Utjecaj distribuirane proizvodnje električne energije na povećanje raspoloživosti napajanja u telekomunikacijskom i podatkovnom postrojenju

Talapko, Domagoj

Doctoral thesis / Disertacija

2020

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:168:062366

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repozitory







Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DOMAGOJ TALAPKO

UTJECAJ DISTRIBUIRANE PROIZVODNJE ELEKTRIČNE ENERGIJE NA POVEĆANJE RASPOLOŽIVOSTI NAPAJANJA U TELEKOMUNIKACIJSKOM I PODATKOVNOM POSTROJENJU

DOKTORSKI RAD

Mentor:
Prof. dr. sc. Sejid Tešnjak

Zagreb, 2020.



University of Zagreb
FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Domagoj Talapko

INFLUENCE OF DISTRIBUTED ELECTRICAL ENERGY PRODUCTION ON THE AVAILABILITY ENHANCEMENT IN TELECOMMUNICATION AND DATACENTER FACILITY

DOCTORAL THESIS

Supervisor:
Professor Sejid Tešnjak, PhD

Zagreb, 2020

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

Mentor: Prof. dr. sc. Sejid Tešnjak

Doktorski rad ima: 190 stranica

Doktorski rad br.:_____

O MENTORU

Dr.sc. Sejid Tešnjak rođen je 29. Kolovoza 1949. godine u Prnjavoru, gdje je završio osnovnu školu (1964.) i Gimnaziju (1968.). Diplomirao je na Elektrotehničkom fakultetu u Zagrebu, smjer Elektroenergetika, 1972. godine. Na istom fakultetu magistrirao je 1977. na smjeru Energetika s temom „Matematički model za potrebe upravljanja elektroenergetskim sistemom“, a doktorirao 1984. obranivši disertaciju pod naslovom „Teorijska i eksperimentalna analiza dinamike hidroelektrane“.

Od 1972. do 1978. radi kao asistent na grupi predmeta „Električna postrojenja“ u Zavodu za visoki napon Elektrotehničkog fakulteta u Zagrebu.

Honorarni je nastavnik (1975. - 1980.) na VTŠ „Rade Končar“ u Zagrebu iz predmeta „Rasklopna postrojenja“.

Znanstveni asistent je (1978. – 1985.) na grupi predmeta „Električna postrojenja“. Održava auditorne i laboratorijske vježbe iz predmeta „Električna postrojenja“, „Elektrane“, „Razvod električne energije“ i „Regulacija u elektroenergetskom sistemu“.

Od 1980. do 1985. sudjeluje u radu na znanstvenoistraživačkom projektu „Optimalno vođenje i eksploatacija elektroenergetskog sistema“ finanaciranog od strane SIZ-a za znanost SRH.

Od 1985. do 1990. glavni je istraživač na predmetnom projektu.

Od 1990. do 1996. aktivno sudjeluje kao glavni istraživač na znanstvenoistraživačkom projektu 2-05-879 „Razvoj, vođenje i eksploatacija pogona elektroenergetskog sistema“ financiranog od strane Ministarstva znanosti i tehnologije Republike Hrvatske.

Izabran je (1996.) ponovno za glavnog istraživača na novom znanstvenoistraživačkom projektu „Planiranje i vođenje srednje razvijenih ees-a“, a sve do kraja 2001. godine. Projekt je financiran od strane MZT RH.

Godine 1985. izabran je u zvanje docenta na grupi predmeta „Električna postrojenja“ u Zavodu za visoki napon i energetiku ETF-a Zagreb.

Za izvanrednog profesora izabran je, na istoj grupi predmeta, 1991., a za redovnog profesora 1997.

U nastavi održava dio predavanja iz predmeta Osnove elektroenergetike (prema nastavnom planu ETF-a 4 – pripremni dio studija) odnosno dio predavanja iz predmeta Energetska elektrotehnika (FER-1 – pripremni dio studija – ZSE 0103).

U stručnom dijelu studija održava predavanja iz predmeta „Regulacija elektroenergetskog sustava“ (ENE 1308), te predmeta „Dinamika elektroenergetskog sustava“ (ZEN 09B1) kao izbornog (D+P) kojeg je samostalno ustrojio.

Na poslijediplomskom studiju održava predavanje iz predmeta: (ZEN05D2) „Pogon hidroelektrana“ i (ZEN06D1) „Regulacija u energetici“.

Na poslijediplomskom studiju u FESB-u Split vodi predmete „Regulacija u elektroenergetskom sustavu“ i „Vođenje elektroenergetskog sustava“.

Školske godine 1978./79. održava dio nastave u FESB-u Split iz predmeta „Automatizacija u električnim postrojenjima“.

Školske godine 1989./90. na ETF-u u Sarajevu održava predavanja iz predmeta „Vođenje i ekspoloatacija elektroenergetskog sistema“.

Na ETF-u u Tuzli honorarni je profesor iz predmeta „Planiranje i vođenje pogona elektroenergetskog sistema“.

Suautor je jednog sveučilišnog udžbenika i jednog priručnika, te jedne sktripte i četiri tzv. zavodske (interne) skripte. Također, suautor je 21 rada u raznim časopisima.

Autor ili suautor je 117 radova na međunarodnim skupovima, 86 studija, elaborata i projekata, te 6 ostalih publikacija.

Vodio je preko 100 diplomskih radova, preko 50 magistarskih radova, te 22 doktorske disertacije.

Znanstvenoistraživačka i stručna djelatnost najizraženija je u istraživanju pojava vezanih za dinamiku pogona elektroenergetskog sustava.

Godine 1976. kao stipendist DAAD boravi 2 mjeseca na Goethe Institut – SR Njemačka, Lünenburg.

Školske 1981./82. boravi, također, kao stipendist DAAD na Rurh-Universität Bochum, SR Njemačka, Lehrstuhl für Mess u Regelungstechnik, gdje radi na problemu teorijskog istraživanja dinamike hidroelektrana.

Godine 1983. boravi (15 dana) u KW „Weissweiler“, RWE, SR Njemačka i KW „Irsching“ ISAR, Amperwerke, SR Njemačka, te u TE „Šoštanj“, Slovenija (1 mjesec) radi upoznavanja s dinamikom pogona termoelektrana.

Za magistarski rad dobio je nagradu „Dr. Vratislav Bednjanič“, Ljubljana, 1978.

Član je slijedećih strukovnih udruženja: CIGRÉ – Paris, HR CIGRÉ, IFAC – Sekcija za velike sustave, KOREMA i MIPRO.

Do sada je na fakultetu obnašao mnoga upravna zaduženja (prodekan za znanost itd.).

ABOUT SUPERVISOR

Sejid Tešnjak, Ph.D., was born on August 29, 1949 in Prnjavor, where he finished elementary school (1964) and high school (1968). He graduated from the Faculty of Electrical Engineering in Zagreb, Department of Electrical Power Engineering, in 1972. At the same faculty, he received his master's degree in 1977 in the field of Energy with the topic "Mathematical model for the needs of power system management", and his doctorate in 1984, defending his dissertation entitled "Theoretical and experimental analysis of hydropower dynamics".

From 1972 to 1978 he worked as an assistant on the group of subjects "Electrical plants" at the Department of High Voltage of the Faculty of Electrical Engineering in Zagreb.

He is a part-time teacher (1975-1980) at the Rade Končar Secondary School in Zagreb in the subject "Switchgear".

He is a research assistant (1978 - 1985) in the group of subjects "Electrical facilities". Holds classroom and laboratory exercises in the subjects "Electrical facilities", "Power plants", "Electricity distribution" and "Regulation in the power system".

From 1980 to 1985, he participated in the work on the scientific research project "Optimal management and operation of the power system" funded by the SIZ for Science of the Republic of Croatia.

From 1985 to 1990 he was the principal investigator on the subject project.

From 1990 to 1996 he actively participated as a principal investigator in the scientific research project 2-05-879 "Development, management and operation of power system plants" funded by the Ministry of Science and Technology of the Republic of Croatia.

He was elected (1996) again as the main researcher on the new scientific research project "Planning and management of medium-developed power systems", until the end of 2001. The project is funded by MZT RH.

In 1985, he was elected assistant professor in the group of subjects "Electrical Plants" at the Institute for High Voltage and Energy of the ETF Zagreb.

He was elected associate professor in the same group of subjects in 1991, and full professor in 1997.

He teaches part of the lecture on the subject Basics of Electrical Engineering (according to the ETF curriculum 4 - preparatory part of the study) and part of the lecture on the subject of Energy Electrical Engineering (FER-1 - preparatory part of the study - ZSE 0103).

In the professional part of the study, he holds lectures on the subject "Power System Regulation" (ENE 1308), and the subject "Dynamics of the Power System" (ZEN 09B1) as an elective (D + P), which he organized independently.

At the postgraduate study he gives a lecture on the subjects: (ZEN05D2) "Hydropower plant" and (ZEN06D1) "Energy regulation".

At the postgraduate study at FESB Split, he teaches the courses "Regulation in the Electric Power System" and "Management of the Electric Power System".

School years 1978/79 holds part of the classes at FESB Split in the subject "Automation in electrical plants".

School years 1989/90 at the ETF in Sarajevo, he holds lectures on the subject "Management and operation of the power system".

At the ETF in Tuzla, he is a part-time professor in the subject "Planning and operation of the power system".

He is the co-author of one university textbook and one manual, as well as one script and four so-called institutional (internal) scripts. He is also a co-author of 21 papers in various journals.

He is the author or co-author of 117 papers at international conferences, 86 studies, studies and projects, and 6 other publications.

He has led over 100 graduate theses, over 50 master's theses, and 22 doctoral dissertations.

Scientific research and professional activity is most pronounced in the study of phenomena related to the dynamics of power system operation.

In 1976, as a DAAD scholarship holder, he spent 2 months at the Goethe Institute - FR Germany, Lünenburg.

School 1981/82 resides, also, as a DAAD scholarship holder at the Rurh-Universität Bochum, FR Germany, Lehrstuhl für Mess in Regelungstechnik, where he works on the problem of theoretical research of hydropower dynamics.

In 1983 he stayed (15 days) in KW "Weissweiler", RWE, FR Germany and KW "Irsching" ISAR, Amperwerke, FR Germany, and in TPP "Šoštanj", Slovenia (1 month) to get acquainted with the dynamics of thermal power plant operation.

For his master's thesis he received the award "Dr. Vratislav Bednjanič “, Ljubljana, 1978.

He is a member of the following professional associations: CIGRÉ - Paris, HR CIGRÉ, IFAC - Section for Large Systems, KOREMA and MIPRO.

So far, he has held many administrative duties at the faculty (vice dean for science, etc.).

ZAHVALA

Izrada doktorske disertacije može se doživjeti kao putovanje koje pojmiti mogu jedino oni što su došli do cilja. Tijekom vlastitog putovanja susreo sam se s mnogim dvojbama koje su propitivale sve kapacitete svojstvene čovjeku od intelektualnih, preko duhovnih do fizičkih. Unatoč tome što sam dospio do kraja te pri tome proširio vlastite kapacitete i horizonte, priznajem da bi izrada ove disertacije bila nemoguća bez dobrote ljudi koji su mi pomagali na mom putu.

U prvom redu zahvaljujem mentoru koji me vodio cijelo vrijeme izrade disertacije prof.dr.sc. Sejidu Tešnjaku, za neizmjerni entuzijazam i beskompromisnu pruženu pomoć, kao i članovima povjerenstava FER-a, prof.dr.sc. Tomislav Tomiša, prof.dr.sc. Ivica Pavić, prof.dr.sc. Zdenko Šimić, prof.dr.sc. Igor Kuzle koji su me pratili tijekom doktorskog studija na savjetima i sugestijama.

Kolegama i prijateljima sa Fakulteta elektrotehnike i informacijskih tehnologija Sveučilišta J.J. Strossmayer u Osijeku - prof.dr.sc. Damir Šljivac, prof.dr.sc. Hrvoje Glavaš, prof.dr.sc. Srete Nikolovski, prof.dr.sc. Predrag Marić, prof.dr.sc. Danijel Topić, dr.sc. Ivica Petrović zahvaljujem na velikoj pomoći savjetima oko metoda znanstvenog rada kao i omogućenim podacima.

Zahvale kolegama iz kompanije Emerson Network Power (danas Vertiv), BJ Sonnenberg, Marek Szpek, Dustin Becker, Mark Murrill, Stephen C Hassell, JF Morier, Kjell Lovquist, Markos Athineos, Rino Doria, Robin Xu Kai, Rongseng Xie, Tim Williams, Ulf Dimle, dr.sc. Beth Chase, Jack Pouchet, Jurica Bečić i Nikola Velčić čiji su stručni savjeti i podaci omogućili vjerodostojnost predloženih modela.

Zahvaljujem kolegama iz kompanije ABB, dr.sc. Simon Walton i Holger Hannemann na pomoći pri postavljanju modela obnovljivih izvora energije. Također, zahvaljujem Michael Skepton na savjetima o modeliranju parametara vezanih za energente i Mladenu Mijakiću na pribavljenim podacima o opterećenju podatkovnog centra.

Veliku zahvalnost dužan sam izraziti svojoj cijeloj obitelji, roditeljima na poticanju na doktorski studij. Tati Josipu, umirovljenom pukovniku oružanih snaga RH, na pomoći pri razumijevanju

rizika vezanih za terorizam i elementarne nepogode, te puncu, prof.dr.sc. Vladimiru Čavraku s Ekonomskog fakulteta, Sveučilišta u Zagrebu na dugim razgovorima o znanstvenim metodama i metodama ekonomske znanosti.

Na posljetku želim zahvaliti svojoj supruzi Mirni i djeci Lari i Davidu na pruženoj potpori i razumijevanju što smo zajedno provodili manje vremena nego što bi svi htjeli. Završetak ove disertacije je naš zajednički uspjeh i tek početak stvaranja mnogih obiteljskih uspjeha.

Disertaciju posvećujem svojoj obitelji

SAŽETAK

Predmetna disertacija se bavi istraživanjem telekomunikacijske i podatkovne infrastrukture, njezine raspoloživosti i procesima odlučivanja u svrhu optimizacije dediciranih izvora energije. Kao glavni kriteriji za odlučivanje odabira prikladne arhitekture, zasnovane na različitim kombinacijama distribuiranih izvora električne energije i spremnika energije kao i uporabe pojne mreže ističu se kapitalna ulaganja, operativni troškovi, efekti emisije CO_2 i rizici vezani za opskrbu energenata, s različitim težinskim faktorima. Posebna pozornost je posvećena integraciji obnovljivih izvora energije u raznim konfiguracijama. Razmotrene su tehnologije napajanja iz pojne mreže, plinske tehnologije (plinske turbine, plinske mikroturbine, plinski agregati i gorive ćelije), dizel agregati i tehnologije obnovljivih izvora (sunčeve i vjetroelektrane) sa i bez uporabe spremnika energije, na teritoriju Republike Hrvatske.

Predstavljeni su dinamički modeli interakcije pojedinih izvora energije temeljeni na Monte Carlo metodi. Razvijeni su modeli razvoda distribucije unutar podatkovnog i TK postrojenja zasnovani na istosmjernom i izmjeničnom razvodu a njihova evaluacija raspoloživosti provedena je metodom dinamičkog stabla kvara.

U svrhu kvantifikacije (kvalifikacije) rizika vezanih za opskrbu energentima korištena je Delphi metoda zasnovana na neizrazitoj logici, a u svrhu predviđanja vremenskih nizova generiranja električne energije iz obnovljivih izvora razvijeni su modeli temeljeni na neuronskim mrežama.

Na kraju su rezultati spomenutih modela korišteni kao ulazni parametri za kriterije odlučivanja temeljeni na TOPSIS metodi. Modeli su ocjenjeni primjenom na postojeću podatkovnu infrastrukturu u SAD-u.

Ključni pojmovi:

Obnovljivi izvori energije, distribuirana proizvodnja, mikro mreže, podatkovni centar, raspoloživost, rizik, TOPSIS, neuronske mreže, neizrazita logika, Monte Carlo simulacija

STRUCTURED ABSTRACT

Dissertation Title: Influence of Distributed Electrical Energy Production on the Availability Enhancement in Telecommunication and Datacenter Facility

Introduction

One of the most important foundation stones of modern economy is data gathering, processing and utilizations, making our society a data driven society. All of the data is stored and processed on serves in data centers. With significant increase in data traffic from year to year data centers also grew to such an extend that traditional paradigms of power supply should no longer be taken for granted due to issues associated to carbon emissions and impact on sustainability. Modern data centers can easily be found in sizes of 200+ MW of installed capacity with indication that these powers could easily be up to 1 TW by same of the facility owners. Today, we are also witnessing convergence of the traditional core telecommunication facilities into data centers by means of virtualization and similar methods.

Undoubtably, a novel type of criteria and decision matrixes needs to be considered to enable these rapidly growing facilities a high level of availability and resiliency as well as to minimize carbon footprint associated to energy use. At a same time, capital expenses are posing a significant problem for the investors who need to balance in between total cost of ownership scheme with respect to return of the investment.

Purpose of this dissertation is to propose adequate models incorporating electrical infrastructure availability of a datacenter or telecommunication facility, as well as capital and operating expenditure, CO_2 emission and risk assessment. One of the main goals is to enable a wholistic model that can be used in real life by decision makers to optimize their business case.

A detailed cost-benefit analysis of distributed power sources with application in data centers or telecommunication facilities has been conducted. The analysis is based on the TOPSIS method, which in this case combines capital and operating costs, CO_2 emissions and risks related to the supply of necessary energy sources. A dynamic model of energy sources has been established that has a direct impact on efficiency, operating costs and CO_2 emissions.

A complex model for the availability of distributed energy sources and a data or telecommunications facility is established. The proposed model is robust and consists of sub models that model individual power sources depending on the properties of the drive and dynamics and which are ultimately built into the model of a higher hierarchical level. The electrical architectures are entirely modeled by a dynamic fault tree.

The established synergy model is verified at a specific plant. A unique data set was collected with a detailed insight into the power availability of the Emerson Data Center in St. Louis, Missouri, USA. The collected data was used in the proposed model, and ultimately unambiguously verified the model, so that the modeled outcome is the same as the actual achieved and realized design and primarily in the technical configuration of different energy sources, their capital investment, operating costs, CO_2 emissions and risks related to energy supply.

