2Op i RL modul Ray integrirani su kako je prikazano na slici 3.1 te predloženi okvir može poslužiti kao okvir za daljnja istraživanja složenijih zadataka upravljanja elektroenergetskim sustavom uz korištenje širokog spektra najsuvremenijih RL algoritama. Nakon što je aplikacija postavljena kako je predloženo u poglavlju 4.5, lako je promijeniti algoritme koji su analizirani na slici 7.2. Razmatrani RL algoritmi iz standardnog RL okvira RLlib čine rezultate lako ponovljivim i provjerljivim.


Također, integracija s modulom Ray nudi jednostavan način korištenja za skaliranje koda za trening na klaster u samo nekoliko redaka koda, što učenje čini značajno bržim. DQN je obično računalno i memorijski zahtjevan algoritam, tako da njegovo skaliranje na klaster može značajno smanjiti vrijeme učenja. Nakon što je aplikacija postavljena kao što je prikazano na slici 3.1, jednostavno se pokreće na HPC klasteru. Paralelizacija treninga postaje jednostavna upotrebom Ray-a, koji omogućuje konfiguriranje algoritma putem jednog parametra. Efekt paralelizacije analizira se za korištenje nekoliko radnika (engl. *workers*). Ovaj hiperparametar određuje koliko se paralelnih poslova može izvršavati u isto vrijeme, a time utječe na brzinu izvršavanja zadatka. Broj radnika treba odabrati prema broju raspoloživih računalnih resursa (CPU). Rezultati odabrane analize nalaze se u tablici 7.3.

**Tablica 7.3:** Brzina učenja odabranog RL algoritma bez paralelizacije i za odabране stupnjeve paralelizacije [57]

Broj radnika	Vrijeme trajanja učenja	Smanjenje vremena učenja
0	11:37:42	-
2	06:10:35	47%
3	04:30:54	61%
4	03:35:03	69%

Smanjenje vremena trajanja treninga je značajno. Trajanje treninga RL agenta sa zadanim


konfiguracijom algoritma (`num_workers = 0`) za 1000 epizoda treninga je 11 sati i 37 minuta, dok je trajanje treninga s 2 paralelna radnika skoro prepolovilo vrijeme treninga. Konačno, trening odabranog RL algoritma s 4 paralelna procesa traje 3 sata i 35 minuta što je smanjilo vrijeme učenja za 69% u usporedbi s osnovnim slučajem. Iako je povećanje broja radnika iznad 4 dovelo do daljnog ubrzanja obuke, ti slučajevi nisu uzeti u obzir jer je učinak agenta tada počeo padati. Slika 7.8 prikazuje krivulje učenja za promatrane agente i pokazuje da konvergencija nije narušena za paralelizirane agente.



**Slika 7.8:** Usporedba konvergencije odabralih RL algoritama prilikom učenja upravljanjem tokova snaga u EES-u [57]

Ray међудјелује с Ray Tune-ом, алатом за distribuirano podešavanje hiperparametara. Hiperparametar je параметар тренинга постављен пре учења модела и не учи га модел стручног учења током процеса тренинга. Примери хипер параметара су величина серије, стопа учења, број слова, број нерона, итд. Да би се добио модел с најбољом изведбом, који има најбољу способност generalizације (изведба на невиђеним подацима), потребно је оптимално подесити хипер параметре. За подесавање хипер параметара користи се модул Ray Tune. Резултати неких експеримената угађања приказани су на слици 7.9 помоћу TensorBoard-а. TensorBoard је скуп веб апликација које пружају визуализацију експеримената стручног учења. Хипер параметри

promatrani u ovoj analizi su aktivacijska funkcija, učestalost ažuriranja ciljne mreže i veličina serije za trening. Cilj podešavanja hiperparametra je postizanje što veće srednje duljine trajanja epizode jer ona predstavlja učinkovitost rada modela. Najbolja kombinacija parametara u ovom eksperimentu označena je zelenom bojom na slici 7.9.



Slika 7.9: Ugađanje hiperparametara u pralalelnom koordinatnom prikazu iz TensorBoard-a [57]

# Poglavlje 8

## Zaključak

Jedan od glavnih ciljeva vođenja elektroenergetskog sustava je pouzdano napajanje električnom energijom svih potrošača i to na ekonomičan način. U posljednje vrijeme elektroenergetski sustav bilježi značajne promjene u svojoj strukturi i načinu rada uslijed kojih dolazi do promjena i dodatnih poteškoća i u samom vođenju EES-a. Broj aktivnih upravljačkih točaka prilikom vođenja EES-a postaje sve veći te se zbog navedenih razloga intenzivno istražuje primjena algoritama koji mogu autonomno i brzo donositi odluke te time pomoći dispečerima u nepredviđenim situacijama.

Područje vođenja sustava koje je u fokusu istraživanja predmetnog rada je kontrola tokova snage kako bi se spriječila zagušenja u mreži i posljedično kaskadni ispadи elemenata te u najgorem slučaju raspad sustava. Tehnička metoda koja je odabrana za primjenu je promjena topologije mreže sekcioniranjem sabirnica. Navedena tehnička metoda je odabrana jer spada u skupinu metoda za sprječavanja zagušenja u mreži bez dodatnih operativnih troškova i zbog toga što potencijal primjene te metode nije dovoljno istražen u literaturi.