Chapter 1 – Situation overview

First chapter of the dissertation has an introductory character. General overview of datacenter industry and telecommunications is presented as well as challenges in modern economy and need for highly available green energy.

Chapter 2 – Distributed Power Sources, Concept and Specific Uses

A general overview of distributed power generation technologies and energy storages is elaborated in this chapter. All of the individual technologies are evaluated on their technical characteristics and performances with general overview on capital and operating costs of individual technology.

For the pure standby application, a diesel generator is evaluated. Other power sources achieved by means of rotational machines are based on gas technology and consist of gas generator, turbines and micro turbines and these technologies can be used for both standby and primary application. Fuel cells are evaluated in all of the forms present today with the main focus on SOFC technology which should be used predominantly as a primary power source.

Renewable power sources in form of wind, solar, hydro and geothermal power are evaluated, however from further analysis hydro and geothermal power were not considered. Both solar

and wind power have a significant reduction in terms of capital expenditure making this technology appealing but since they rely on primary energy sources such as solar irradiance or wind mass movement a special modeling had to be conducted in later chapters.

Energy storage systems in different forms and technologies are evaluated, such as stationary batteries, supercapacitors and flywheels. Necessity for energy storage in critical systems is of great importance due to time bridging when switching in between different power sources and as well for optimization purposes of renewable power sources implementation. Main considered technology in this dissertation is traditional valve regulated lead acid (VRLA) battery due to the flexibility in terms of achieving different runtimes and established capital costing due to the technology maturity.

Special attention is given to dimensioning and optimization of hybrid systems and microgrid creation, based on combination of solar and wind power in conjunction with energy storage. For that purpose a special algorithm is developed. Algorithm is based on iteration for every hour of the day monitoring the present situation but also most importantly keeping the memory of previous runtimes what turned out to be paramount for proper battery dimensioning for hybrid systems.

Chapter 3 – Infrastructure Characteristics and Most Common Forms

Need for the high levels of availability are explained through costs associated to the data center downtime. All of the costs associated to the downtime increase from year to year calling out for a robust resilient infrastructure. Two major different approaches to all electrical architectures are discussed in terms of electrical distribution being achieved by alternating (AC) or direct (DC) current. Difference between mechanical and IT loads is discussed, since the dissertation considers in the models IT load only as a critical load while mechanical loads are omitted from the discussion since the global trend in that domain is to leave mechanical load unprotected or to segregate it from the IT load. It is Author's believe that this topic should be revisited in the future work.

Uninterruptable power supply (UPS) systems are presented in both AC and DC variants in most common architectures.

Chapter 4 – Distributed Power Sources and Data Center Electrical Infrastructure Interaction

Fundamentals of availability levels or tiers is presented. Clear indication of four different availability levels presented for electrical infrastructure of a data center. All availability levels are discussed together with their inherent properties.

All presented structures emphasize distinguishment between power sources and rest of the infrastructure.

Chapter 5 – Fundamental Mathematical Models and Algorithms Related to the Concept of Availability and Reliability

Fundamental terms in reliability, availability and maintainability theory are discussed. Clear differentiation between reliability and availability is made and most important variables such as MTTF, MTTR, MTBF, etc. are defined. Mathematical models for most common probability distribution functions, such as uniform, exponential, Weibull, are elaborated. Basic structures and models of serial and parallel availability are depicted.

Dynamic Fault Tree Analysis (DFTA), based on Boolean algebra in combination with Monte Carlo simulation or Petri nets, is a preferred choice in this dissertation for infrastructure availability assessment. Monte Carlo as a computer simulation based on random number generation is being used and discussed. In dissertation Monte Carlo is being used for assessment of operating costs of different distributed power sources as well as for overall data center architecture CO_2 emission contribution. Entropy in information systems is discussed as a foundation stone for choice of probability distribution functions used for the Monte Carlo simulation. Different approaches to data center maintenance are also described.

Special attention is given to the simulation and modeling methodology where the time series forecast is the heart of the discussion. Smoothing methods and Auto Regressive Integrated Moving Average are described and tried out, however in the dissertation Neural Networks have been chosen as a preferred method. Nonlinear Auto Regressive with Exogenous Inputs - NARX, Nonlinear Auto Regressive – NAR and Nonlinear Input-Output – NIO types of Neural Networks are described.

Additional modeling techniques were used, such as Fuzzy Logic in combination with Delphi method to enable qualifying and quantifying risk factors associated to the location of data center

deployment. In the end, a TOPSIS method (Technique for Order of Preference by Similarity to Ideal Solution) was used to find optimal solutions (combinations of distributed power sources).

Chapter 6 – Availability Models

A set of availability models for individual power sources is proposed. Due to different properties of every disused power source an individualized approach is proposed. Solar power achieved by the means of photovoltaic cells is subjected to constant degradation resulting in overcapacity on first day of installation to reach nominal needed power after ten years. Since all of the panels are exposed to certain failure rate the power plant is modeled with availability model of serial connected panels. Wind power plant consists of different configurations of individual power and inherent availability. Two scenarios are calculated: to obtain three and four "nines" of availability respectively. Installed capacity and overcapacity information are extracted and will be used later in the simulation for purposes of impacting the operating costs (maintenance). Diesel and gas generators are seen as monolithic systems; hence their state is modeled as "Up" or "Down" based on statistical operational data (achieved availability) including both regular and corrective maintenance in a "Down" state. Modeling of the fuel cell system is based on serial availability model. Models of the commercial power grid are based on actual data for EU-28.

Data center electrical infrastructure availability is modeled with DFTA. Both AC and DC distribution systems are considered, based on Level 4 availability level. As a foundation, a model is proposed with 400 V_{DC}, -48 V_{DC}, 12 V_{DC} and 400 V_{AC} UPSs. All DFTA models are explained and illustrated.

Holistic model is based on Monte Carlo simulation and predominantly consider uniform probability distribution for availability estimation, in accordance to the information maximum entropy theorem. Simulated availability is for the whole data center electrical architecture and has a special feature of indicating availability levels for every individual power source, availability of groups of two power sources and also for all power sources enabling a model of predicting CO_2 emissions allocated to specific examined electrical infrastructure of a data center. Proposed are 41 architectures divided in five groups where every group has common electrical architecture.

Evaluation methodology for every individual architecture in ten steps is established.

Chapter 7 – Explored Examples

In this chapter of the dissertation two models are set up, where the first model is based on real case with actual data center implementation in St. Louis, Missouri, USA and is used as a benchmark for overall model validation. Second model refers to hypothetical implementation in the Republic of Croatia. Model limitations are outlined and comprise of power limitation, omission of mechanical loads, data origin, cost base definition, etc.

Capital expenditure, operating costs and CO_2 emission rate of individual distributed power supply are evaluated from multiple sources as well as the commercial electrical and gas network parameters. Historical data used, for simulation of future wind and solar power generated, derives from project EMHIRES and SETIS initiative of European Union. Simulation of future wind and solar power generation is based on artificial Neural Networks and simulation is carried out by the means of Matlab 2018b software package. Special attention is given to simulation and optimization of hybrid solution where the main task was to minimize capital investment and operating costs between different configurations of wind turbines, solar panels and energy storage.

Risks of energy resources acquirement is assessed through Fuzzy Delphi method. Actual data indicating risk parameters from relevant sources is presented for supply of oil, gas and electrical energy from abroad, considering routs of supply, political stability of countries through supply is achieved. Method captures overall assessment based on three different risks groups: infrastructure, supply and resiliency. Infrastructure risks are seen as risks imposed on gas and electrical networks, risks of supply refer to self sufficiency in respect to reserves and refining capacities as well as possible political impacts on energy supply, while risks associated to resiliency refer to meteorologic risks as well as risks of terrorism etc.

Foundation for the TOPSIS method is presented in form of capita and operating expenditure, CO_2 and degree of supply quality (risks). Monte Carlo simulation is applied for the CO_2 offset simulation in all given architectures respecting all of the efficiency curves of individual distributed power source as well as in respect to individual power supply sources operational availability.

A referent model is presented for actual critical facility, Emerson data center in St. Louis, Missoury. Actual data of grid power quality is assessed as well as capital investment schemes for different technologies available at the time of implementation as well as costs for energy

(gas and electrical) from the time the structure was erected. Special attention is given to the actual data derived from the actual solar power plant on site.

Chapter 8 – Results

Results are divided into two main sections. The first section details the results of a validation model. Simulation indicated that the model was set up properly since the ideal combination of the power sources is exactly the one that has been applied and prior to the implementation studied in detail. At this point, the proposed model is successfully validated.

Second part of results details the evaluation model for Republic of Croatia. First subsection of the discussion details results of a Fuzzy Delphi method and a risk assessment. A sensitivity analysis is performed to observe impact of the risk as a factor to identification of optimal architecture. In second subsection a detailed result of TOPSIS method are presented capturing all 41 modeled architectures with indication on capital and operating expenditures, CO_2 emission and risks impacting supply quality. A graphical illustration of TOPSIS results is presented along with detailed tables. In the third subsection a detailed sensitivity analysis is carried out to illustrate proportions among all four main criteria (CAPEX, OPEX, CO_2 and risk) and how they impact the overall optimal architecture finding.

Conclusion

Dissertation addresses the problem of achieving and maintaining high availability levels allocated to electrical infrastructure of a telecommunication facility or a data center in combination with variety of distributed power sources. Every power source inherently possesses properties that impact operating costs such as efficiency, fuel type, maintenance schedule and yielding a certain emission of CO_2 during the operation. Other points of interest is the capital investment for every possible power source as well as risks associated to energy generating products supply.

A detailed cost-benefit analysis of distributed sources of electricity generation with application in data or telecommunications facilities has been proposed. The analysis is based on the TOPSIS method, which in this case combines capital and operating costs, CO_2 emissions and risks related to the supply of necessary energy sources. A dynamic model of energy sources has been established that has a direct impact on efficiency, operating costs and CO_2 emissions.

A synergy model for the availability of distributed energy sources and a data or telecommunications facility is established. The proposed model is robust and consists of submodels that model individual sources depending on the properties of the drive and dynamics and which are ultimately built into the model of a higher hierarchical level. The electrical architectures are entirely modeled by a dynamic fault tree.

The established synergy model has been verified at a specific plant. A unique data set was collected with a detailed insight into the power availability of the Emerson Data Center in St. Louis. Louis in the state of Missouri, USA. The collected data were used in the proposed model, and ultimately unambiguously verified the model, so that the modeled outcome is the same as the actual and primarily in the technical configuration of different energy sources, their capital investment, operating costs, CO_2 emissions and risks related to energy supply.

Special attention is given to microgrid creation and to the impact of high availability necessity to the microgrid dimensioning. Model is based on sets of static two-dimensional matrixes depicting space of the possible solutions. Special algorithm for time series sequencing is proposed for every individual solution. Although many different approaches have been considered for time series analysis best results were achieved by the means of artificial neural networks.

Keywords:

Renewable energy, distributed generation, microgrid, data center, availability, risk, TOPSIS, neural networks, fuzzy logic, Monte Carlo simulation

SADRŽAJ

1. Pregled stanja 1
2. Distribuirani izvori energije, pojam i specifične primjene 4
2.1. Dizel i plinski agregati 4
2.2. Plinske turbine 6
2.3. Vjetroelektrane 8
2.4. Sunčeve elektrane 12
2.5. Plinske mikro turbine 14
2.6. Gorive ćelije 16
2.7. Male hidroelektrane 19
2.8. Geotermalne elektrane 20
2.9. Spremnici energije 21
2.9.1. Općenito 21
2.9.2. Reverzibilne elektrane 22
2.9.3. Spremnik komprimiranog zraka 23
2.9.4. Zamašnjak 23
2.9.5. Supervodljivi magnetski spremnici energije 23
2.9.6. Superkondenzator 23
2.9.7. Baterijski spremnici energije 23
2.9.8. VRLA baterije 24
2.9.9. Litij ionske baterije 25
2.10. Mikromreže 26
2.11. Hibridni sustavi 26
3. Značajke infrastrukture i najčešći karakteristični oblici 31

3.1. Osnovni pojmovi 31
3.2. Tereti u podatkovnom postrojenju 35
3.3. Besprekidni sustavi napajanja 37
4. Međudjelovanje distribuiranih izvora i podatkovne električke infrastrukture 41
5. Temeljni matematički modeli i algoritimi vezani uz pojam raspoloživosti i pouzdanosti 45
5.1. Osnovni pojmovi 45
5.2. Funkcije razdiobe vjerojatnosti 49
5.2.1. Eksponencijalna razdioba 50
5.2.2. Primjena konstantne učestalosti kvara u eksponencijalnom modelu 51
5.2.3. Primjena Weibullovog modela pouzdanosti 52
5.2.4. Uniformna razdioba 53
5.3. Osnovni modeli i strukture raspoloživosti 54
5.4. Dinamičko stablo kvara 55
5.4.1. I (*AND*) logička vrata 55
5.4.2. ILI (*OR*) logička vrata 56
5.4.3. Prioritetna I vrata (PAND) 57
5.4.4. Rezervna vrata 58
5.5. Monte Carlo metoda 58
5.6. Teorija informacija – entropija 60
5.7. Teorija održavanja sa primjenom u podatkovnim i telekomunikacijskim postrojenjima 61
5.8. Metodologija modeliranja i simuliranja 62
5.9. Predviđanje vremenskih nizova 62
5.9.1. Modeli glađenja 63
5.9.2. ARIMA modeli 64
5.9.3. Simuliranje vremenskih nizova pomoću modela umjetnih neuronskih mreža 65

5.10. Modeliranje uporabom neizrazite logike, Delphi i TOPSIS metode 69
5.10.1. Neizrazita logika 69
5.10.2. Neizrazita Delphi metoda 70
5.10.3. TOPSIS metoda 71
6. Modeli raspoloživosti 74
6.1. Modeli raspoloživosti distribuiranih izvora energije 74
6.1.1. Raspoloživost sunčeve elektrane 74
6.1.2. Raspoloživost vjetroelektrane 75
6.1.3. Raspoloživost dizel agregata 76
6.1.4. Raspoloživost plinskih agregata 77
6.1.5. Raspoloživost gorivih ćelija 77
6.1.6. Raspoloživost krute mreže 77
6.2. Raspoloživost podatkovne i telekomunikacijske infrastrukture 79
6.3. Zajednička raspoloživost 84
6.4. Uspostava konačnog modela i postupak evaluacije 91
7. Primjeri istraživanja 92
7.1. Ograničenja modela 92
7.2. Modeli cijena i troškova 93
7.2.1. Kruta mreža 93
7.2.2. Dizel agregati i distribuirani izvori električne energije zasnovani na plinskim tehnologijama 94
7.2.3. Vjetroelektrane, sunčeve elektrane i VRLA baterije 96
7.3. Simulacija proizvodnje električne energije iz sunčevih i vjetroelektrana 97
7.3.1. Predviđanje vremenskih nizova 97
7.3.2. Simulacija vjetroelektrane u R.H. 98

7.3.3. Simulacija sunčeve elektrane u R.H. 102
7.4. Simulacija i optimiziranje hibridnog sustava 106
7.5. Rizici opskrbe energentima u R.H. 113
7.6. Višekriterijsko odlučivanje 115
7.7. Emerson podatkovni centar – referentni validacijski model 117
8. Rezultati istraživanja 121
8.1. Rezultati validacijskog modela 121
8.2. Rezultati modeliranja za R.H. 126
9. Zaključna razmatranja 142
10. Postignuti znanstveni doprinosi 146
11. Popis slika 147
12. Popis tablica 152
13. Popis literature 155
14. Popis kratica i oznaka 167
15. Prilog 1 – Podaci o modeliranom hibridnom sustavu 173
16. Prilog 2 - Interpolocaijske krivulje učinkovitosti tehnologija proizvodnje električne energije 183
17. Životopis 188
18. Curriculum Vitae 190

1. PREGLED STANJA

Podatkovni promet praćen velikim brzinama i širokom dostupnošću postao je jedan od stupova modernog društva u cijelosti, čiji utjecaj se posebno očituje u modernom poslovanju i ekonomiji, ali, i u svakodnevnom životu [1]. Potreba za sve znatnijim količinama podataka koji trebaju biti dostupni u što kraćem vremenskom periodu stavlja znatne izazove pred tehničku i znanstvenu zajednicu u podatkovnoj i telekomunikacijskoj industriji. Podatkovni centri imaju ulogu skladištenja i obrade podataka, dok telekomunikacijski centri imaju ulogu slanja i reguliranja podataka.

Kao zahtjev sintagme održivog razvoja uvjet je energetska učinkovitost u sveukupnoj energetskoj potrošnji, a cjelovita industrija informacijskih i komunikacijskih tehnologija (eng. *Information and communications technology - ICT*) ima znatan udio u ukupnoj potrošnji. U svrhu poštivanja ciljeva Kyoto protokola, Europska Unija treba smanjivati emisiju CO_2 za 650 Mt godišnje, od čega je 400 Mt proizvedeno u energetskim sektorima [2]. Poštivanje navedenog cilja će svakako zahtijevati nekonvencionalne metode u vođenju sustava. Kao jedan od primjera je ICT industrija koja inkorporira telekomunikacijske i podatkovne infrastrukture.

Sveza tih dvaju tipova infrastruktura, ali, i u konačnici industrija je izuzetno izražena, obzirom da oba tipa infrastruktura potpomažu jedna drugu, a u novije vrijeme i poprimaju iste značajke, kao što se može vidjeti na primjeru specifične, originalno telekomunikacijske infrastrukture, jezgre mreže, koja se izvodi kao podatkovni centar a njezina funkcionalnost se virtualizira. Drugi primjer je pristupna mreža mobilnih telekomunikacija, koja se originalno koristila u svrhu prijenosa govornih podataka (telefonskog razgovora), dok danas se koristi sve više u svrhu podatkovnog prometa.

Spomenute industrije, dakle, uz mogućnosti i dobrobiti koje donose društvu, također donose i izazove za sustave opskrbe energijom, te neminovno imaju i veliki utjecaj na okoliš, obzirom da je njihov udio u ukupnoj potrošnji u stalnom porastu. Javlja se i problem energetske učinkovitosti i smanjenja emisije stakleničkih plinova, prije svega CO_2, te sigurnost opskrbe energentima na određenom teritoriju.

Jedan od glavnih izazova za znanstvenu i tehničku zajednicu je kako pronaći rješenja za podatkovnu infrastrukturu, a da ona zadovoljava visoke kriterije raspoloživosti, pouzdanosti i obnovljivosti, uz zadržavanje što nižih troškova kapitalnih ulaganja i operativnih troškova [3], [4].

U svrhu razumijevanja podatkovne infrastrukture i stvaranja rješenja koja mogu zadovoljiti spomenute kriterije, nužno je sagledati cjelokupnu infrastrukturu, od priključka na pojnu mrežu i paralelnih distribuiranih izvora električne energije, preko internih sustava distribucije sve do tereta, koji je u predmetnoj disertaciji računalni teret, odnosno poslužitelj (*eng. server*).

Infrastruktura podatkovnih centara je tradicionalno zasnovana na razvodu izmjenične električne energije, dok je svojstvo telekomunikacijskih postrojenja da imaju razvod zasnovan na istosmjernoj električnoj energiji. Oba razvoda, kao načela, imaju svoje dobrobiti, no nužno je razmotriti mogućnost uporabe istosmjernog razvoda u podatkovnim centrima, obzirom da takva rješenja mogu ponuditi više razine raspoloživosti, ali, i omogućiti nesmetanu integraciju izvora energije koji su inherentno zasnovani na izmjeničnoj električnoj energiji, poput sunčevih elektrana zasnovanih na tehnologiji fotonapona. Rezultati predočeni u dosadašnjim radovima [5]-[10] navode na zaključak da istosmjerna postrojenja mogu imati veću razinu raspoloživosti u odnosu na postrojenja zasnovana na izmjeničnom razvodu, a također da je moguće i ostvariti uštede u kapitalnim ulaganjima u slučaju kada se koriste sunčeve elektrane. Metoda koja se ističe kao najbolja u svrhu evaluacije razina raspoloživosti same infrastrukture je dinamičko stablo kvara (DFTA).

Spomenuti kriteriji, poput kapitalnih ulaganja, operativnih troškova uključujući i pogonske troškove, emisije CO_2 i rizika vezanih za opskrbu energentima kao što su električna energija iz pojne mreže, nafte i plina, imaju veliku važnost pri nalaženju najboljeg rješenja za investitora i vlasnika podatkovne infrastrukture. U tu svrhu, u predmetnom radu, koristiti će se metoda višekriterijskog odlučivanja.

Uz konvencionalno napajanje podatkovnih centara iz pojne mreže, nužna je uporaba i paralelnih izvora energije u svrhu uspostave visokih razina raspoloživosti opskrbe tereta električnom energijom. Obzirom da je nužno sagledavanje svih spomenutih kriterija, nužno je također i obaviti analizu dostupnih tehnologija koje mogu pomoći pri iznalaženju najboljeg rješenja. U tu svrhu, u predmetnoj disertaciji, razmatraju se spajanje na pojnu mrežu i razni distribuirani izvori električne

energije, poput: dizel agregata, plinskih agregata, gorivih ćelija, plinskih turbina i mikroturbina, sunčevih i vjetroelektrana, geotermalnih i hidro elektrana. Uz navedene izvore energije razmotrit će se i različite tehnologije pohrane električne energije.

Posebna pozornost u predmetnoj disertaciji daje se distribuiranim izvorima energije, njihovim dinamičkim svojstvima u pogledu učinkovitosti u ovisnosti o opterećenju i utjecaju na operativne troškove i emisiju CO_2 za što je ponuđena simulacijska metoda. Svojstva obnovljivih izvora su u snažnoj vezi sa primarnim izvorima energije, dakle, sučevom radijacijom i kretanjem zračnih masa a procjena srednjih vrijednosti proizvodnje iz istih izvora ne zadovoljava koncepte raspoloživosti i kapaciteta u podatkovnoj industriji. U svrhu evaluacije obnovljivih izvora energije potrebno je koristiti metode predviđanja vremenskih nizova kako bi se moglo sa izvjesnom razinom sigurnosti utvrditi kapacitete proizvodnje u točki vremena. U tu svrhu, potrebno je razviti dinamičke modele koji mogu opisivati međuodnose između pojedinih izvora energije. To je najočitije u hibridnim sustavima, gdje je nužno zasnivanje posebnog algoritma u svrhu pravilnog dimenzioniranja sustava, što u konačnici omogućuje i optimizaciju sustava zasnovanog na višestrukim obnovljivim izvorima i spremniku energije.

Jedan od važnih faktora pri odlučivanju o primarnim i sekundarnim izvorima energije je i rizik vezan za opskrbu energenata nužnih za rad izvora električne energije. Rizici vezani za opskrbu uvelike ovise o stabilnosti dobavne infrastrukture, proizvodnji energenata na danom području i rizicima vezanima za utjecaje vremenskih nepogoda i terorističkih djelovanja. U radu je izložena metoda kvalifikacije, umjesto kvantifikacije, rizika opskrbe energentima, uporabom metode zasnovane na neizrazitoj logici.

Predmetna disertacija daje uvid u funkcioniranje kritične podatkovne infrastrukture kao i nužne kriterije raspoloživosti iste, te nudi model temeljem kojeg je moguće doći do zaključka o optimalnoj arhitekturi i uporabi raznih izvora električne energije sa ciljevima smanjenja kapitalnih ulaganja, operativnih troškova i emisije CO_2, a uz kvalifikaciju rizika opskrbe, zasnivanjem jedinstvenog složenog modela.

2. DISTRIBUIRANI IZVORI ENERGIJE, POJAM I SPECIFIČNE PRIMJENE

2.1. Dizel i plinski agregati

Dizel i plinski agregati imaju znatnu važnost u sustavima proizvodnje električne energije. Najčešća primjena im je u svojstvu tzv. paralelnih generatora koji *ulaze* u pogon u slučaju gubitka primarnog izvora energije, najčešće pojne mreže. Osim uporabe kao paralelnog izvora energije mogu se koristiti i kao primarni izvor električne energije. Načelo funkcioniranja im je da se sastoje od motora s unutarnjim izgaranjem goriva čiji izlaz je spojen na generator koji elektromagnetskom pretvorbom proizvodi električnu energiju.

U svrhu uporabe generatora kao paralelnog sustava za slučaj nužde, gotovo 95% svih instaliranih sustava su zasnovani na dizelskom gorivu i prirodnom plinu [11]. Generatori se mogu razlikovati još i prema kvaliteti izvedbe, razini buke i razini emisije štetnih plinova.

Fundamentalna razlika između generatora na prirodni plin i onih na dizel gorivo je u tome što su dizelski generatori uvijek sa spremnikom, dok plinski generatori u pravilu nemaju spremnik već se izravno spajaju na plinsku mrežu. Spajanjem na plinsku mrežu omogućuje se plinskim generatorima da mogu raditi kontinuirano kao primarni (stalni) izvor električne energije ali i kao paralelni ovisno o konfiguraciji sustava kojeg napaja. Dizel generatori s druge strane se koriste gotovo uvijek kao paralelni generatori obzirom da imaju ograničenu količinu goriva na lokaciji. U pravilu, količina je goriva koje se sprema za paralelne sustave dostatna za 72 h [12] pogona pri 100% opterećenja.

Ukoliko se generatori koriste kao pomoćni, tada postoji mogućnost njihovog pogona i u trenutcima kada je glavni izvor energije aktivan, a u svrhu napajanja tereta ukoliko je trenutna cijena električne energije iz pojne mreže viša od troška pogona. Također, ovisno o tržištu na kojem je sustav implementiran postoji mogućnost uporabe paralelnih sustava u svrhu regulacije vršnog opterećenja u mreži za što vlasnik infrastrukture može dobiti premium naknade. U predmetnoj disertaciji takovi se slučajevi neće razmatrati.

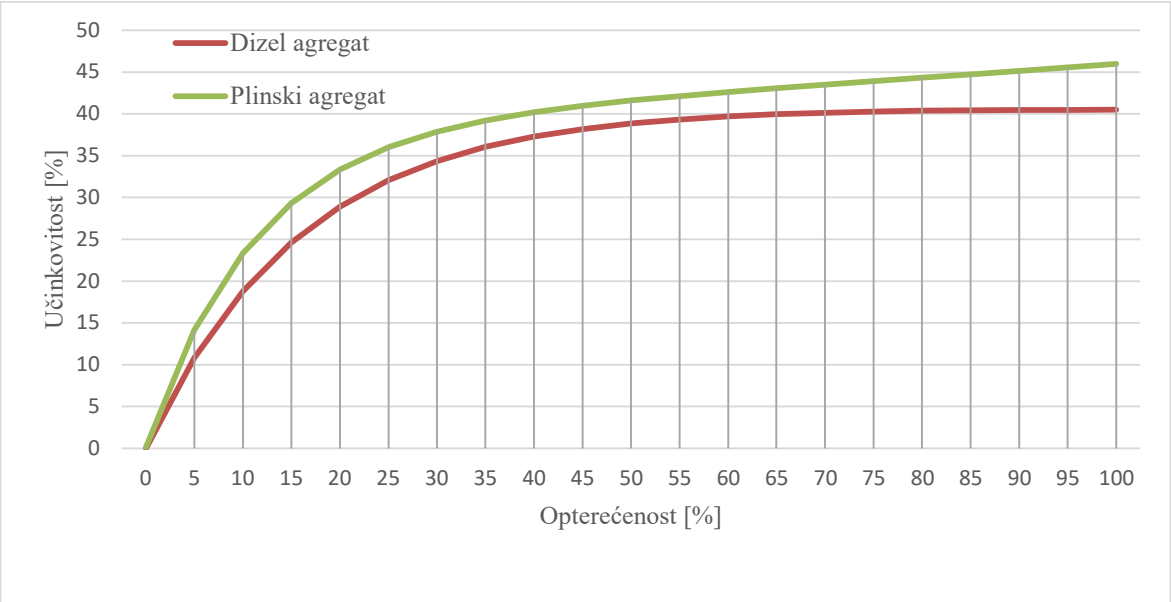
Dizel generatori, u pravilu, imaju niži trošak rezervnih dijelova u odnosu na generatore pogonjene prirodnim plinom. Suvremeni sustavi dizel generatora se opremaju na način da imaju smanjenu emisiju štetnih plinova. Unatoč tome, prosječna cijena instaliranog dizel generatora je 800 USD/kW dok su troškovi instaliranog generatora na prirodni plin 1 000 USD/kW, za generatore najvišeg standarda u pogledu sigurnosti i smanjenja emisije štetnih plinova [11].

Nakon što je generator dobavljen, instaliran i pušten u pogon isti treba biti periodički održavan, bez obzira na vrstu pogonskog goriva. Troškovi održavanja paralelnih generatora se mogu procijeniti na približno 35 USD/kW godišnje za oba tipa generatora [11]. Obzirom da su intervali održavanja minimalno jednom godišnje, može se pretpostaviti da nema bitne razlike u troškovima održavanja za generatore koji se upotrebljavaju kao primarni izvor električne energije, jer jedina razlika se može očitovati u slučaju potrebe za sitnim materijalima.

Unatoč tome što su nabavni troškovi dizel generatora niži od generatora na prirodni plin, troškovi pogona dizel agregata su znatno veći obzirom da je dizelsko gorivo skuplje od prirodnog plina.

Dizel generatori su jedan od najpoznatijih izvora korištenih u svrhu rezervnog napajanja u telekomunikacijskim i podatkovnim postrojenjima, ali, također, i u mnogim drugim industrijama poput nuklearnih postrojenja, bolnica i drugih kritičnih postrojenja. Dizel agregati imaju svojstvo da mogu preuzeti cijeli teret obično za manje od 10 sekundi od započete sekvence pokretanja. Obično mogu biti u pogonu približno 30 000 sati bez značajnijih kvarova [13]. Prema [14] čak dva od deset najvećih akcidenata u podatkovnim postrojenjima na svijetu u 2012. godini su povezani za nemogućnost pokretanja dizel agregata. Komponenta zadužena za neuspjeh starta dizel agregata je najčešće interna baterija (spremnik energije) zadužena za obavljanje inicijalnog starta i pokretanje rotirajuće mase. Iz tog razloga je nužno provoditi mjere redovitog održavanja.

Pri odabiru sustava zasnovanog prema principu motor-generator treba primijeniti ISO 8528-1 standard koji definira tri različita načina označavanja generatora: za kontinuiranu uporabu, primarni generator i pomoćni (paralelni) generator. *Uptime Institute* u radu [15] upućuje na to da generatori u podatkovnim centrima trebaju biti dimenzionirani s obzirom na kontinuiran rad i to u kW, dok u slučaju primarnih generatora treba smanjiti njihovu nazivnu snagu do 70% [11]. Na slici 2.1 prikazane su karakteristike učinkovitosti u ovisnosti o opterećenju dizel agregata [16] i plinskih agregata najnovije generacije [17].



Slika 2.1: Karakteristika učinkovitosti dizel i plinskog agregata u ovisnosti o postotnom opterećenju

2.2. Plinske turbine

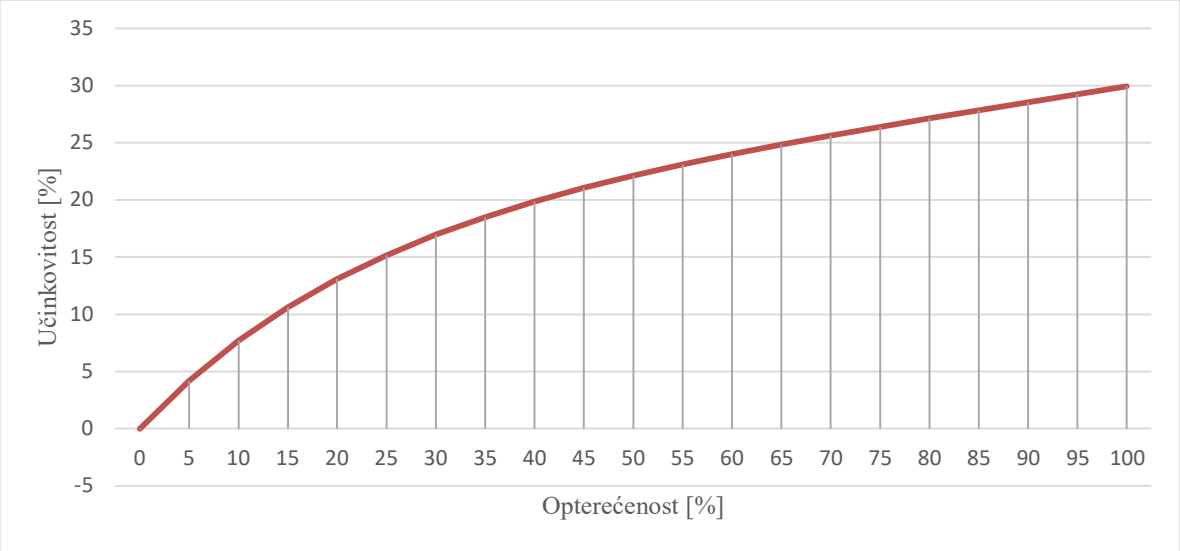
Plinske turbine su uobičajena vrsta strojeva za pogon generatora električne energije koja obično ima uporabu u području elektrana i tzv. propulzijskih sustava. Veličine plinskih turbina (bez mikroturbina) mogu biti između 500 kW i 250 MW i u pravilu koriste se kao strojevi za pogon generatora električne energije i topline (eng. *Combined Heat and Power* - CHP).

Sastoje se od tri najvažnije komponente, a to su: kompresor, dio za spaljivanje goriva i turbina. U svrhu analiziranja plinskih turbina obično se koriste Braytonov ili Jouleov ciklus.

U svrhu odabira prikladne plinske turbine s obzirom na primjenu, obično se treba razmotriti pet parametara: omjer tlakova, električna snaga na izlazu, ukupna učinkovitost, temperatura ispuha i protok ispuha.

Tijekom istraživanja nije identificirana značajnija korist pri uporabi plinskih turbina u usporedbi sa plinskim agregatom, što potvrđeno i u analizi malih i srednjih plinskih turbina [18] posebice u smislu učinkovitosti alocirane na proizvodnju električne energije.

Ukupna toplinska i električna učinkovitost CHP sustava je, obično, u rasponu između 65% do 70% [19] a emisije CO_2 su između 290 i 370 g/kWh. Omjer proizvedene energije i topline se obično mijenja u ovisnosti o veličini turbine i iznosi između 0,58 i 1,03 te se stoga treba uzeti u razmatranje pri odlučivanju obzirom da ima izravan utjecaj na rentabilnost sustava. Ovisno o lokaciji i dodatnoj opremi cijena instalirane plinske turbine je između 3 320 USD/kW i 1 276 USD/kW za 40 MW sustav [19]. Slika 2.2 predočava karakteristiku električne korisnosti malih plinskih turbina (1 MW) [16].



Slika 2.2: Karakteristika učinkovitosti plinske turbine u ovisnosti o postotnom opterećenju

Intervali preventivnog održavanja se provode svakih 4 000 sati što je približno pola godine a provodi se u svrhu kontrole vibracija koje mogu uzrokovati oštećenje vrhova krilaca ili preuranjenu istrošenost rotora. Veliko održavanje je potrebno obaviti svakih 25 000 do 50 000 sati te uključuje kompletnu restauraciju plinske turbine [20].

Osnovni podaci šest tipova plinskih turbina sa pripadnim svojstvima poput nazivne snage, potrošnje goriva i učinkovitosti jednog proizvođača prikazani su u tablici 2.1. Iz iste tablice je evidentno da je električna učinkovitost turbina između 23,7% i 35,5%, odnosno da je ukupna učinkovitost, električna i toplinska, varira između 64,9% i 70,6% ovisno o veličini turbine.