Kako bi razvijeni model upravljanja tokovima snaga imao brzi odziv prilikom donošenja odluka te sposobnost automatskog učenja iz podataka, u istraživanju su korišteni algoritmi strojnog učenja. Točnije, odabrani su algoritmi podržanog učenja zbog njihove glavne karakteristike, a to je da agent uči strategiju odabira akcije kroz interakciju s okolišem. Agent koji odabire akcije ne zna unaprijed koje radnje treba poduzeti, već ih sam treba otkriti na temelju pokušaja i pogrešaka te pripadnih nagrada. Potencijal ovih algoritama potvrđuju njihove uspješne primjene u robotici, autonomnoj navigaciji, učenju kontrolnih strategija, igranju računalnih igrica.

Preduvjet za istraživanje primjene podržanog učenja u vođenju EES-a je programski okvir koji sadrži simulator rada EES-a te proširenje za implementaciju podržanog učenja. Predlo-

ženi okvir izrađen u sklopu ovog istraživanja opisan je u poglavlju 4. Okvir implementira alate otvorenog programskog koda na način da simulator EES-a prilagođava primjeni širokog raspona najsuvremenijih RL algoritama iz standardnih biblioteka koje se koriste u tom području. Kako su RL aplikacije računalno i memorijski vrlo zahtjevne, predloženo okruženje je izrađeno vodeći računa o tome da je moguće izvođenje na računalima s visokom učinkovitostu (HPC) koja se danas popularno nazivaju superračunalima. Prethodno navedena karakteristika predloženog okruženja, koja se odnosi na mogućnost skaliranja RL algoritama na HPC klastere, pruža mogućnost za drugu vrlo bitnu karakteristiku, a to je paralelizacija učenja kojom se vrijeme potrebno za učenje agenta može bitno smanjiti.

Sljedeća stavka o kojoj je nužno voditi računa prilikom ove vrste istraživanja je testna mreža i za nju pripremljeni pogonski scenariji. U poglavlju 5 detaljno je opisana i prikazana korištena modificirana mreža IEEE-14 čvoršta. Analizom pogonskih stanja za navedenu testnu mrežu, identificirani su problemi koji se pojavljuju prilikom vođenja iste, a to su preopterećenja grana koja dovode do kaskadnih ispada i raspada sustava ako se ne poduzmu potrebne mjere. Osim opisa mreže sa stajališta elektroenergetike, mreža je predstavljena elementima podržanog učenja te su prikazana pravila i ograničenja koja se uzimaju u obzir prilikom simuliranja rada EES-a.

Preliminarni rezultati istraživanja primjene RL-a za vođenje EES-a nisu dali zadovoljavajuće rezultate zbog toga što je problem sekcioniranja sabirnica vrlo zahtjevan. U normalnim uvjetima, kada nema preopterećenja u mreži, većina akcija povezanih s promjenom topologije sekcioniranjem sabirnica ima sličnu vrijednost pripadajuće nagrade zbog čega rezultati učenja RL modela nisu zadovoljavajući. Stoga je u poglavlju 6 prikazan algoritam u kojem se reducira broj mogućih promjena topologija s ciljem boljeg i bržeg učenja RL agenta uzimajući u obzir stvarna ograničenja u radu EES-a i rezultate proračuna za analizu rada EES-a.

U poglavlju 7 su prikazani rezultati istraživanja koji potvrđuju potencijal primjene predloženih metoda iz ovog rada. Prikazan je razvijeni RL model uz detaljan opis svih njegovih komponenti: odabrani RL algoritam, opis strukture korištene neuronske mreže te iznosi hiperparametara. Rezultati treninga prikazuju kriterij odabira korištenog algoritma dvostrukе dualne duboke Q mreže s prioritetskim ponavljanjem iskustva (engl. *Double Dueling DQN with prioritized replay*). Za evaluaciju predloženog RL agenta korišteno je 100 neviđenih scenarija te je rad RL agenta uspoređen sa sličnim agentima iz dostupne literature. Osim puno duljeg vremena u kojem uspješno upravlja elektroenergetskom mrežom, predloženi pristup je puno jednostavniji jer ne zahtijeva dodatne tehnike učenja te su prostori opažanja i akcijski prostor znatno smanjeni

u odnosu na ostala relevantna rješenja iz dostupne literature. Demonstracijom rada autonomnog RL dispečera za odabrane pogonske scenarije s različitim udjelom obnovljivih izvora prikazana je učinkovitost predloženog RL agenta i mogućnost prilagodljivosti nakon primjene podržanog učenja.

Rad se zaključuje osvrtom na perspektivu praktične primjene razvijenog autonomnog RL modela za vođenje EES-a, za čiji je razvoj potrebno imati odgovarajuće programsko okruženje za simulaciju rada EES-a i primjenu algoritama podržanog učenja. U tom segmentu potrebno je u predloženo okruženje, prikazano na slici 4.3, integrirati neki od standardnih alata za simulaciju rada EES-a koji mora imati odgovarajući modul proširenja za pozivanje programskim jezikom (u ovom slučaju python). Prilikom integracije, potrebno je mrežu ispravno predstaviti pomoću svih osnovnih elemenata podržanog učenja (okoliš, prostor opažanja, akcije, nagrada) kako bi se mogle koristiti sve prednosti predloženog okvira. Također, potrebno je imati model stvarne promatrane mreže i pripadne pogonske scenarije. Implementacijom standardnih alata korištenih za analizu rada EES-a, okruženje za primjenu RL-a bi se moglo koristiti i za istraživanje primjene RL-a u drugim područjima vođenja EES-a, kao što su regulacija napona ili analiza dinamičkih pojava u EES-u. Osim promjena u programskom okruženju, predloženi RL model sa slike 7.1 za kontrolu tokova snaga u mreži mogao bi se proširiti i ostalim mjerama koje se koriste prilikom vođenja sustava, kao što su: promjena statusa uključenosti grana, promjena položaja regulacijskih preklopki i kuta zakreta transformatora, redispečing generatora, upravljanje FACTS uređajima. Unatoč tome što je u radu prikazan autonomni rad RL dispečera, u stvarnosti bi ovakav alat služio kao podrška dispečerima na način da bi RL algoritam predložio neku mjeru, a dispečer bi odredio hoće li je zaista primijeniti.