Tablica 2.1: Usporedba različitih plinskih turbina iz proizvodnog portfelja jednog od proizvođača [20]

	Sustav					
	1	**2**	**3**	**4**	**5**	**6**
Nazivna el. Snaga (kW)	3 515	4 600	7 965	11 350	21 745	43 069
Neto el. Snaga (kW)	3 304	4 324	7 487	10 669	20 440	40 485
Potrošnja goriva (m^3/h)	1,7528	2,1808	3,2325	4,797	7,7786	14,354
Korisna toplina (m^3/h)	0,7232	0,9299	1,3395	1,9262	2,8561	4,9373
Omjer snage i topline	0,58	0,58	0,70	0,70	0,90	1,03
El. Učinkovitost (%)	23,7	25,0	29,2	28,0	33,1	35,5
Toplinska učinkovitost (%)	41,1	42,7	41,4	40,2	36,7	34,4
Ukupna učinkovitost (%)	64,9	67,6	70,6	68,2	69,8	69,9

2.3. Vjetroelektrane

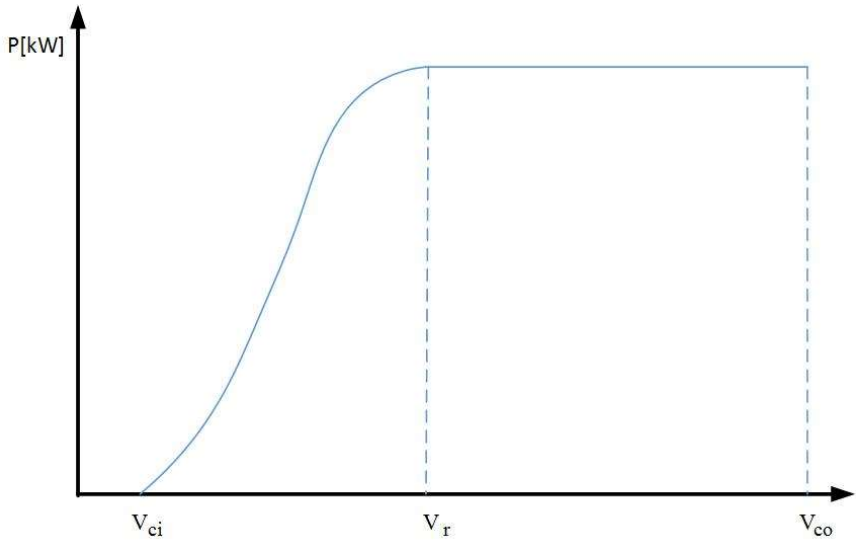
Vjetroelektrane imaju za svrhu pretvorbu kinetičke energije vjetra u električnu energiju korištenjem generatora. U toj pretvorbi brzina vjetra izravno ima utjecaj na izlaznu snagu. Slika 2.3 predočava karakteristiku vjetroelektrane koja opisuje ovisnost izlazne snage o brzini vjetra kao ulaznom parametru. Obično se ta karakteristika može podijeliti u četiri zone; kada je brzina vjetra manja od brzine pokretanja izlazna snaga je 0, između brzine pokretanja i brzine pune snage. Snaga je određena s krivuljom u skladu s jednadžbama 2.1 – 2.4, između brzine pune snage i brzine isključenja snage na izlazu [21]. U slučaju prekoračenja brzine isključenja vjetroelektrana odlazi u sigurnosni mod tako da pomakne krilca u smjeru ostvarivanja najmanjeg otpora vjetru te se aktivira automatski kočioni sustav, što rezultira sa 0 izlazne snage.

Teoretska povezanost između brzine vjetra i izlazne snage definirana je sljedećom jednadžbom:

$$P = \frac{\rho_{zraka}}{2} c_p A_r v^3 \tag{2.1}$$

gdje P označava izlaznu snagu iz vjetroelektrane, ρ_{zraka} gustoću zraka, c_p koeficijent značajke vjetroagregata, A_r površina pokrivena rotorom a v brzina vjetra. Koeficijent značajke vjetroturbine funkcija je kuta otklona krila prema ravnini rotacije i ujedno je omjer između brzine okretanja

rotora s krilima i brzine vjetra. Sukladno Betzovom zakonu vjetroturbina ne može uzeti više od 16/27 snage vjetra.



Slika 2.3: Karakteristika izlazne električne snage iz vjetroagregata u ovisnosti o brzini vjetra

Sukladno [22], Karakteristika izlazne električne snage iz vjetroagregata u ovisnosti o brzini vjetra se može opisati setom jednadžbi 2.2 – 2.3, gdje je v_{ci} brzina vjetra pri kojoj vjetroagregat počinje generirati električnu energiju, v_r brzina pri kojoj se ostvaruje nazivna snaga vjetroagregata, v_{co} brzina pri kojoj vjetroagregat se zaustavlja zbog sigurnosti uslijed prevelike brzine vjetra, dok P_r označava nazivnu snagu vjetroagregata:

$$P(v) = \begin{cases} 0 & 0 \le v < v_{ci} \\ (A + B\,v + C\,v^2)\,P_r & v_{ci} \le v < v_r \\ P_r & v_r \le v < v_{co} \\ 0 & v \le v_{co} \end{cases} \tag{2.2}$$

$$A = \frac{1}{(v_{ci} - v_r)^2}\left\{v_{ci}(v_{ci} + v_r) - 4v_{ci}v\left[\frac{v_{ci} + v_r}{2v_r}\right]^3\right\}$$

$$B = \frac{1}{(v_{ci} - v)^2}\left\{4v_{ci}v_r\left[\frac{v_{ci} + v_r}{2v_r}\right]^3 - (3v_{ci} + v_r)\right\} \tag{2.3}$$

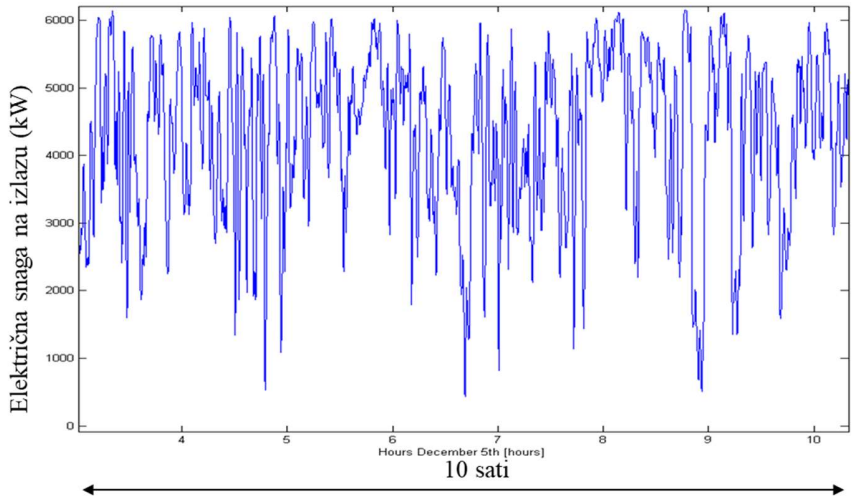
$$C = \frac{1}{(v_{ci} - v_r)^2}\left\{2 - 4\left[\frac{v_{ci} + v_r}{2v_r}\right]^3\right\}$$

Iz tablice 2.2 vidljivo je da mehaničke komponente VE, elise, generatora i reduktora čine više od 80% udjela u trošku održavanja vjetroagregata, te, također imaju udio u ukupnoj neraspoloživosti vjetroagregata veći od 80% [23]. S druge strane, električni dio sustava karakterizira značajna raspoloživost i relativno neznatan udio u troškovima održavanja.

Tablica 2.2: Raspoloživost elemenata vjetroturbine i udio u ukupnom trošku

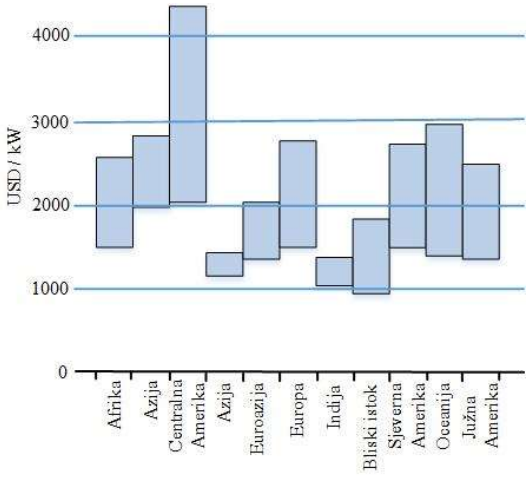
Element VE	**Udio u neraspoloživosti**	**Udio u trošku**
Elisa	34%	30%
Generator	32%	28%
Reduktor	21%	19%
Električni razvod	5%	5%
Kontrolni sustav	2%	5%
Sustav skretanja	2%	4%
Sustav zakretanja	2%	3%
Osovina i ležaj	1%	4%
Inverter	1%	1%
Kočioni sustav	0%	1%

Na slici 2.4 prikazane su realne vrijednosti izlazne snage koja se kreće od maksimalnih 6 MW do minimalnih 360 kW, što je posljedica ovisnosti izlazne snage o trećoj potenciji brzine vjetra sukladno izrazima (2.2) i (2.3).



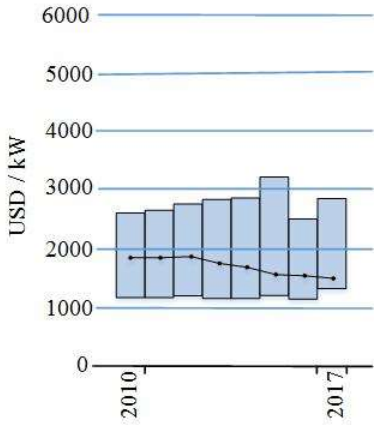
Slika 2.4: Primjer karakteristike izlazne snage iz grupe vjetroagregata tijekom perioda od 10 sati u zapadnoj Australiji, projekt kompanije ABB Ltd.

Na slici 2.5 prikazan je raspon troškova za instalirani kW vjetroagregata u više regija svijeta ukazujući na najveći raspon troškova i ujedno najveći iznos u regiji Centralne Amerike, dok su najniži troškovi zabilježeni u Indiji.



Slika 2.5: Prosječne cijene instaliranog kW vjetroagregata globalno na kopnu u 2016, izraženo u USD [24]

U razdoblju od 2010. do 2017. bilježi se pad troškova instalacije vjetroelektrana na kopnu od 20% s padom tzv. niveliranog troška proizvodnje električne energije od 22%, što je prikazano na slici 2.6. Unatoč padu srednje vrijednosti troškova za instalirani kW vjetroagregata, raspon troškova je i dalje širok dok se srednja vrijednost nalazi neposredno blizu najniže vrijednosti, indicirajući na trend gradnje sve većih vjetroagregata čiji su troškovi dobave, instalacije i puštanja u pogon znatno niži u odnosu na manje.



Slika 2.6: Prosječne cijene instaliranog kW vjetroagregata na kopnu 2010. - 2016. izražene u USD [24]

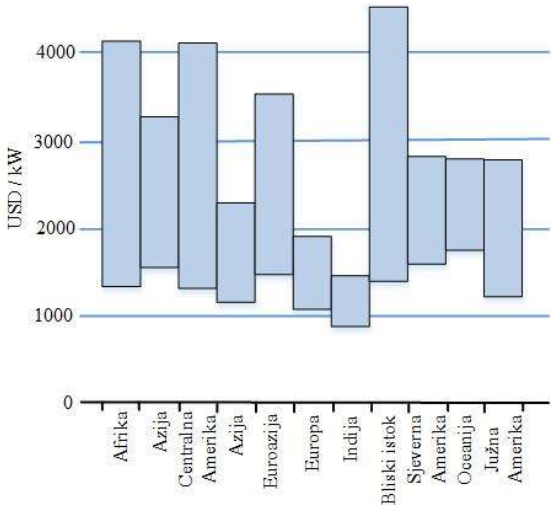
Tipična raspoloživost koju jamče proizvođači vjetroagregata je 97% za vjetroagregate na kopnu i 95% za vjetroagregate na pučini [25].

2.4. Sunčeve elektrane

Energija Sunca se može smatrati jednom od najčišćih i održivijih energija s gotovo neiscrpnim izvorom. Potencijal uporabe Sunčeve energije je znatan, no, također, su i znatni izazovi stavljeni pred znanstvenu i tehničku zajednicu u smislu prikupljanja iste. Tehnologija sunčevih elektrana se i dalje razvija još i danas, te je zasigurno jedan od najboljih *kandidata* za jedan od glavnih izvora električne energije u 21.st.

Sunčeve elektrane se, strukturno, mogu podijeliti u dvije vrste: koncentrirajuće i fotonaponske Sunčeve elektrane. Koncentrirajuće Sunčeve elektrane funkcioniraju na način da se Sunčeve zrake koncentriraju uporabom zrcala i leća prema maloj površini koja proizvodi toplinu odakle se toplina odvodi i koristi na konvencionalan način kao što je to slučaj u termoelektranama, posredstvom turbina. Predmet ovog istraživanja u pogledu Sunčevih elektrana su fotonaponske tehnologije, te se u nastavku akronim SE odnosi na fotonaponske sunčeve elektrane.

U 2016. godini najniži troškovi instaliranog kW fotonaponske sunčeve elektrane zabilježeni su u Indiji a sljedeća regija sa najnižim troškovima je Europa kako je prikazano na slici 2.7.

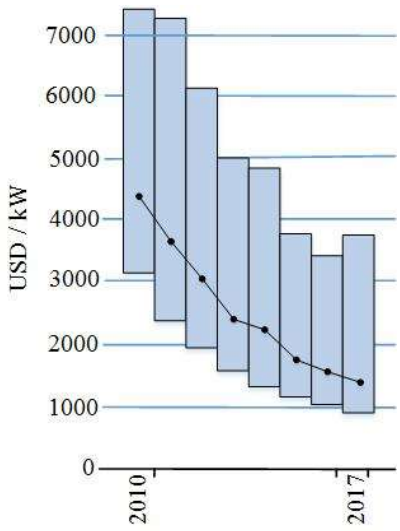


Slika 2.7: Prosječne cijene instaliranog kW sunčeve elektrane (fotonaponski tip) globalno na kopnu u 2016, izraženo u USD [24]

Fotonaponske SE funkcioniraju prema principu pretvorbe sunčeve kratkovalne radijacije u električnu energiju pomoću fotoelektričnog efekta u poluvodičima poput monokristalnog ili polikristalnog silicija ili tehnologije tankog filma. Najzastupljenija tehnologija izvedbe danas je zasnovana na polikristalnim silicijevim ćelijama s udjelom od 54,5% u ukupnom tržištu, dok je sljedeća najzastupljenija tehnologija zasnovana na monokristalnim silicijskim ćelijama s udjelom u tržištu od 29,36% [26]. Fotonaponski modul kao najmanja samostalna jedinica, sastoji se od poluvodičkih panela, nosača i spojih električkih kutija. Obzirom da je stvorena električna energija iz fotonaponskih modula istosmjernog karaktera (DC) u primjenama gdje su tereti izmjeničnog karaktera (AC) nužna je uporaba izmjenjivača električne energije (inverter).

Obzirom da su Sunčeve elektrane u varijanti fotonaponskih panela stacionarne i ne posjeduju pomične dijelove potrebne za pretvorbu energije inherentno posjeduju visok stupanj pouzdanosti i raspoloživosti.

U periodu između 2010. i 2017. bilježi se pad troškova instalacije fotonaponskih modula za 68% za industrijsku primjenu te se, također, bilježi pad tzv. niveliranog troška proizvodnje električne energije iz istih tehnologija za 73% tijekom istog perioda, sukladno slici 2.8 [24].



Slika 2.8: Prosječne cijene instaliranog kW sunčeve elektrane (fotonaponski tip) na kopnu 2010. - 2016. izražene u USD [24]

U tablici 2.3 prikazane su različite vrste poluvodičkih tehnologija fotonaponskih ćelija. Tehnologije zasnovane na monokristalnom siliciju imaju učinkovitost između 4,5% i 20,3%

indicirajući na pospješivanje iste tehnologije tijekom vremena. Najviša učinkovitost među prikazanim tehnologijama je 39% i odnosi se na troslojnu poluvodičku tehniku.

Tablica 2.3: Pregled tehnologija fotonaponskih ćelija sa pripadajućim stupnjem djelovanja [27]

Tehnologija solarnih ćelija	**Učinkovitost**
Monokristalni silicij	4,5 – 20,3%
Amorfni silicij	1,10%
Galij-indij fosfid / Galij-arsenid; sa konektorima	>30,0%
Fotoelktrokemijske, Grätzel	12,20%
CIS tanki film	19,20%
Multikristalni silicij	20,30%
Aluminij-galij-indij fosfid / Galij-indij arsenid / germanij; tri sloja sa konektorima	39,00%

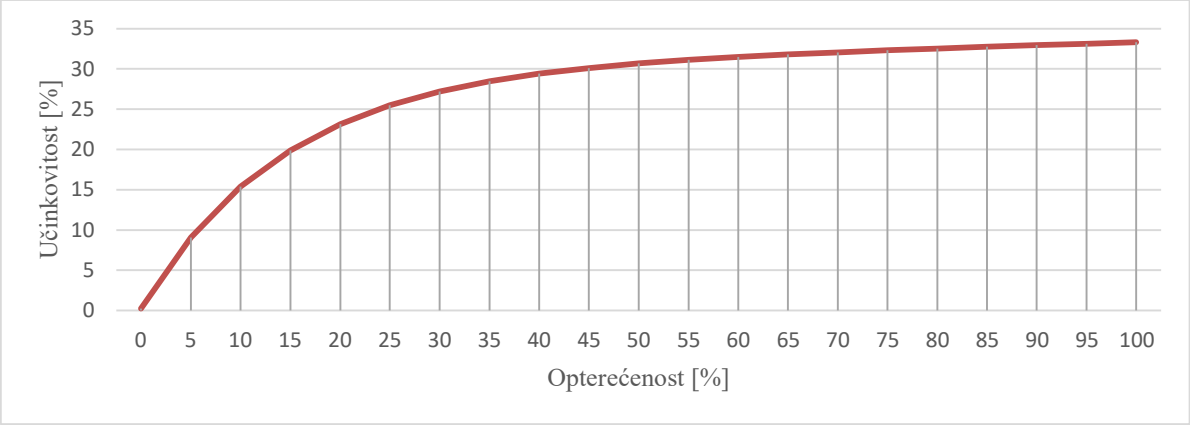
2.5. Plinske mikro turbine

Mikroturbine su strojevi za pogon generatora električne i toplinske energije, te imaju primjenu u industriji sličnu kao i standardne plinske turbine, no s obzirom na manju snagu mogu se koristiti i u rezidencijalnom sektoru kao i u industrijama koje ne zahtijevaju snage veće od 1 MW. Plinske mikroturbine su turbo alternatori koji se sastoji od centrifugalnog kompresora, radijalne turbine alternatora izvedenog kao rotor a rade prema principu Braytonovog ciklusa [28]. Umjesto mjenjačke kutije u klasičnim slučajevima primjenjuju se elementi iz područja energetske elektronike [29].