## **Dodatak A**

### **Opis analiziranih akcija**

Akcija 1

Postavi sabirnicu:

- Na sekciju 1 spoji granu s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 2 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 3 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 1]
- Na sekciju 1 spoji generator s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji teret s oznakom 0 [sabirnica 1]

Akcija 2

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 0 [sabirnica 1]
- Na sekciju 2 spoji granu s oznakom 2 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 3 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 1]
- Na sekciju 1 spoji generator s oznakom 0 [sabirnica 1]
- Na sekciju 2 spoji teret s oznakom [sabirnica 1]

Akcija 3

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 0 [sabirnica 1]
- Na sekciju 2 spoji granu s oznakom 2 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 3 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 1]

## Dodatak A. Opis analiziranih akcija

---

- Na sekciju 1 spoji generator s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji teret s oznakom 0 [sabirnica 1]

### Akcija 4

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 2 [sabirnica 1]
- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 1]
- Na sekciju 1 spoji generator s oznakom 0 [sabirnica 1]
- Na sekciju 2 spoji teret s oznakom [sabirnica 1]

### Akcija 5

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 2 [sabirnica 1]
- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 1]
- Na sekciju 1 spoji generator s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji teret s oznakom 0 [sabirnica 1]

### Akcija 6

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 2 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 3 [sabirnica 1]
- Na sekciju 2 spoji granu s oznakom 4 [sabirnica 1]
- Na sekciju 1 spoji generator s oznakom 0 [sabirnica 1]
- Na sekciju 2 spoji teret s oznakom [sabirnica 1]

### Akcija 7

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 2 [sabirnica 1]
- Na sekciju 1 spoji granu s oznakom 3 [sabirnica 1]
- Na sekciju 2 spoji granu s oznakom 4 [sabirnica 1]

## Dodatak A. Opis analiziranih akcija

---

- Na sekciju 1 spoji generator s oznakom 0 [sabirnica 1]
- Na sekciju 1 spoji teret s oznakom 0 [sabirnica 1]

### Akcija 8

Postavi sabirnicu:

- Na sekciju 1 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 9

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 10

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 11

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 15 [sabirnica 3]

## Dodatak A. Opis analiziranih akcija

---

- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 12

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 13

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 14

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 15

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]

## Dodatak A. Opis analiziranih akcija

---

- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 16

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 17

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 18

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 19

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]

## Dodatak A. Opis analiziranih akcija

---

- Na sekciju 2 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 20

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 21

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 22

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 23

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 15 [sabirnica 3]

## Dodatak A. Opis analiziranih akcija

---

- Na sekciju 2 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 24

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 25

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 26

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 27

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]

## Dodatak A. Opis analiziranih akcija

---

- Na sekciju 2 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 2 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 28

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 3 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 5 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 3]
- Na sekciju 1 spoji granu s oznakom 15 [sabirnica 3]
- Na sekciju 2 spoji granu s oznakom 16 [sabirnica 3]
- Na sekciju 1 spoji teret s oznakom 2 [sabirnica 3]

### Akcija 29

Postavi sabirnicu:

- Na sekciju 1 spoji granu s oznakom 1 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 4]
- Na sekciju 1 spoji teret s oznakom 3 [sabirnica 4]

### Akcija 30

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 1 [sabirnica 4]
- Na sekciju 2 spoji granu s oznakom 4 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 4]
- Na sekciju 2 spoji teret s oznakom 3 [sabirnica 4]

### Akcija 31

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 1 [sabirnica 4]
- Na sekciju 2 spoji granu s oznakom 4 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 4]
- Na sekciju 1 spoji teret s oznakom 3 [sabirnica 4]

### Akcija 32

## Dodatak A. Opis analiziranih akcija

---

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 1 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 4]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 4]
- Na sekciju 2 spoji teret s oznakom 3 [sabirnica 4]

Akcija 33

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 1 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 4]
- Na sekciju 2 spoji granu s oznakom 6 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 4]
- Na sekciju 1 spoji teret s oznakom 3 [sabirnica 4]

Akcija 34

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 1 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 4]
- Na sekciju 2 spoji granu s oznakom 17 [sabirnica 4]
- Na sekciju 2 spoji teret s oznakom 3 [sabirnica 4]

Akcija 35

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 1 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 4 [sabirnica 4]
- Na sekciju 1 spoji granu s oznakom 6 [sabirnica 4]
- Na sekciju 2 spoji granu s oznakom 17 [sabirnica 4]
- Na sekciju 1 spoji teret s oznakom 3 [sabirnica 4]

Akcija 36

Postavi sabirnicu:

- Na sekciju 1 spoji granu s oznakom 7 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 8 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 9 [sabirnica 5]

## Dodatak A. Opis analiziranih akcija

---

- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 2 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 3 [sabirnica 5]
- Na sekciju 1 spoji teret s oznakom 4 [sabirnica 5]

Akcija 37

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 7 [sabirnica 5]
- Na sekciju 2 spoji granu s oznakom 8 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 9 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 2 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 3 [sabirnica 5]
- Na sekciju 2 spoji teret s oznakom 4 [sabirnica 5]

Akcija 38

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 7 [sabirnica 5]
- Na sekciju 2 spoji granu s oznakom 8 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 9 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 2 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 3 [sabirnica 5]
- Na sekciju 1 spoji teret s oznakom 4 [sabirnica 5]

Akcija 39

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 7 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 8 [sabirnica 5]
- Na sekciju 2 spoji granu s oznakom 9 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 2 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 3 [sabirnica 5]
- Na sekciju 2 spoji teret s oznakom 4 [sabirnica 5]

Akcija 40

## Dodatak A. Opis analiziranih akcija

---

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 7 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 8 [sabirnica 5]
- Na sekciju 2 spoji granu s oznakom 9 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 17 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 2 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 3 [sabirnica 5]
- Na sekciju 1 spoji teret s oznakom 4 [sabirnica 5]

Akcija 41

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 7 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 8 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 9 [sabirnica 5]
- Na sekciju 2 spoji granu s oznakom 17 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 2 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 3 [sabirnica 5]
- Na sekciju 2 spoji teret s oznakom 4 [sabirnica 5]

Akcija 42

Postavi sabirnicu:

- Na sekciju 2 spoji granu s oznakom 7 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 8 [sabirnica 5]
- Na sekciju 1 spoji granu s oznakom 9 [sabirnica 5]
- Na sekciju 2 spoji granu s oznakom 17 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 2 [sabirnica 5]
- Na sekciju 1 spoji generator s oznakom 3 [sabirnica 5]
- Na sekciju 1 spoji teret s oznakom 4 [sabirnica 5]

# Literatura

- [1]Alpaydın, E., Introduction to Machine Learning. London: The MIT Press, 2014.
- [2]Sutton, R. S., Barto, A. G., Reinforcement Learning: An Introduction. The MIT Press, 2018.
- [3]Hrvatski operator prijenosnog sustava d.o.o., "Mrežna pravila prijenosnog sustava", dostupno na: [https://narodne-novine.nn.hr/clanci/sluzbeni/full/2017\\_07\\_67\\_1585.html](https://narodne-novine.nn.hr/clanci/sluzbeni/full/2017_07_67_1585.html) 2017.
- [4]Handschin, E., Petroianu, A., Energy Management Systems: Operation and Control of Electric Energy Transmission Systems, Kassakian, J. G., Naunin, D. H., (ur.). Berlin: Springer-Verlag, 1991.
- [5]Brosinsky, C., Westermann, D., Krebs, R., "Recent and prospective developments in power system control centers: Adapting the digital twin technology for application in power system control centers", 2018 IEEE International Energy Conference, ENER-GYCON 2018, 2018, str. 1–6.
- [6]Vaahedi, E., Practical Power System Operation. Wiley-IEEE Press, 2014.
- [7]Wu, F. F., Moslehi, K., Bose, A., "Power system control centers: Past, present, and future", Proceedings of the IEEE, Vol. 93, No. 11, 2005, str. 1890–1908.
- [8]Cigré Working Group D2.24, EMS for the 21 Century - System Requirements. CIGRE, 2011, dostupno na: <https://e-cigre.org/publication/452-ems-for-the-21st-century---system-requirements>
- [9]Massachusetts Institute of Technology, The Future of the Electric Grid: An Interdisciplinary MIT Study. Massachusetts Institute of Technology, 2011, dostupno na: <http://energy.mit.edu/wp-content/uploads/2011/12/MITEI-The-Future-of-the-Electric-Grid.pdf>

- [10] Astic, J. Y., Bareux, G., Buhagiar, T., Dussartre, M., Omont, N., De Longeaux, P., Jacquemart, Y., Meyer, B., Peyron, B., Saludjian, L., “Control center designs: New functions and challenges for the transmission system operator”, IEEE Power and Energy Magazine, Vol. 16, No. 2, 2018, str. 57–66.
- [11] Xin, Y., Zhang, B., Zhai, M., Li, Q., Zhou, H., “A smarter grid operation: New energy management systems in China”, IEEE Power and Energy Magazine, Vol. 16, No. 2, 2018, str. 36–45.
- [12] Ito, H., Hanai, K., Saito, N., Kojima, T., Yoshiyama, S., Fukui, S., “Electricity System Reform Requirements : A Novel Implementation Approach to Grid Management and Control”, IEEE Power and Energy Magazine, Vol. 16, No. 2, 2018, str. 46–56, dostupno na: <https://ieeexplore.ieee.org/document/8295074>
- [13] European Parliament and the Council, “Directive 2009/28/EC on the promotion of the use of energy from renewable sources and amending and subsequently repealing Directives 2001/77/EC and 2003/30/EC”, str. 16–62, 2009.
- [14] European Commission, “Directive (EU) 2018/2001 of the European Parliament and of the Council of 11 December 2018 on the promotion of the use of energy from renewable sources (recast)”, Official Journal of the European Union, Vol. 2018, No. L 328, 2018, str. 82–209.
- [15] European Commission, “Commission Regulation (EU) 2017/1485: Establishing a guideline on Electricity Transmission System Operation (SO GL)”, Official Journal of the European Union, Vol. L 220, No. 25 August 2017, 2017, str. 120, dostupno na: <http://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32017R1485&from=EN>
- [16] Gumpu, S., Pamulaparthy, B., Sharma, A., “Review of Congestion Management Methods from Conventional to Smart Grid Scenario”, International Journal of Emerging Electric Power Systems, Vol. 20, No. 3, 2019, str. 1–24.
- [17] Gómez-Expósito, A., Conejo, A. J., Cañizares, C., Electric energy systems: Analysis and operation. London: CRC Press, 2009.
- [18] Wood, A. J., Wollenberg, B. F., Sheblé, G. B., POWER GENERATION, OPERATION, AND CONTROL. New Jersey: Wiley, 2014.