Osim što imaju mogućnost sagorijevanja različitih vrsta goriva [30], također, su u mogućnosti imati pogon korištenja energije biomase. Obično imaju konstrukciju zasnovanu na jednom vratilu što je mongo lakše i jeftinije za proizvesti u odnosu na varijante s dva vratila, a generator može biti smješten nasuprot ispuha tako da ispušni plinovi mogu *napustiti* turbinu uz manji gubitak tlaka što u konačnici omogućuje veću snagu na izlazu i ujedno smanjuje potrošnju goriva.

Najveće prednosti mikro turbina su što su lagane i kompaktne, imaju nisku razinu buke, jednostavan sustav rekuperacije topline, trebaju malo održavanja pogotovo u izvedbama s automatskim podmazivanjem. Plinske mikroturbine imaju relativno nizak stupanj emisije CO_2 u odnosu na starije tipove plinskih strojeva, no viši u odnosu na plinske strojeve nove generacije i

gorive ćelije. Slika 2.9 prikazuje karakteristiku učinkovitosti plinske mikroturbine zasnovane na tabličnim vrijednostima iz [31].



Slika 2.9: Karakteristika učinkovitosti plinske mikro turbine u ovisnosti o postotnom opterećenju [31]

Novije generacije plinskih mikroturbina imaju svojstvo naprednog spaljivanja te na taj način minimiziraju emisije štetnih tvari kao što su *CO*, CO_2, NO_x. Ovisno o vrsti mikroturbine s obzirom na to otvoreni ciklus ili uporabu rekuperatora neto učinkovitosti se razlikuju. Neto električna učinkovitost mikroturbina s otvorenim ciklusom je približno 17% što je razmjerno malo u odnosu na do 30% u slučaju mikroturbina s rekuperatorom [32].

Tvrtka *Capstone* je jedna od najpoznatijih proizvođača mikroturbina u SAD-u, čije mikroturbine koriste visoki omjer zraka prema gorivu u zoni primarnog spaljivanja [33]. U tablici 2.4 prikazana su svojstva pet mikroturbina iz asortimana sa različitim svojstvima iz koje se može iščitati da je mikroturbina nazivne snage 333 kW ujedno i najučinkovitija, odnosno ima najmanju emisiju CO_2.

Tablica 2.4: Podaci mikroturbina kompanije Capstone [33]

Nominalna snaga (kW)	65	200	250	333	1 000
Neto el. snaga (kW)	61	190	242	323	950
Potrošnja (m^3/h)	0,031	0,0845	0,1162	0,1421	0,4218
El. Učinkovitost	24,7%	28,4%	26,1%	28,7%	28,3%
Trošak uređaja i materijala USD/kW	2 120	2 120	1 830	1 750	1 710
Troškovi instalacije USD/kW	1100	1030	870	800	790
Troškovi pogona bez goriva USD/kWh	1,3	1,6	1,2	0,8	1,2
CO_2 (kg/MWh)	1613	1406	1529	1392	1407

Rano miješanje zraka i goriva omogućuje čišće spaljivanje pri nižim temperaturama što rezultira smanjenom emisijom štetnih čestica i boljim spaljivanjem *CO* i hidrokarbonata. Capstonove mikroturbine mogu raditi u različitim modalitetima: samostalno kao osnove za mikromrežu ili biti spojene na mrežu. Moguće ih je paralelno spajati te na taj način ako je potrebno stvarati zalihost, a osim toga mogu će ih je i paralelno spojiti sa drugim izvorima električne energije. Pogonsko gorivo im može biti plin, ukapljeni plin ili bioplin.

2.6. Gorive ćelije

Gorive ćelije se, danas, koriste u mnogim industrijama, a među kojima i u telekomunikacijskoj i podatkovnoj industriji. Tvrtke i proizvođači električne energije odabiru gorive ćelije zbog njihove pouzdanosti, učinkovitosti i smanjenja emisije štetnih čestica.

Gorive ćelije koriste vodik kako bi stvorile vodu, električnu energiju i toplinu [34]. Obzirom da je primjena gorivih ćelija jako široka, također je moguće i koristiti različite tipove goriva ovisno o primjeni. U autonomnim sustavima kao što su vozila ili u sustavima telekomunikacija udaljene pristupne točke mobilnih telekomunikacija, zbog nepostojanja lokalne pojne električne i plinske mreže, koristi se čisti vodik u spremnicima kao pogonsko gorivo. Druga varijanta je za stacionarne primjene gdje postoji razvijena plinska mreža, te se koriste goriva bogata vodikom kao što je prirodni plin. Obzirom da gorive ćelije ne spaljuju gorivo na način kao što je to slučaj s plinskim turbinama, njihova električna učinkovitost je visoka.

Osim prema pogonskom gorivu, gorive ćelije se razlikuju i prema tehnologiji izvedbe koja je odabrana s obzirom na primjene u specifičnim industrijama. Kao najpopularnija tehnologije ističe se tehnologija zasnovana na krutim oksidima [35], [36] (eng. *Solid Oxide Fuel Cell - SOFC*).

U SAD-u postoje mnogi primjeri uporabe gorivih ćelija u telekomima i podatkovnim centrima [37]. U First National Bank of Nabraska u uporabi je sustav gorivih ćelija je u uporabi više od 20 godina a prije implementacije tvrtka je koristila napajanje iz mreže s paralelnim dizel generatorom u svrhu napajanja glavnog podatkovnog centra. Obzirom da je pojna mreža loše kvalitete prilikom gubitka napajanja mreže dizel generatori nisu startali a tvrtka je bila suočena sa golemim financijskim

gubitcima, procijenjenim na oko 6 milijuna USD. Otkako u uporabi imaju gorive ćelije (četiri jedinice od 200 kW) kao primarni sustav napajanja, raspoloživost sustava napajanja električnom energijom je 99,9999%. Kompanije kao što se Microsoft, Apple, eBay, Google, Verizon, JP Morgan Chase su također implementirale gorive ćelije na mnogim svojim lokacijama.

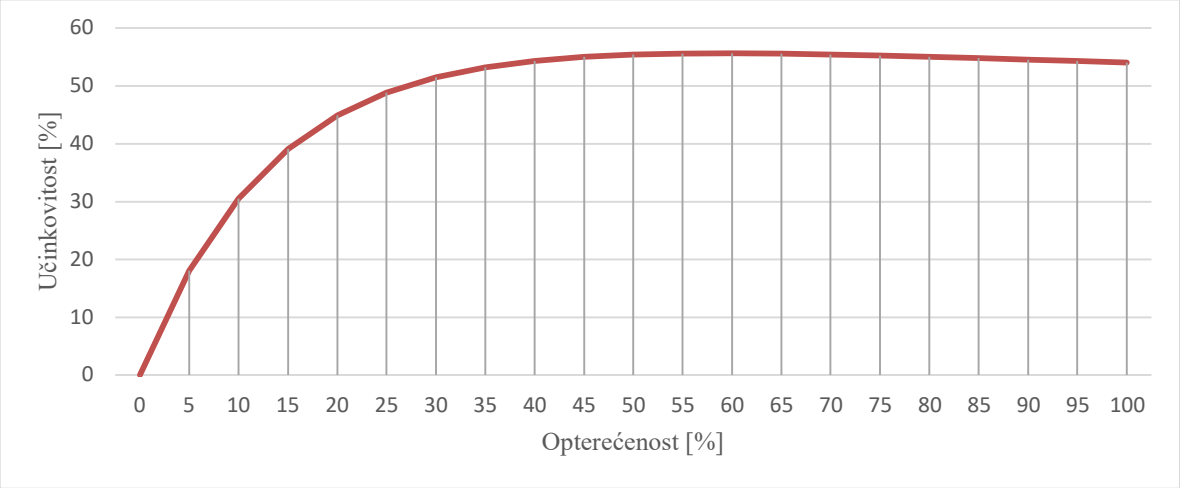
Pregled najrelevantnijih tehnologija gorivih ćelija s obzirom na primjenu, snagu, učinkovitost, prednosti i nedostatke dana je u tablici 2.5. Iz tablice je evidentno kako sve spomenute tehnologije imaju električnu učinkovitost između 40% i 60% od kojih čak 50% ima učinkovitost od 60%.

Tablica 2.5: Pregled tehnologija gorivih ćelija [38]

Tehnologija gorive ćelije	**Pogonska temperatura**	**Električna učinkovitost**	**Raspon snage (kW)**	**Primjena**	**Prednosti**	**Nedostaci**
Polimerna elektrolitska membrana	<120°C	60%	1-100	Transport, paralelni pomoćni sustav	Smanjena korozija, niska temperatura, mogućnost brzog starta	Osjetljivost na nečistoće u gorivu, skup katalizator
Alkalne	<100°C	60%	1-100	Vojska, svemir, transport	Niski troškovi komponenti, niska temperatura, mogućnost brzog starta	Osjetljivost na CO_2 u gorivu i zraku, provodljivost elektrolita
Fosforna kiselina (PAFC)	150-200°C	40%	5-400	Distribuirana proizvodnja	Tolerancija na nečistoće u gorivu	Dugo puštanje u pogon, skup katalizator
Otopljeni karbonati (MCFC)	600-700°C	50%	300-3000	Elektroenergetska postrojenja, distribuirana proizvodnja	Visoka učinkovitost, raznolikost goriva, prihvaćanje karbonata	Dugo puštanje u pogon, korozija, mala gustoća snage
Kruti oksid - SOFC	500-1000°C	60%	1-2000	Elektroenergetska postrojenja, distribuirana proizvodnja, pomoćni paralelni sustav	Visoka učinkovitost, raznolikost goriva, reverzibilni pogon	Dugo puštanje u pogon, korozija, ograničen broj puštanja u pogon

Jedan od najvećih proizvođača gorivih ćelija, *Bloom Energy*, omogućio je američkoj telekomunikacijskoj tvrtki *AT&T* sustav od 9,6 MW što je učinilo *AT&T* najvećom tvrtkom koja nije spojena na električnu mrežu u SAD-u [37]. Proizvod kompanije *Bloom Energy*, pod nazivom *Bloom Box* [39] unatoč svojim prednostima kao što su visoka učinkovitost i raznolikost u uporabi goriva, ima nekoliko nedostataka kao što su visoka nabavna cijena i visoke operativne temperature koje su između 800°C i 1 000°C. Obzirom da sustav radi na vrlo visokoj temperaturi vjerojatnost za kvarove uzrokovane ubrzanom degradacijom se povećava, iako nema zabilježbe o postojanju akcidenta vezanog za taj proizvod. Također važno je za napomenuti da je vrijeme starta istog sustava relativno dugačko, i prema saznanjima stručnjaka u *Bloom Energy* potvrđeno je da je potrebno sedam dana za podizanje jedinice od 200 kW. Druga varijanta proizvoda dolazi iz tvrtke *Ceres Power* i njihova goriva ćelija ima operativnu temperaturu između 500°C i 600°C [40], [41], što omogućava da elektrokemijski elementi budu tanji a kao krajnji rezultat sustav može startati znatno brže. Proizvodi spomenutih kompanija su zasnovani na SOFC tehnologiji.

Iz navedenih razloga, jedina smislena uporaba gorivih ćelija u stacionarnim primjenama je u svrhu primarnog sustava napajanja. Na slici 2.10 prikazana je karakteristika učinkovitosti gorivih ćelija izvedena iz [16].



Slika 2.10: Karakteristika učinkovitosti gorive ćelije u ovisnosti o postotnom opterećenju

Iako su najznačajnija istraživanja i primjene gorivih ćelija na području SAD-a, u Europi se također zadnjih godina intenzivno radi na razvoju gorivih ćelija kroz *Framework Program 6* u sklopu kojeg se investira oko 60 milijuna Eura godišnje u razvoj gorivih ćelija. Razvojni projekt u Europi se

primarno orijentira na razvoje gorivih ćelija zasnovanih na SOFC i PEMFC tehnologijama [38]. Određivanje troškova kapitalnih ulaganja u ovu tehnologiju je zahtjevno, obzirom da cijena variraju između 2 000 i 10 000 EUR za instalirani kW [38]. Bloom je u svojoj izvedbi od 100 kW postigao tržišnu cijenu između 7 000 i 8 000 USD za instalirani kW 2010. godine [39]. U predmetnoj disertaciji korištena je cijena u iznosu od 4 000 USD za instalirani kW sustava [37], SOFC tipa gorive ćelije, obzirom da je to cijena koju se može postići u SAD-u i obzirom da je prošlo više od devet godina od dostupnih relevantnih cijena. Izvještaj [38] potvrđuje da je moguće postići stvarnu nabavnu cijenu u iznosu od 3 000 do 4 000 USD za kW instalirane snage.

2.7. Male hidroelektrane

Hidroelektrane su vrsta izvora električne energije s najduljom primjenom i dokazanom djelotvornošću [42] od preko sto godina te se smatraju fleksibilnim i pouzdanim izvorom električne energije. Malim hidroelektranama se smatraju one elektrane s mogućnosti proizvodnje električne snage do 10 MW. Postoji više tipova hidroelektrana s obzirom na raspoložive zalihe vode, izvedbe turbine i vrste opterećenja [43]. U radu [44] iznesen je model u kojem u hidroelektrani je instalirano pet turbina od kojih su dvije u stalnom pogonu što dovodi do optimalne razine raspoloživosti, pouzdanosti i kapaciteta, te u toj konfiguraciji operativna raspoloživost hidroelektrane je u razini od 97%.

Munteanu i Nemes u radu [45] ukazuju na vremensku razdiobu kvarova u hidroelektranama u iznosima:

56,2% kvarovi na generatorima

31,3% kvarovi turbine

12,2% kvarovi hidrogeneratora.

U ovom radu hidroelektrane se neće razmatrati kao potencijalni kandidat za napajanje podatkovne i telekomunikacijske infrastrukture obzirom na stupanj operativne raspoloživosti, veliki kapacitet

koji je potrebno instalirati u svrhu postizanja operativne raspoloživosti kao i potrebu za lociranjem infrastrukture u neposrednoj blizini vode što dovodi do potencijalnog rizika od plavljenja i slično.

2.8. Geotermalne elektrane

Male geotermalne elektrane mogu biti dobar kandidat za napajanje podatkovne i telekomunikacijske infrastrukture obzirom na konstantnu raspoloživost primarnog izvora energije tj. topline iz unutrašnjosti Zemljine kore.

Općenito postoje tri vrste geotermalnih elektrana:

- s suhom parom
- s parom atmosferskog tlaka koja se oslobađa ispuštanjem kondenzata višeg tlaka (jednostruke i dvostruke), (eng. flash steam, single and double) i
- binarne

Kagel, Bates i Gawell u [46] ukazuju na to da se geotermalne elektrane mogu smatrati elektranama s visokom razinom raspoloživosti u iznosu od 95%. Gehringer i Loksha u priručniku o geotermalnoj energiji [47] ukazuju na činjenicu da je 42% svih geotermalnih elektrana na svijetu zasnovano na tehnologiji jednostrukog postrojenja sa ispuštanja kondenzata dok je 21% zasnovano na dvostrukom postrojenju iste tehnologije. Iz potanjega se može zaključiti da je glavnina geotermalnih elektrana koje sudjeluju u rezultiranoj razini raspoloživosti od 95% zasnovano na tehnologiji ispuštanja kondenzata (ukupno 63%). Legmann i Citrin u radu [48] opisuju geotermalnu elektranu Mokai na Novom Zelandu instalirane snage 60 MW, zasnovane na binarnoj tehnologiji i postignute operativne raspoloživosti u iznosu od 97% tijekom prve godine korištenja.