- [19]Vasilev, I., Slater, D., Spacagna, G., Roelants, P., Zocca, V., Python Deep Learning. Packt publishing, 2019.
- [20]WATKINS, C. J., DAYAN, P., “Q-learning”, Machine Learning, Vol. 8, 1992, str. 279–292.
- [21]Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., Hassabis, D., “Human-level control through deep reinforcement learning”, Nature, Vol. 518, No. 7540, 2015, str. 529–533, dostupno na: <http://dx.doi.org/10.1038/nature14236>
- [22]Hessel, M., Modayil, J., van Hasselt, H., Schaul, T., Ostrovski, G., Dabney, W., Horgan, D., Piot, B., Azar, M., Silver, D., “Rainbow: Combining improvements in deep reinforcement learning”, Proceedings of the AAAI Conference on Artificial Intelligence, Vol. 32, No. 1, Apr. 2018, dostupno na: <https://ojs.aaai.org/index.php/AAAI/article/view/11796>
- [23]Hasselt, H., “Double q-learning”, Advances in Neural Information Processing Systems, Vol. 23, 2010, dostupno na: <https://proceedings.neurips.cc/paper/2010/file/091d584fcfed301b442654dd8c23b3fc9-Paper.pdf>
- [24]Wang, Z., Schaul, T., Hessel, M., Hasselt, H., Lanctot, M., Freitas, N., “Dueling network architectures for deep reinforcement learning”, Proceedings of The 33rd International Conference on Machine Learning, Vol. 48, 20–22 Jun 2016, str. 1995–2003, dostupno na: <https://proceedings.mlr.press/v48/wangf16.html>
- [25]Schaul, T., Quan, J., Antonoglou, I., Silver, D., “Prioritized experience replay”, 4th International Conference on Learning Representations, ICLR 2016 - Conference Track Proceedings, 2016.
- [26]Miraftabzadeh, S. M., Foiadelli, F., Longo, M., Pasetti, M., “A Survey of Machine Learning Applications for Power System Analytics”, in 2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe). Genova, Italy: IEEE, 2019, str. 1–5.
- [27]Pi, R., Cai, Y., Li, Y., Cao, Y., “Machine Learning Based on Bayes Networks to Predict the Cascading Failure Propagation”, IEEE Access, Vol. 6, 2018, str. 44 815–44 823.

- [28]Zhang, D., Han, X., Deng, C., “Review on the research and practice of deep learning and reinforcement learning in smart grids”, CSEE Journal of Power and Energy Systems, Vol. 4, No. 3, 2018, str. 362–370, dostupno na: <https://ieeexplore.ieee.org/document/8468674>
- [29]Zhang, Z., Zhang, D., Qiu, R. C., “Deep Reinforcement Learning for Power System: An Overview”, CSEE Journal of Power and Energy Systems ( Early Access ), 2019, dostupno na: <https://ieeexplore.ieee.org/document/8859593>
- [30]Cao, D., Hu, W., Zhao, J., Zhang, G., Zhang, B., Liu, Z., Chen, Z., Blaabjerg, F., “Reinforcement Learning and Its Applications in Modern Power and Energy Systems: A Review”, Journal of Modern Power Systems and Clean Energy, Vol. 8, No. 6, nov 2020, str. 1029–1042.
- [31]Yang, T., Zhao, L., Li, W., Zomaya, A. Y., “Reinforcement learning in sustainable energy and electric systems: a survey”, Annual Reviews in Control, Vol. 49, No. xxxx, 2020, str. 145–163.
- [32]Li, F., Du, Y., “From AlphaGo to Power System AI: What Engineers Can Learn from Solving the Most Complex Board Game”, IEEE Power and Energy Magazine, Vol. 16, No. 2, 2018, str. 76–84, dostupno na: <https://ieeexplore.ieee.org/document/8295075>
- [33]Shang, X. Y., Li, M. S., Ji, T. Y., Zhang, L. L., Wu, Q. H., “Discrete reactive power optimization considering safety margin by dimensional Q-learning”, in 2015 IEEE Innovative Smart Grid Technologies - Asia (ISGT ASIA). Bangkok, Thailand: IEEE, 2015, dostupno na: <https://ieeexplore.ieee.org/document/7386971>
- [34]Glavic, M., Fonteneau, R., Ernst, D., “Reinforcement Learning for Electric Power System Decision and Control: Past Considerations and Perspectives”, IFAC-PapersOnLine, 2017.
- [35]Xu, Y., Zhang, W., Liu, W., Ferrese, F., “Multiagent-based reinforcement learning for optimal reactive power dispatch”, IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews, Vol. 42, No. 6, 2012, str. 1742–1751, dostupno na: <https://ieeexplore.ieee.org/document/6392462>
- [36]Vlachogiannis, J. G., Hatziargyriou, N. D., “Reinforcement learning for reactive power