2.9. Spremnici energije

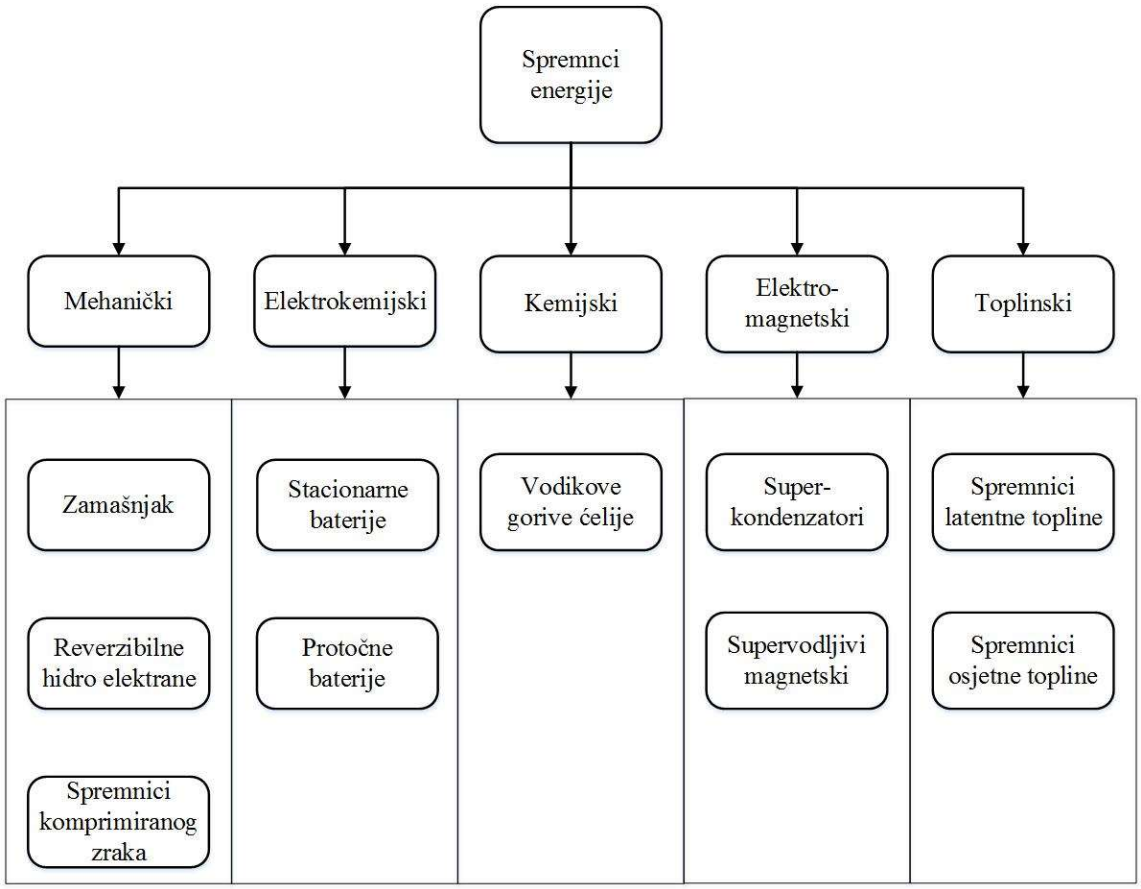
2.9.1. Općenito

Spremnici energije imaju znatnu važnost u kritičnim (važnim) industrijama budući da trenutno mogu omogućiti proizvodnju električne energije u slučaju nužde. Najčešća primjena spremnika energije u podatkovnim i telekomunikacijskim postrojenjima je da u slučaju nestanka primarnog napajanja (najčešće pojne mreže) omoguće nesmetanu opskrbu tereta s električnom energijom. U telekomunikacijskim sustavima najčešće se sreću autonomije alocirane na spremnike energije od 2 do 4 sata u pristupnim točkama (*eng. Access Point*) dok u jezgrama telekomunikacijske mreže autonomije su od 4 do 8 sati (bez paralelnih izvora električne energije). U slučaju podatkovne infrastrukture autonomije alocirane na spremnike energije su najčešće između 10 sekundi do 15 minuta, obzirom da podatkovna infrastruktura uvijek podrazumijeva paralelne izvore energije, što ne mora nužno biti slučaj u telekomunikacijskoj infrastrukturi.

U spomenutim slučajevima spremnici energije uvijek imaju ulogu da premoste vremenski dio od trenutka nestanka glavnog napajanja do njegovog povratka ili do uspješnog pokretanja paralelnog sustava energije. U slučaju telekomunikacijske infrastrukture dimenzije spremnika energije su veće obzirom da se očekuje da su spremnici dovoljno veliki da mogu dati dovoljno energije do povratka pojne mreže, dok u slučaju podatkovne infrastrukture se uvijek računa s tim da se mora gotovo trenutno pokrenuti paralelni izvor napajanja te stoga spremnik energije treba biti dostatan da premosti to vrijeme. Također, podatkovna infrastruktura je, u pravilu, znatno veća od telekomunikacijske u smislu instalirane snage i kritičnih tereta, te stoga *gomilanje* rezerve postaje nerentabilno.

Sve češćom uporabom obnovljivih izvora energije u telekomunikacijama kao i hibridnih rješenja zasnovanih na npr. dizel agregatima i baterijama, javlja se potreba za rješenjima sa spremnicima energije koji će moći podnijeti zahtjevnije uvjete od onih u paralelnim primjenama. U izoliranim mikromrežama nužno je koristiti spremnike energije u svrhu omogućavanja njihanja energije, odnosno spremati energiju kada izvor energije proizvodi više nego što je potrebno teretu te imati mogućnost *puštanja* energije prema teretu u slučaju ako se generira nedostatna količina električne energije za teret. Stoga, nužno je da spremnik energije može podnijeti vremenski dugačke autonomije, te imati svojstvo *preživljavanja* znatnog broja ciklusa punjenja i pražnjenja.

Spremnici energije se, u principu, mogu podijeliti na mehaničke, elektrokemijske, kemijske, elektromagnetske i termalne. Na slici 2.11 je predočena osnovna podjela spremnika energije, prema [49]. U radu će se analizirati najvažniji tipovi spremnika energije.



Slika 2.11: Klasifikacija spremnika energije [49]

2.9.2. Reverzibilne elektrane

Sastoje se od dva spremnika energije koje se nalaze na različitim visinama [50]. U slučaju postojanja viška električne energije u sustavu uporabom crpke voda se s točke nižeg potencijala dovodi na točku višeg potencijala. U slučaju nedostatka električne energije u sustavu voda se dovodi s višeg potencijala prema nižem prelazeći pri tome kroz (vodenu) turbinu koja tada s generatorom proizvodi električnu energiju i predaje istu u odgovarajući (elektroenergetski) sustav.

2.9.3. Spremnik komprimiranog zraka

U slučaju postojanja viška energije u pogon se pokreće električni kompresor koji komprimira zrak u spremnik dok u slučaju nedostatka energije komprimirani zrak izlazi van iz spremnika pod visokim tlakom preko turbine koja s generatorom proizvodi električnu energiju [51]. Spremnici komprimiranog zraka za velike energije se mogu ukopati pod zemlju.

2.9.4. Zamašnjak

Zamašnjak je vrsta rotacijskog spremnika energije gdje je energija pohranjena u rotirajuću masu, tj. u njezinu tromost [52]. Zamašnjak se uglavnom sprema u vakuumski spremnik kako bi se smanjili gubici uzrokovani trenjem. Za vrijeme normalnog pogona brzina zamašnjaka je između 20 000 i 50 000 r/min i rotira stalnom brzinom. Tek u slučaju potrebe za aktivacijom energije iz spremnika zamašnjak prelazi u generatorski režim rada i ispušta energiju pri čemu mu postupno opada brzina vrtnje. Zamašnjaci su prikladni za uporabu gdje su autonomije potrebne od 1 do 30 sekundi. Dobrobit pri uporabi zamašnjaka se očituje u tome što je poprilično otporan na smetnje iz pojne mreže. Kao nedostatak za uporabu zamašnjaka se navodi cijena i održavanje.

2.9.5. Supervodljivi magnetski spremnici energije

Spremnici energije zasnovani na supervodljivim magnetima se sastoje od supervodljive zavojnice, sustava za regulaciju snage, hladnjaka i vakuuma [53]. Energija je pohranjena u magnetskom polju a sustav ima primjenu u stabilizaciji sustava za brzo djelovanje kao što je u kombinaciji s vjetroelektranama. Autonomije ovih sustava su uglavnom između nekoliko milisekundi do 10 sekundi.

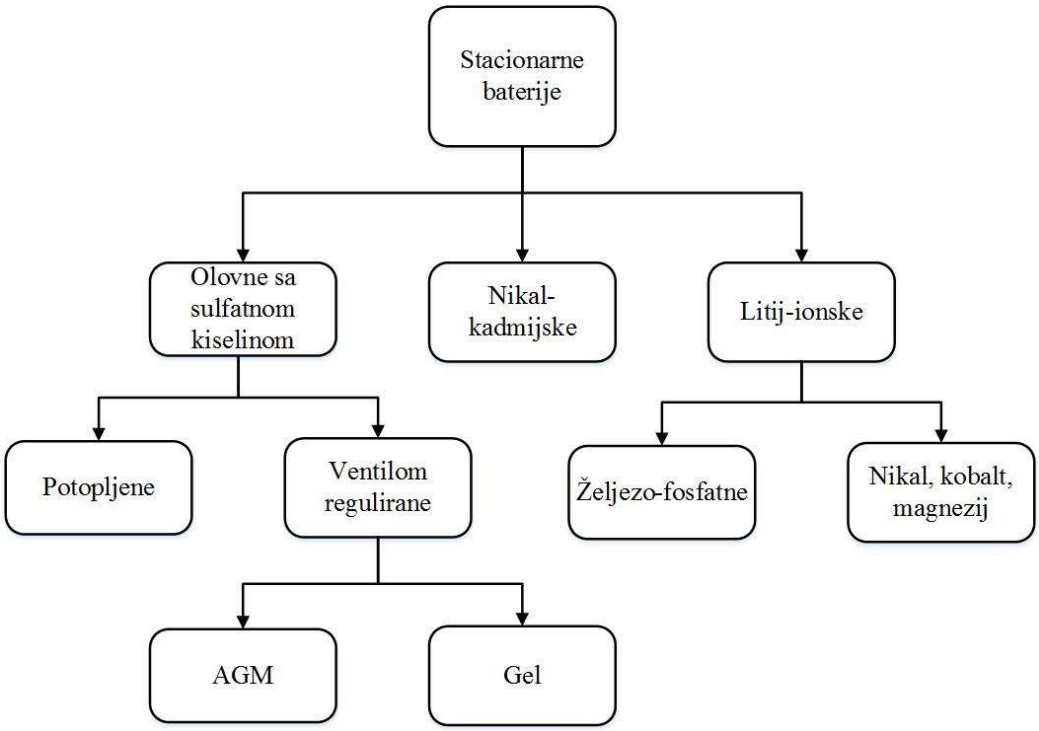
2.9.6. Superkondenzator

Koriste otopinu elektrolita između dva kruta vodiča [54]. U usporedbi s klasičnim kondenzatorima imaju veću kapacitivnost i gustoću energije. Vrlo su izdržljivi i pouzdani a primjena im je u glavnom ista kao i u slučaju supervodljivih magnetskih spremnika energije. Autonomije koje mogu postići su između 1 sekunde sve do 1 sata.

2.9.7. Baterijski spremnici energije

Baterije su elektrokemijski tip spremnika energije [55], [56]. Imaju jako široku uporabu a primarna uporaba u telekomunikacijskoj i podatkovnoj infrastrukturi je kao paralelni sustav energije [10]. Uvid u osnovnu podjelu tehnologija stacionarnih baterija dan je na slici 2.12. Najčešće varijante

baterija u telekomunikacijskoj i podatkovnoj infrastrukturi su olovne baterije sa sulfatnom kiselinom u izvedbi kućišta za minimalno održavanje odnosno regulacijskim ventilom (eng. *Valve Regulated Lead Acid battery - VRLA*) i u zadnje vrijeme sve više litij ionske baterije.

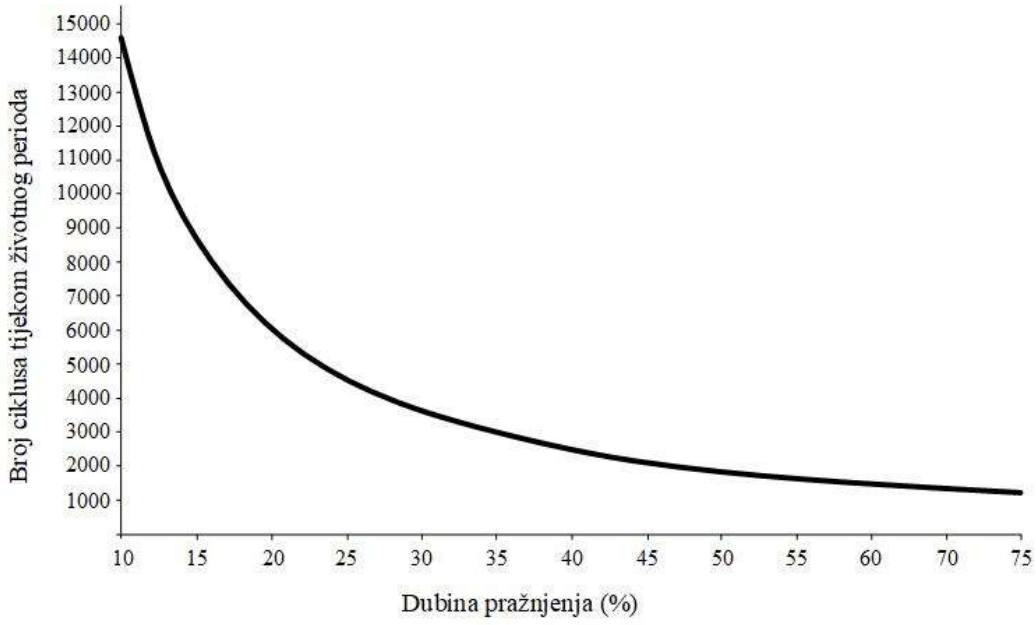


Slika 2.12: Klasifikacija stacionarnih baterija [10]

2.9.8. VRLA baterije

VRLA tip baterije je najzastupljenija tehnologija spremnika energije u telekomunikacijskoj i podatkovnoj infrastrukturi. VRLA tehnologije se mogu podijeliti na paralelne i visokociklirajuće. Paralelni tip VRLA može imati između 200 i 400 ciklusa punjenja i pražnjenja i obično iznos napona 12 V ili 6 V bloka između 40 Ah do najčešće 400 Ah. Također, postoji i podvarijanta paralelne VRLA baterije koja se izrađuje od čistog olova s kiselinom, te može ostvarivati do 600 ciklusa. VRLA tip za visoko cikliranje koristi se u hibridnim sustavima i ima napon 2 V bloka do 4 000 Ah.

Za razliku od potopljenih baterija s olovom i sulfatnom kiselinom VRLA baterije nije potrebno održavati na način da im se dodaje voda, te su stoga sigurnije za uporabu, a pogotovo na udaljenim lokacijama [57]. Predmetni tip baterije funkcionira na način da se emitirani vodik ne pušta u zrak već da se dalje rekombinira, a u slučaju prevelikog tlaka unutar kontejnera ugrađen je sigurnosni ventil kroz koji se može ispustiti vodik. Na slici 2.13 prikazana je karakteristika sa predviđenim brojem ciklusa kojeg baterija može imati tijekom životnog perioda u ovisnosti o dubini pražnjenja.



Izvor: Enersys

Slika 2.13: Karakteristika degradacije ciklusa PowerSafe SBS EON, VRLA tipa stacionarne baterije kompanije Enersys za primjenu u hibridnom sustavu u ovisnosti o dubini pražnjenja (%)

2.9.9. Litij ionske baterije

Omogućuju veću gustoću energije u odnosu na VRLA te su stoga manje u dimenzijama (10-30%), lakše (30-50%), [58], [59]. Litij ionske baterije imaju bolju otpornost na visoke cikluse punjenja i pražnjenja u odnosu na VRLA paralelne baterije, obzirom da mogu funkcionirati između 1000 i 3000 ciklusa punjenja i pražnjenja. Najveći nedostatak im je cijena koja je približno 20-30% veća u odnosu na paralelne VRLA tip.

2.10. Mikromreže

Zadnjih godina osjetan je trend u industriji pojava koncepta mikromreža. Njihova uporaba je temeljena na potrebi za stvaranjem energije izravno na lokaciji gdje se nalazi i teret. Vrlo često ih se nalazi u telekomunikacijskim postrojenjima pogotovo na područjima gdje je lokalna pojna mreža loše kvalitete ili je nepostojeća, a koristi se u svrhu napajanja pristupnih čvorišta za mobilne telekomunikacije, te je njihova snaga relativno mala, uglavnom između 4 i 20 kW.

Mikromrežom se može nazivati bilo koja mreža koja ima mogućnost stvaranja energije u neposrednoj blizini tereta, a temeljena je na uporabi jednog ili više distribuiranih izvora električne energije, a poštujući kriterij dostatnosti. Mikromreže zasnovane na dva ili više izvora energije se, također, nazivaju i hibridnim sustavima, te će se tako nazivati i u daljnjem tekstu ovoga rada.

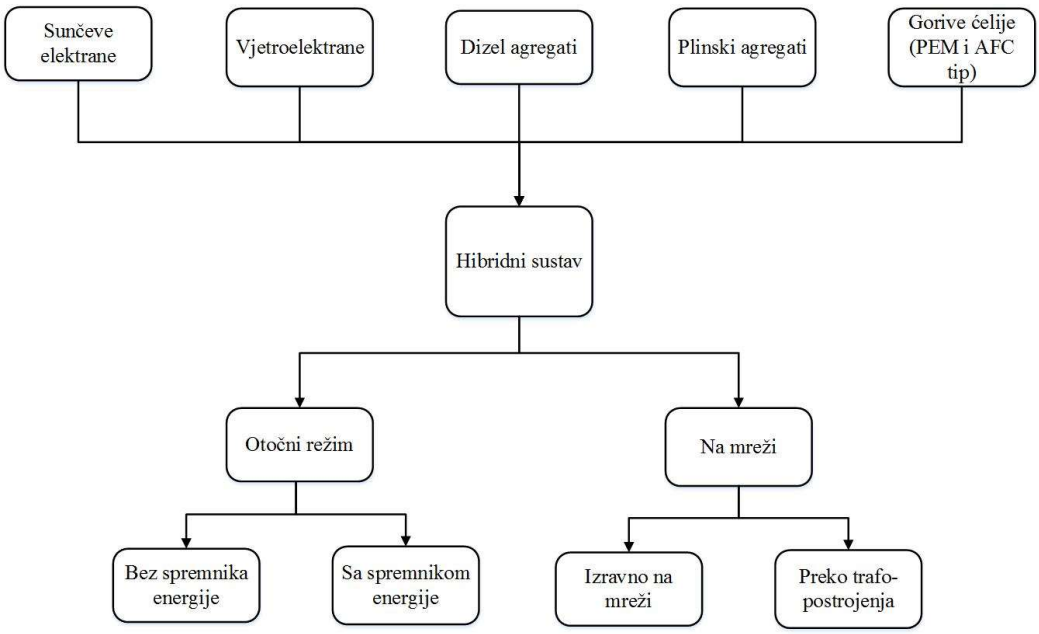
Osim što se mikromreže nalazi u mnogim primjenama, od posebnog područja istraživanja je varijanta koja dominira u telekomunikacijskim sustavima. Obzirom da veliki telekomunikacijski centri (glavna čvorišta) se u zadnjih desetak godina sve više grade kao podatkovni centri s mogućnosti virtualizacije telekomunikacijske opreme, vrlo je važno ispitati mogućnost uporabe hibridnih rješenja kakove se nalazi u telekomunikacijskoj infrastrukturi, a s primjenom u podatkovnim centrima, metodama evaluacije tehničkih kriterija, te, također, evaluacijom ekonomskih parametara.