- control”, IEEE Transactions on Power Systems, Vol. 19, No. 3, 2004, str. 1317–1325, dostupno na: <https://ieeexplore.ieee.org/document/1318666>
- [37]Zarrabian, S., Belkacemi, R., Babalola, A. A., “Reinforcement learning approach for congestion management and cascading failure prevention with experimental application”, Electric Power Systems Research, Vol. 141, 2016, str. 179–190, dostupno na: <http://dx.doi.org/10.1016/j.epsr.2016.06.041>
- [38]Ye, D., Zhang, M., Sutanto, D., “A Hybrid Multiagent Framework With Q-Learning for Power Grid Systems Restoration”, IEEE Transactions on Power Systems, Vol. 26, No. 4, 2011, str. 2434–2441, dostupno na: <https://ieeexplore.ieee.org/document/5871714>
- [39]Diao, R., Wang, Z., Shi, D., Chang, Q., Duan, J., Zhang, X., “Autonomous Voltage Control for Grid Operation Using Deep Reinforcement Learning”, IEEE Power and Energy Society General Meeting, Vol. 2019-August, 2019.
- [40]Chen, X., Qu, G., Tang, Y., Low, S., Li, N., “Reinforcement Learning for Selective Key Applications in Power Systems: Recent Advances and Future Challenges”, IEEE Transactions on Smart Grid, Vol. 13, No. 4, 2022, str. 2935–2958.
- [41]Xu, Y., Zhang, W., Liu, W., Ferrese, F., “Multiagent-based reinforcement learning for optimal reactive power dispatch”, IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews, Vol. 42, No. 6, 2012, str. 1742–1751, dostupno na: <https://ieeexplore.ieee.org/document/6392462>
- [42]Jasmin, E. A., Imthias Ahamed, T. P., Jagathy Raj, V. P., “Reinforcement Learning approaches to Economic Dispatch problem”, International Journal of Electrical Power and Energy Systems, Vol. 33, No. 4, 2011, str. 836–845, dostupno na: <http://dx.doi.org/10.1016/j.ijepes.2010.12.008>
- [43]Li, D., Yu, L., Li, N., Lewis, F., “Virtual-Action-Based Coordinated Reinforcement Learning for Distributed Economic Dispatch”, IEEE Transactions on Power Systems, Vol. 36, No. 6, 2021, str. 5143–5152.
- [44]Duan, J., Shi, D., Diao, R., Li, H., Wang, Z., Zhang, B., Bian, D., Yi, Z., “Deep-Reinforcement-Learning-Based Autonomous Voltage Control for Power Grid Operations”, IEEE Transactions on Power Systems, Vol. 35, No. 1, 2019, str. 814–817.

- [45] Lukianykhin, O., Bogodorova, T., "Voltage control-based ancillary service using deep reinforcement learning", *Energies*, Vol. 14, No. 8, 2021, str. 1–22.
- [46] Lu, R., Hong, S. H., "Incentive-based demand response for smart grid with reinforcement learning and deep neural network", *Applied Energy*, Vol. 236, feb 2019, str. 937–949.
- [47] Zhang, X., Lu, R., Jiang, J., Hong, S. H., Song, W. S., "Testbed implementation of reinforcement learning-based demand response energy management system", *Applied Energy*, Vol. 297, No. January, 2021, str. 117131, dostupno na: <https://doi.org/10.1016/j.apenergy.2021.117131>
- [48] Subramanian, M., Viebahn, J., Tindemans, S. H., Donnot, B., Marot, A., "Exploring grid topology reconfiguration using a simple deep reinforcement learning approach", 2021 IEEE Madrid PowerTech, PowerTech 2021 - Conference Proceedings, 2021.
- [49] Lan, T., Duan, J., Zhang, B., Shi, D., Wang, Z., Diao, R., Zhang, X., "AI-based autonomous line flow control via topology adjustment for maximizing time-series ATCs", in IEEE Power and Energy Society General Meeting, Vol. 2020-Augus, 2020.
- [50] Yoon\*, D., Hong\*, S., Lee, B.-J., Kim, K.-E., "Winning the L2RPN Challenge: Power Grid Management via Semi-Markov Afterstate Actor-Critic", International Conference on Learning Representations (ICLR), 2021, str. 1–17, dostupno na: <https://openreview.net/forum?id=LmUJqB1Cz8>
- [51] Marot, A., Donnot, B., Romero, C., Donon, B., Lerousseau, M., Veyrin-Forrer, L., Guyon, I., "Learning to run a power network challenge for training topology controllers", *Electric Power Systems Research*, Vol. 189, dec 2020, str. 106635.
- [52] Donnot, B., "Grid2Op- A testbed platform to model sequential decision making in power systems.", <https://GitHub.com/rte-france/grid2op>, 2020.
- [53] "Grid2Operate", dostupno na: [https://l2rpn.chalearn.org/grid2operate#h.p\\_dX50ywFh9uoG](https://l2rpn.chalearn.org/grid2operate#h.p_dX50ywFh9uoG) (1. ožujka 2022.).
- [54] "OpenAI Gym", dostupno na: <https://github.com/openai/gym> (1. ožujka 2022.).
- [55] Brockman, G., Cheung, V., Pettersson, L., Schneider, J., Schulman, J., Tang, J., Zaremba, W., "OpenAI Gym", dostupno na: <http://arxiv.org/abs/1606.01540> 2016.

[56]“ray”, dostupno na: <https://github.com/ray-project/ray> (1. ožujka 2022.).

[57]Damjanović, I., Pavić, I., Brčić, M., Jerčić, R., “High performance computing reinforcement learning framework for power system control”, in 2023 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT). IEEE, 2023, str. 1–5.

[58]Damjanović, I., Pavić, I., Puljiz, M., Brećic, M., “Deep Reinforcement Learning-Based Approach for Autonomous Power Flow Control Using Only Topology Changes”, Energies 2022, Vol. 15, Page 6920, Vol. 15, No. 19, sep 2022, str. 6920, dostupno na: <https://www.mdpi.com/1996-1073/15/19/6920>

[59]Liang, E., Liaw, R., Moritz, P., Nishihara, R., Fox, R., Goldberg, K., Gonzalez, J. E., Jordan, M. I., Stoica, I., “RLlib: Abstractions for distributed reinforcement learning”, in 35th International Conference on Machine Learning, ICML 2018, Vol. 7, 2018, str. 4768–4780, dostupno na: <http://rllib.io>

# Popis slika

2.1. Stanja elektroenergetskog sustava [4] . . . . .	7
2.2. Shematski prikaz arhitekture modernih dispečerskih centara [5] . . . . .	8
2.3. EMS sustav s ekspertnom računalnom podrškom [4] . . . . .	10
2.4. Podjela mjera za sprječavanje i upravljanje zagušenjima u mreži [16] . . . . .	13
3.1. Okvir podržanog učenja [2] . . . . .	20
4.1. Arhitektura sustava Grid2Op - 1.dio [53] . . . . .	32
4.2. Arhitektura sustava Grid2Op - 2.dio [53] . . . . .	32
4.3. Programski okvir za simulaciju rada EES-a i podržano učenje [57] . . . . .	34
5.1. Modificirana IEEE-14 čvorišta testna mreža. . . . .	36
5.2. Mjesečni dijagram proizvodnje (a) i potrošnje (b). . . . .	37
5.3. Broj scenarija s pridruženim rasponom vremenskih koraka bez djelovanja dispečera prije raspada sustava. . . . .	38
5.4. Postotak preopterećenih vremenskih koraka za svaki mjesec . . . . .	39
5.5. Maksimalni iznosi preopterećenja za svaki mjesec . . . . .	39
5.6. Odnos maksimalnog iznosa preopterećenja i postotka vremenskih koraka u kojima su se dogodila preopterećenja za svaki mjesec . . . . .	40
6.1. Odabrane topologije sabirnica na temelju navedenog algoritma . . . . .	53
7.1. Konačni okvir podržanog učenja [58] . . . . .	55
7.2. Usporedba konvergencije odabranih RL algoritama prilikom učenja upravljanjem tokova snaga u EES-u [58] . . . . .	57
7.3. Usporedba konvergencije odabranog RL algoritama za nekoliko odabranih prostora opažanja [58] . . . . .	58

7.4.	Rezultati evaluacije RL agenta na 100 testnih scenarija [58] . . . . .	59
7.5.	Profili proizvodnje za odabrane scenarije. . . . .	62
7.6.	Maksimalna opterećenja grana za odabrane scenarije 1 i 2 pri djelovanju RL agenta (crveno) i agenta koji ne poduzima ništa (plavo) . . . . .	63
7.7.	Maksimalna opterećenja grana za odabrane scenarije 3 i 4 pri djelovanju RL agenta (crveno) i agenta koji ne poduzima ništa (plavo) . . . . .	64
7.8.	Usporedba konvergencije odabralih RL algoritama prilikom učenja upravlja- njem tokova snaga u EES-u [57] . . . . .	66
7.9.	Ugađanje hiperparametara u pralalelnom koordinatnom prikazu iz TensorBoard- a [57] . . . . .	67

# Popis tablica

5.1.	Termičke granice grana . . . . .	41
5.2.	Detaljan opis značajki kojima je opisano stanje okoliša . . . . .	43
5.3.	Broj jedinstvenih kombinacija prilikom sekcioniranja svake od sabirnica . . . . .	44
6.1.	Broj neželjenih kombinacija prilikom sekcioniranja svake od sabirnica . . . . .	46
6.2.	PTDF faktori za granu 9 i odabране akcije sekcioniranja sabirnice 1 . . . . .	48
6.3.	PTDF faktori za granu 17 i odabране akcije sekcioniranja sabirnice 1 . . . . .	48
6.4.	PTDF faktori za granu 9 i odabранe akcije sekcioniranja sabirnice 3 - dio I . .	49
6.5.	PTDF faktori za granu 9 i odabранe akcije sekcioniranja sabirnice 3 - dio II .	49
6.6.	PTDF faktori za granu 17 i odabранe akcije sekcioniranja sabirnice 3 - dio I .	50
6.7.	PTDF faktori za granu 17 i odabранe akcije sekcioniranja sabirnice 3 - dio II .	50
6.8.	PTDF faktori za granu 9 i odabранe akcije sekcioniranja sabirnice 4 . . . . .	51
6.9.	PTDF faktori za granu 17 i odabранe akcije sekcioniranja sabirnice 4 . . . . .	51
7.1.	Hiperparametri RL modela [58] . . . . .	56
7.2.	Pregled prikazanih pristupa iz literature i usporedba s predloženim RL sredstvom u ovom istraživanju . . . . .	60
7.3.	Brzina učenja odabranog RL algoritma bez paralelizacije i za odabranе stupnjeve paralelizacije [57] . . . . .	65

# **Životopis**

Ivana Damjanović rođena je 16. veljače 1994. godine. Sveučilišni preddiplomski i diplomski studij završila je 2015. godine, odnosno 2017. godine na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu, profil elektroenergetika. Od 2017. godine radi na Zavodu za visoki napon i energetiku Fakulteta elektrotehnike i računarstva Sveučilišta u Zagrebu. Od 2017. do 2018. godine radila je kao stručni suradnik, a od 2018. radi kao asistent. Na istom zavodu započela je doktorski studij 2018. godine. Njezina područja istraživanja su vođenje i analiza elektroenergetskog sustava, osobito u području kontrole tokova snaga, kontrole napona i kompenzacije jalove snage, analize sigurnosti, proračuna kratkog spoja, kvalitete električne energije i harmonijske analize. Do sada je objavila 4 rada u časopisima, 6 radova na konferencijama s međunarodnom recenzijom i 3 rada na domaćim konferencijama. Sudjelovala je u izradi više od 20 stručnih studija i elaborata. Članica je udruge CIGRE i IEEE.