2.11. Hibridni sustavi

Hibridni sustavi imaju za zadaću opskrbiti teret s minimalno 100% snage u bilo kojem trenutku *t*, a mogu i ne moraju u sebi imati ugrađenu zalihost, što se u konačnici odražava na stupanj raspoloživosti napajanja odgovarajuće infrastrukture.

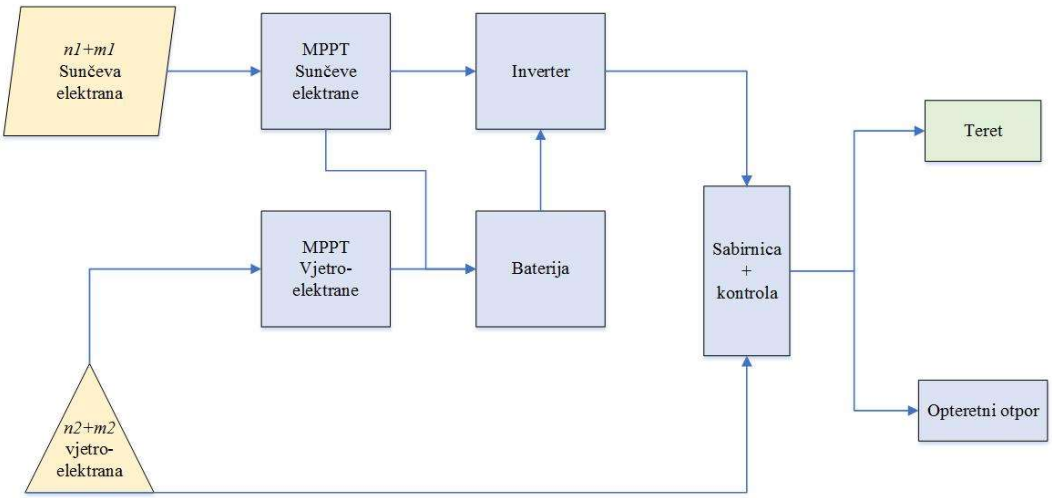
U sklopu predmetnog rada poseban naglasak je dat na optimizaciju hibridnog sustava zasnovanog na spremnicima energije (baterijama), sunčevim i vjetroelektranama, a kao poseban doprinos (značaj) je razvoj algoritma za dimenzioniranje sustava pohrane energije u svrhu optimizacije cjelovitog hibridnog sustava zasnovanog korištenjem obnovljivih izvora električne energije.

Na slici 2.14 prikazane su različite varijante hibridnih sustava, zasnovane na različitim kombinacijama tehnologija i također u različitim modalitetima rada.



Slika 2.14: Klasifikacija hibridnih sustava

U predmetnoj disertaciji razmatra se hibridni sustava zasnovan na sunčevim i vjetroelektranama, a model je postavljen na način da hibridni sustav radi u otočnom režimu rada, kao što je prikazano na slici 2.15.

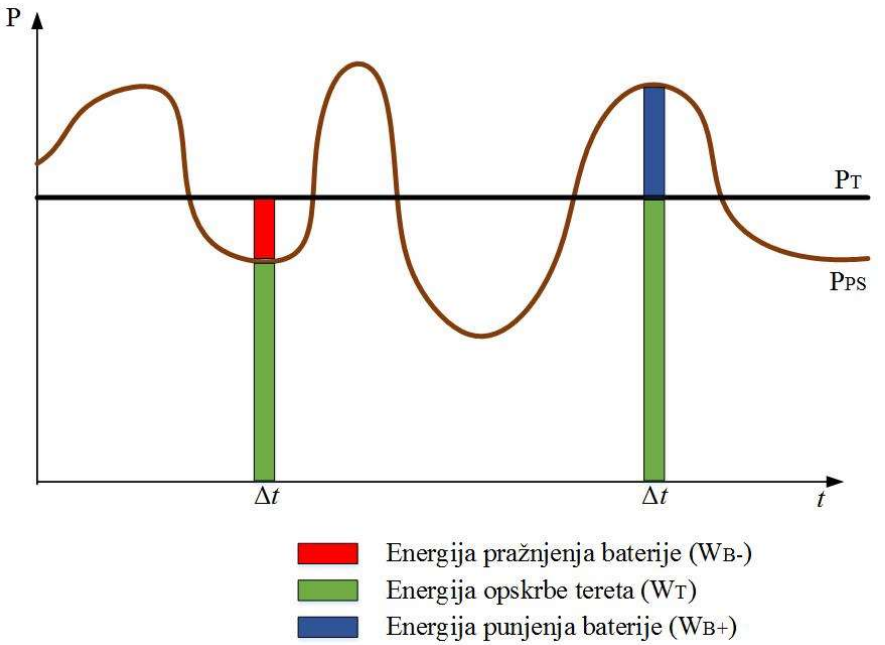


Slika 2.15: Model hibridnog sustava

Iako sustav neće biti u istinskom otočnom režimu rada, svrha takvog modeliranja je uspostava modela spremnika energije zasnovanog na VRLA baterijama. U kasnijim poglavljima predmetne disertacije, također će se zasnovati i alternativni sustav na način da se razmotri uporaba sunčevih i vjetroelektrana, bez uporabe spremnika energije, a sa spajanjem na mrežu.

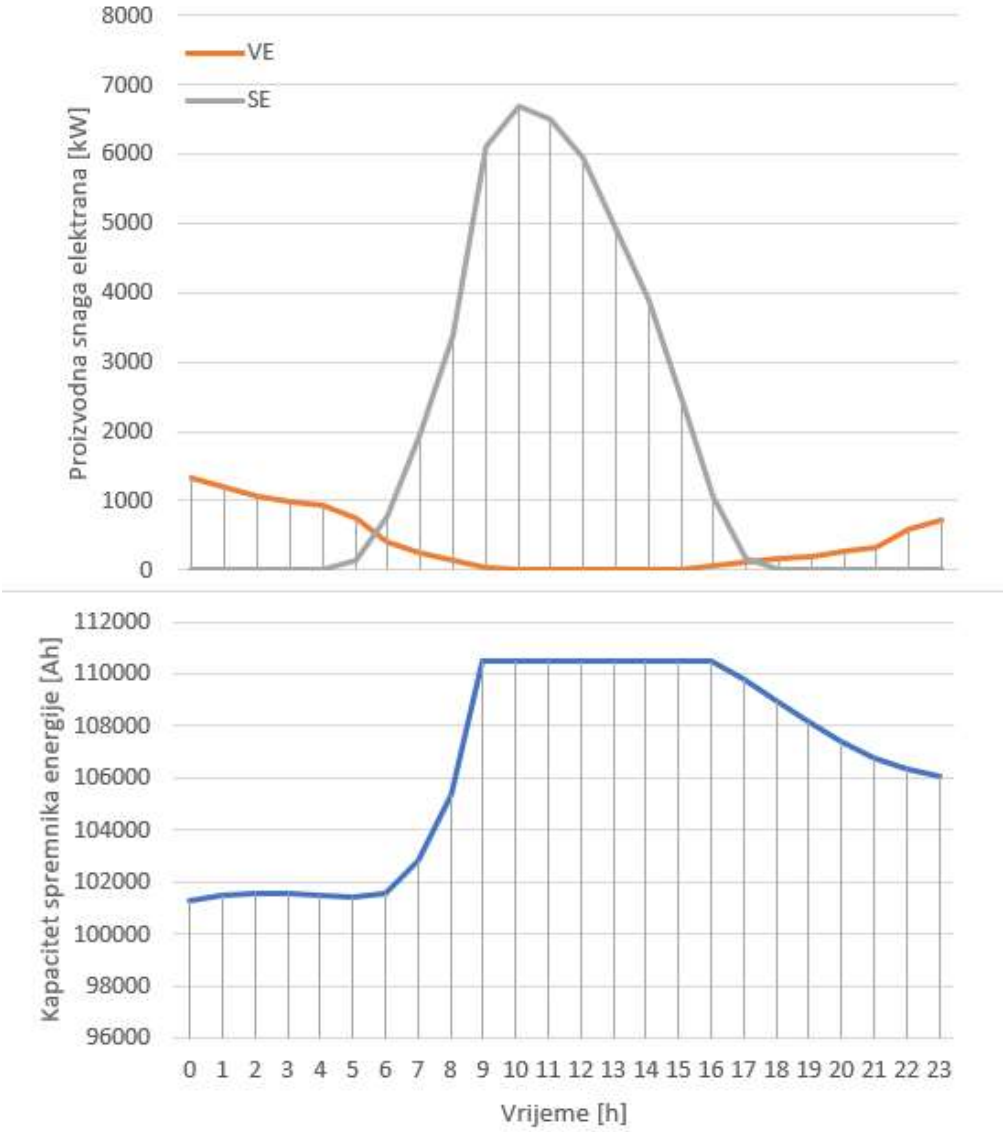
U modelu hibridnog sustava vidljivo je da i sunčeve i vjetroelektrane su sustavi sa zalihom koja je nužna kako bi se postigla tražena razina raspoloživosti.

Obzirom da izlazne snage sunčeve i vjetroelektrane nisu stalnog karaktera, nužno je koristiti i spremnike energije, odnosno VRLA baterije za hibridne primjene. Na slici 2.16 predstavljen je grafički model njihanja energije u hibridniom sustavu. Električna snaga koju (proizvodni) sustav generira označena je sa P_{PS}, a energija W_{PS}, i u svakom Δt moguće je izračunati potrebnu energiju za opskrbu tereta (W_T) i također odrediti ukoliko postoji deficit (W_{B-}) ili suficit (W_{B+}) energije koja će kompenzirati nedostatak generirane energije iz proizvodnog sustava injektiranjem energije iz baterija ili puniti bateriju u slučaju suficita. Snaga tereta (P_T) je konstantna, što za posljedicu ima da je također i potrebna energija za opskrbu tereta (W_T) konstantna.



Slika 2.16: Dinamika punjenja i pražnjenja spremnika energije

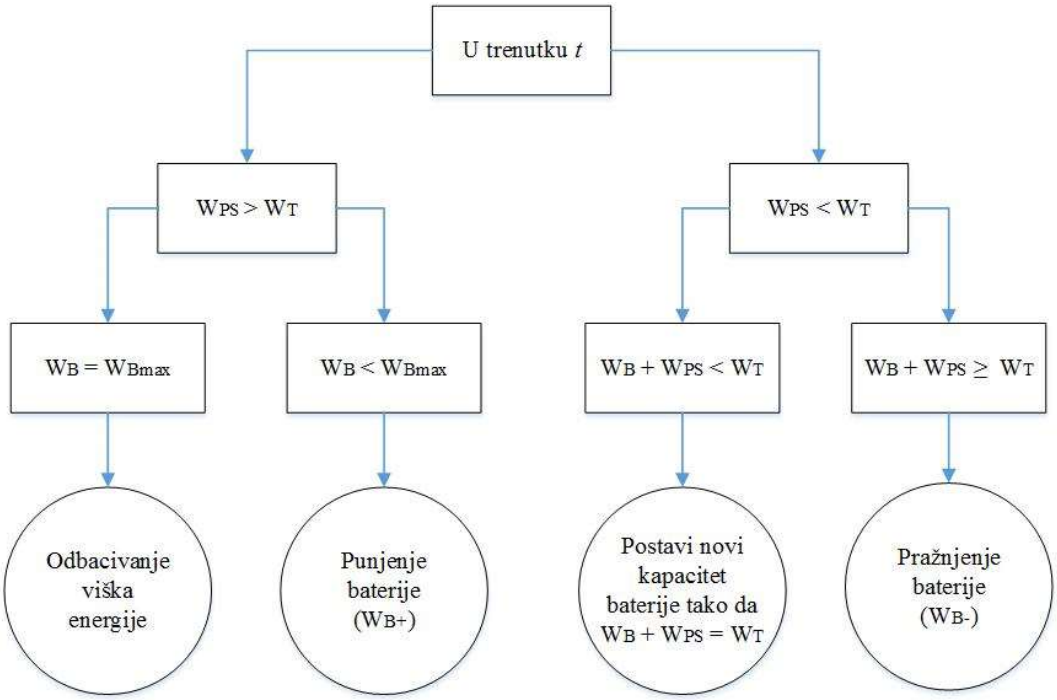
Na slici 2.17 prikazan je primjer dinamike proizvodnje energije iz VE i SE kao i njihov utjecaj na dinamiku kapaciteta spremnika energije u periodu od 24 h.



Slika 2.17: primjer dinamike proizvodnje energije iz VE i SE i utjecaj na dinamiku kapaciteta spremnika energije

Proizvodnja električne energije u vjetroelektrani ovisi o brzini vjetra kao što i ovisi o Sunčevoj insolaciji u slučaju sunčevih elektrana. U predmetnoj disertaciji predlaže se metodologija dimenzioniranja kapaciteta spremnika energije u ovisnosti u proizvedenoj električnoj energiji iz SE i VE koja ovisi o instaliranom kapacitetu SE i VE, sukladno stablu odlučivanja prikazanom na

slici 2.18. Ispitivanje se vrši u svakom trenutku i za sve Δt u promatranom razdoblju, kronološkim redoslijedom u ovisnosti o ulaznim podacima o sunčevoj radijaciji i brzini vjetra, a obzirom da je razlučivost podataka 1 h, tada i Δt je jedan sat. Simulacija započinje sa $t = 0$, a završava sa $t =$ 87 600 a na kraju se razmatraju elektrane dimenzije SE, VE i spremnika energije. Obzirom da su vremenski nizovi koji opisuju količinu generirane energije u odnosu na instalirani kapacitet već postojeći, jedini način kako se može povećati ili smanjiti generiranje električne energije iz VE i SE je povećavanjem ili smanjivanjem kapaciteta.



Slika 2.18: metodologija dimenzioniranja kapaciteta spremnika energije

3. ZNAČAJKE INFRASTRUKTURE I NAJČEŠĆI KARAKTERISTIČNI OBLICI

3.1. Osnovni pojmovi

Sve vrste telekomunikacijskih postrojenja zahtijevaju visoku razinu pouzdanosti. Zahtjevi postavljeni od strane telekomunikacijskog postrojenja prema napajačkom sustavu su takovi da neraspoloživost napajala treba biti najviše $5x10^{-7}$ [60], što znači 0,26 minuta tj. 16 sekundi za vrijeme pogona tijekom jedne godine, što znači da je tražena raspoloživost sustava 99,99995 %, što se s obzirom na napajanje električnom energijom naziva i *premium energija* [61].

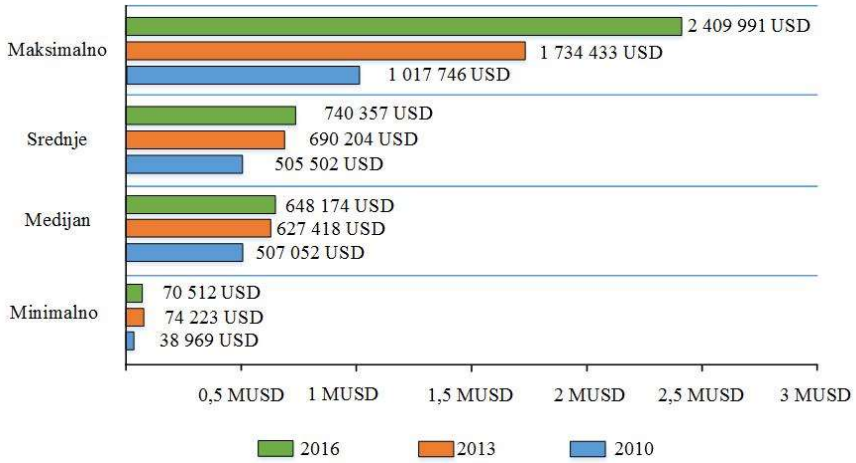
Instituti poput BICSI-a i Uptime Institut-a [15] definiraju razine raspoloživosti podatkovne infrastrukture u razinama od 1 do 4, sukladno tablici 3.1. Neminovno je da su kritične infrastrukture poput telekomunikacijske i podatkovne podložne velikim financijskim rizicima u slučaju pada infrastrukture. Sukladno rizicima i mogućoj šteti, definira se i razina raspoloživosti koju infrastruktura treba zadovoljiti, a u svrhu minimiziranja rizika.

Tablica 3.1: Pregled razina raspoloživosti podatkovne infrastrukture [62]

	Razina I	**Razina II**	**Razina III**	**Razina IV**
Arhitektura sustava	Osnovni data centar	Redundantne komponente	Održavanje uz neprekinut pogon	Otporan na kvar
Primjer vrste industrije	Proizvodnja opreme (npr. poluvodiča)	Medicinske i pravne ustanove, male data sobe	Zrakoplovna i farmaceutska ind., banke, osiguravajuća društva	Burza, televizijske postaje
Trošak zbog prekida rada	Manje od 1 000 USD / h	1 000 – 10 000 USD / h	10 000 – 50 000 USD / h	Više od 50 000 USD / h
Trajanje prekida kroz godinu	28,8h	22h	1,6h	0,8h
Raspoloživost	99,67%	99,75%	99,98%	99,99%

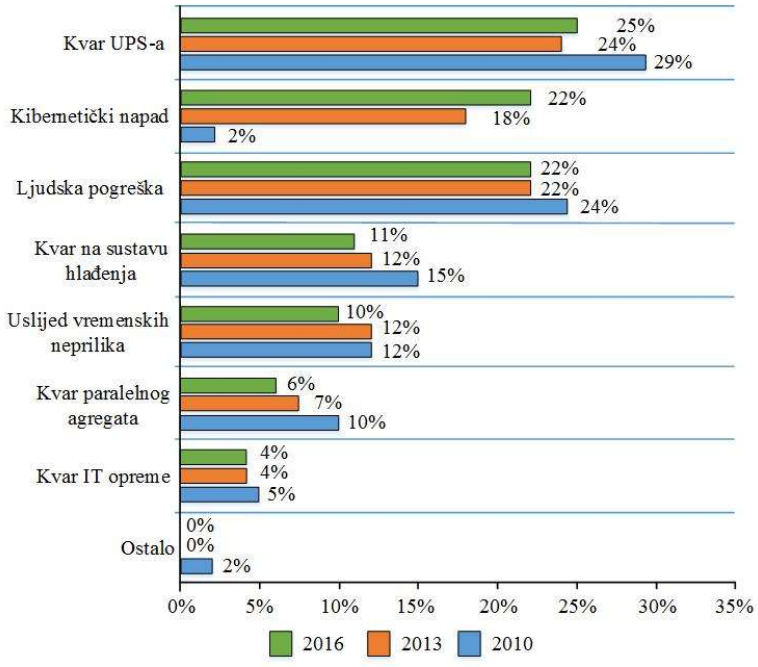
Prema istraživanju Ponemon instituta iz 2016. godine [63], financijske štete vezane za prestanak pogona podatkovnih postrojenja je u porastu iz godine u godinu. Na slici 3.1 vidljivo je da u godini

2016. u odnosu na 2010. je došlo do rasta maksimalne i minimalne financijske štete za gotovo duplo.