## **Popis objavljenih djela**

### **Rad u časopisima**

- 1.Damjanović, I., Pavić, I., Puljiz, M., Brčić, M., "Deep Reinforcement Learning-Based Approach for Autonomous Power Flow Control Using Only Topology Changes", Energies 2022, Vol. 15, Page 6920, Vol. 15, No. 19, 2022, str. 6920, dostupno na:  
<https://www.mdpi.com/1996-1073/15/19/6920>
- 2.Damjanović, I., Tomašević, F., Pavić, I., Filipović-Grčić, B., Župan, A., "Harmonic Performance Analysis of Static Var Compensator Connected to the Power Transmission Network", Journal of Energy, 67 (2018), S.I.; 13-22.
- 3.Keitoue, S., Murat, I., Filipović-Grčić, B., Župan, A., Damjanović, I., Pavić, I., "Lightning caused overvoltages on power transformers recorded by on-line transient overvoltage monitoring system." Journal of Energy, 67 (2018), 2; 44-53.

- 4.Pavić, I., Tomašević, F., Damjanović, I., "Application of artificial neural networks for external network equivalent modeling.", Journal of Energy, 64 (2015), 275-284.

## Konferencijski radovi

- 1.Damjanović, I., Pavić, I., Brčić, M., Jerčić, R., "High performance computing reinforcement learning framework for power system control", in 2023 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT). IEEE, 2023, str. 1-5.
- 2.Filipovic-Grcic, B.; Damjanovic, I.; Zupan, A.; Jurisic, B.; Zupan, T., "Potential benefits of using controlled switching technique in 400 kV network for mitigation of switching overvoltages", SEERC 2021 - 3rd Conference of the South-East European Regional Council of CIGRE, Vienna, Austria, 2021.
- 3.Filipovic-Grcic, B.; Damjanovic, I.; Teklic, Lj.; Lasic, M.; Jurisic, B., "Model of Static Var Compensator Connected to the Power Transmission Network for Electromagnetic Transient Studies", SEERC 2021 - 3rd Conference of the South-East European Regional Council of CIGRE, Vienna, Austria, 2021.
- 4.Damjanović, I., Pavić, I., Filipović-Grčić, B., Duraković, I., "Vođenje elektroenergetskog sustava uz primjenu strojnog učenja", 14. CIGRE simpozij o vođenju EES-a, Opatija, Hrvatska, 2020.
- 5.Jerčić, R., Pavić, I., Damjanović, I., "New algorithm for identifying network topology based on artificial neural networks", 2nd International Colloquium on Smart Grid Metrology (SMAGRIMET), Split, Hrvatska, 2019.
- 6.Damjanović, I., Tomašević, F., Pavić, I., Filipović-Grčić, B., "Harmonijska analiza utjecaja SVC-a na prijenosnu mrežu", 13. CIGRE simpozij o sustavu vođenja EES-a, Rovinj, Hrvatska, 2018.
- 7.Damjanović, I., Tomašević, F., Pavić, I., Filipović-Grčić, B., Župan, A., "Harmonic Performance Analysis of Static Var Compensator Connected to the Power Transmission Network", SECOND SEERC CONFERENCE 2018: ENERGY TRANSITION AND INNOVATIONS IN ELECTRICITY SECTOR, Kyiv, Ukraine, 2018.
- 8.Keitoue, S., Murat, I., Filipović-Grčić, B., Župan, A., Damjanović, I., Pavić, I., "Lightning caused overvoltages on power transformers recorded by on-line transient overvoltage monitoring system", SECOND SEERC CONFERENCE 2018: ENERGY TRANSITION AND INNOVATIONS IN ELECTRICITY SECTOR, Kyiv, Ukraine, 2018.

9.Damjanović, I., Pavić, I., Tomašević, F., "Modeliranje visokonaponskih regulacijskih po-prečnih prigušnica", 13. Savjetovanje HRO CIGRE, 2017. Šibenik, Hrvatska, 2017.

# Biography

Ivana Damjanović was born on 16th February 1994. She received her B. Sc. and M. Sc. degrees in electrical engineering and information technology at the University of Zagreb, Faculty of Electrical Engineering and Computing (FER) in 2015, and 2017, respectively. Since 2017 she has been working with the Department of Energy and Power Systems at FER. From 2017 to 2018 she worked as a research associate, and from 2018 she has been working as a research assistant. She started her Ph.D. at the Faculty of Electrical Engineering and Computing in 2018. Her research interest includes power system analysis, operation, and control, especially in the fields of power flow control, voltage control, security analysis, short circuit calculations, power quality, and harmonic analysis. Her publications include 4 journal papers, 6 papers at international conferences, and 3 papers at a domestic conference. She worked on more than 20 technical studies. She is a member of the IEEE and CIGRÉ.