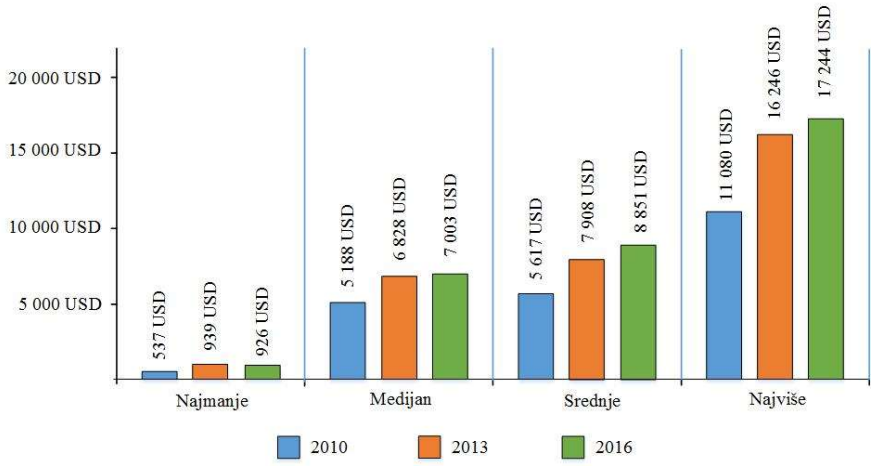
Slika 3.1: Financijska šteta uzrokovana kvarom opskrbe tereta u podatkovnoj infrastrukturi [63]

Važno je za napomenuti, da kvarovi besprekidnog sustava napajanja su uzrok prestanka opskrbe u četvrtini svih slučajeva, dok je ljudska greška odgovorna za petinu svih prestanaka opskrbe, što je vidljivo na slici 3.2.



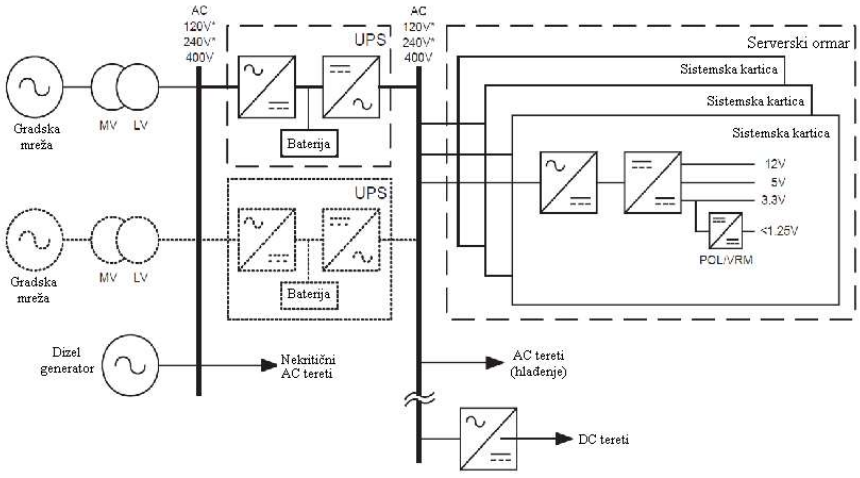
Slika 3.2: Uzroci neplaniranih kvarova opskrbe tereta u podatkovnoj infrastrukturi [63]

Troškovi za svaku minutu neraspoloživosti su također u značajnom porastu, obzirom da su minimalni troškovi veći za 72%, medijan za 35%, srednje vrijednosti za 58% i maksimalne vrijednosti za 56% u 2016. u odnosu na 2010. godinu, kao što je prikazano na slici 3.3.



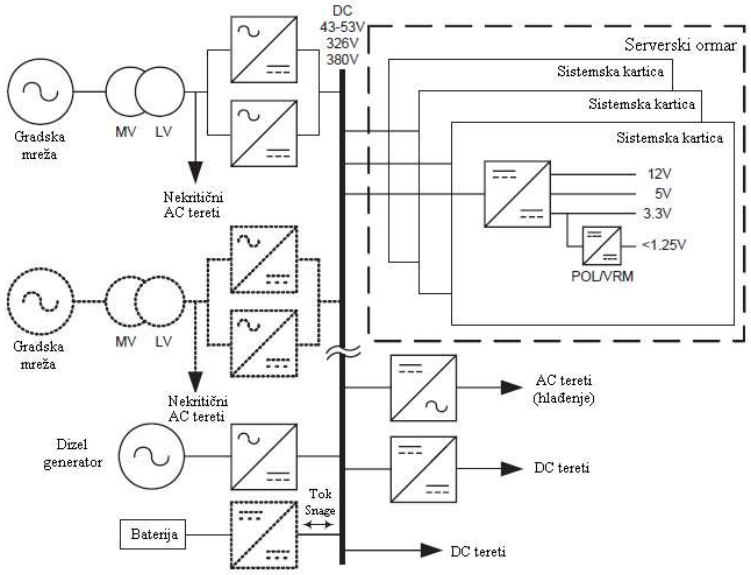
Slika 3.3: Ukupni troškovi za svaku minutu neplaniranog gubitka opskrbe tereta [63]

Najčešća arhitektura u podatkovnim postrojenjima je zasnovana na AC razvodu (distribuciji), kao što je ilustrirano na slici 3.4.

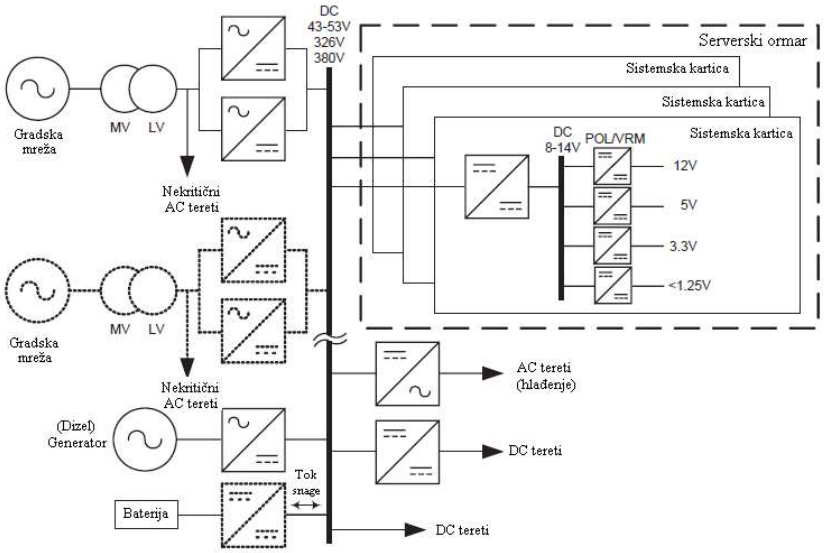


Slika 3.4: Tipična AC distribucijska arhitektura (iscrtkani blokovi su opcijski) [64]

Uz standardni razvod svojstven za podatkovnu infrastrukturu zasnovanu na AC razvodu, također postoje iznimke koje se zasnivaju na DC razvodu koji je inače dominantan u telekomunikacijskim postrojenjima a naponske razine mogu biti 380 V DC ili -48 V DC kao što je na slikama 3.5 i 3.6.



Slika 3.5: Tipična DC distribucijska arhitektura (iscrtkani blokovi su opcijski) [64]



Slika 3.6 DC distribucijska arhitektura sa međusabirnicom (iscrtkani blokovi su opcijski) [64]

Fundamentalne razlike između AC i DC distribucije kroz razne aspekte kao i utjecaje pojedinih aspekata na učinkovitost i pouzdanost prikazane su u tablici 3.2.

Tablica 3.2: Usporedba aspekata pouzdanosti, učinkovitosti i mogućnosti za spajanje tehnologija u usponu radi potpore stvaranju električne energije na lokaciji i pohrani električne energije, između AC i DC energetskih distribucija [64]

Aspekt	AC distribucija	DC distribucija	Utjecaj na pouzdanost	Utjecaj na učinkovitost
Najmanji broj potrebnih en. pretvorbi	Četiri	Dvije	Pouzdanost se povećava smanjenjem broja en. pretvorbi	Učinkovitost raste sa smanjenjem broja en. pretvorbi
Broj potrebnih en. pretvorbi za funkcionalnost UPS-a	Dvije	Jedna	Pouzdanost se povećava smanjenjem broja en. pretvorbi	Učinkovitost raste sa smanjenjem broja en. pretvorbi
Obavljanje en. pretvorbe	AC transformator i pretvarači energetske elektronike	Pretvarači energetske elektronike	AC transformatori su pouzdaniji od energetske elektronike	Učinkovitost AC transformatora i pretvarača en. elektronike je slična
Frekvencija pri kojoj se odvija en. pretvorba	Mrežna frekvencija (50 ili 60 Hz)	Visoke sklopne frekvencije (>100 kHz)	Visokofrekventni pretvarači su skloniji kvaru, što smanjuje pouzdanost	Više frekvencije sklapanja povećavaju učinkovitost en. pretvorbe
Potreba za sinkronizacijom pri spajanju generatora ili spremnika energije	Da, za sve terete	Ne, svi tereti su spojeni na DC sabirnicu	Pouzdanost se povećava smanjenjem broja en. pretvorbi	Sinkronizacija ne utječe na učinkovitost
Potreba za pretvorbom pri spajanju generatora ili spremnika energije	Uvijek	Samo za visokofrekventnu AC opremu	Pouzdanost se povećava smanjenjem broja en. pretvorbi	Učinkovitost raste sa smanjenjem broja en. pretvorbi
Moguća redundancija	Da	Da	Redundancija značajno povećava pouzdanost	Redundancija ne utječe na učinkovitost

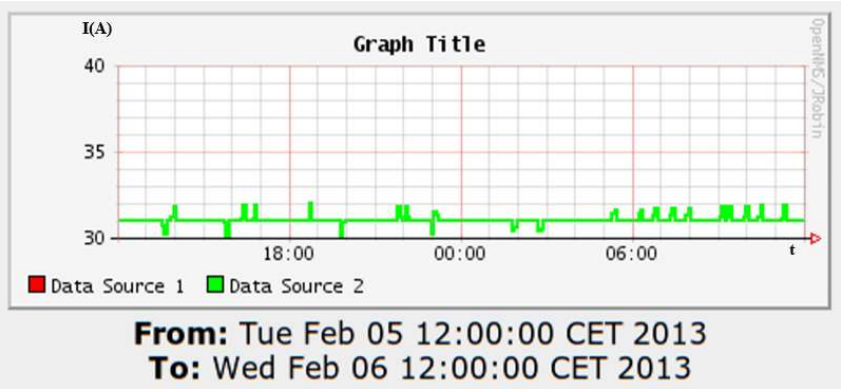
3.2. Tereti u podatkovnom postrojenju

Ukupan električki teret u podatkovnim centrima se općenito može podijeliti u dvije skupine: mehanički i informacijski teret.

Mehanički teret je sadržan primarno u induktivnim motornim teretima (uređaji za hlađenje, liftovi) i sustavima rasvjete. Mehanički teret je promjenjiv tijekom godine zbog nelinearne karakteristike motornih pogona poput kompresora ili pumpi za cirkulaciju rashladnog sredstva. Svojstva i značajke hlađenja su ovisna o odabranoj strategiji hlađenja kao i svojstvu uređaja u uporabi te ovisna i o samoj geografskoj lokaciji postrojenja. Odabir strategije hlađenja ovisi o mnogim varijablama, poput dozvoljene unutarnje temperature prostora, gustoće snage u pojedinom informacijskom ormaru, konfiguraciji podatkovnih redova, protoku fluida, udjelu glikola u primarnim rashladnim krugovima, itd. Također važno je za napomenuti da se razvojem tehnologije i potrebe za dodatnim uštedama u investicijskim ciklusima, razvijaju se nove doktrine hlađenja poput slobodnog hlađenja. Zbog navedenih razloga, napajanje mehaničkih tereta neće biti predmetom istraživanja.

Podatkovni teret je okarakteriziran kao stalni teret i sadržan je u poslužiteljima, spremnicima memorije, modemima i drugim uređajima nužnim za aktivnosti vezane uz protok i pohranu podataka.

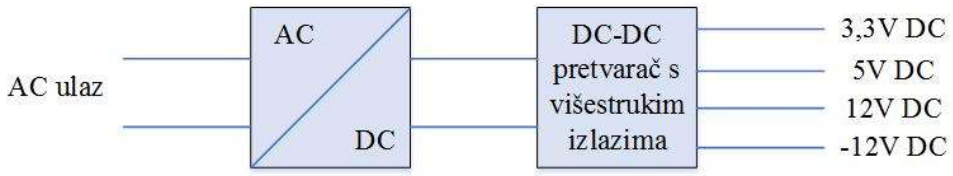
Na slici 3.7 prikazana je snimka potrošnje servera tijekom 24 h u izoliranom odsjeku kolokacijskog podatkovnog centra Markoja u Zagrebu od 5. do 6. veljače 2013. Iz snimke je uočljivo da tijekom dana odstupanja jakosti struje iznose +/-1 A od srednje vrijednosti koja iznosi 31 A.



Izvor: mjerenje omogućio Markoja d.o.o., Zagreb

Slika 3.7: primjer dnevnog opterećenja serverskog niza

Na slici 3.8 prikazana je blokovska shema (model) sustava napajanja unutar pojedinog poslužitelja, sa konvencionalnim ulazom AC napajanja 230 V, serijski spojenim ispravljačem i serijski spojenom grupom pretvarača na različite nužne napone istosmjernog napajanja.



Slika 3.8: Prikaz napajanja poslužitelja

3.3. Besprekidni sustavi napajanja

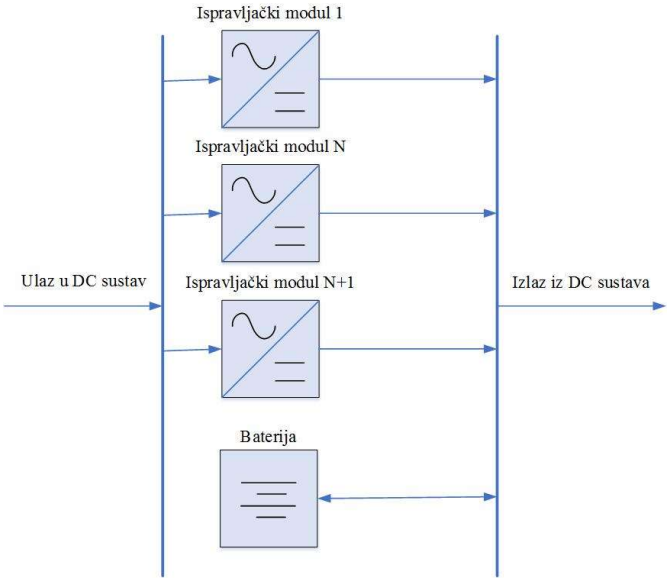
Besprekidni sustavi napajanja su neizostavni element u svakom za sustav važnom postrojenju. Imaju ulogu poboljšanja kvalitete opskrbe električnom energijom, te u slučaju nestanka napajanja električnom energijom iz primarnog izvora (uglavnom javna mreža) imaju zadaću omogućiti neometanu opskrbu tereta energijom iz paralelnog spremnika energije, uglavnom zasnovanog na baterijama.

Tijekom inicijalnih istraživanja i utvrđivanja svojstava besprekidnih napajanja u pogledu pouzdanosti i raspoloživosti, zaključeno je da je nužno sagledavanje utjecaja uređaja besprekidnog napajanja na arhitekturu električnog razvoda radije nego bazično uspoređivanje pouzdanosti i raspoloživosti samih uređaja besprekidnog napajanja [5], [9], [10].

Utvrđeno je da je pouzdanost baterijskog sustava najkritičnija, ali, također, je nužno za naznačiti da u slučaju kvara ili servisa baterije odnosno njezine neraspoloživosti niti u kojem slučaju se ne smije zaključiti i da je sustav besprekidnog napajanja također neraspoloživ.

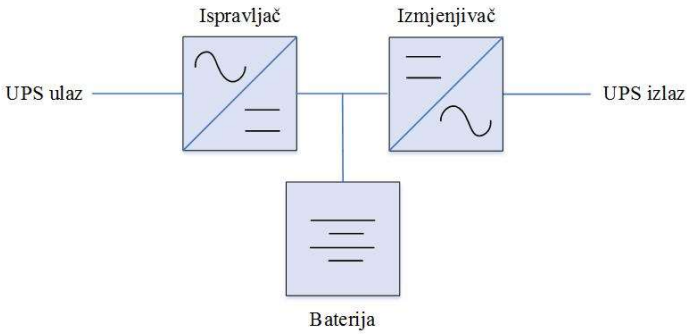
Istosmjerni sustavi napajanja se napajaju iz pojne mreže konvencionalnom AC električnom energijom, te je stoga ne moguće uspostaviti premosnicu oko sustava budući da sustav proizvodi DC električnu energiju, kao što je prikazano na slici 3.9. Sustav ima u sebi ugrađenu redundanciju,

odnosno sustav ima minimalno N+1 ispravljački modul čime se značajno podiže raspoloživost sustava, a sustav će nastaviti sa radom čak i u slučaju kvara kontrolnog sustava.



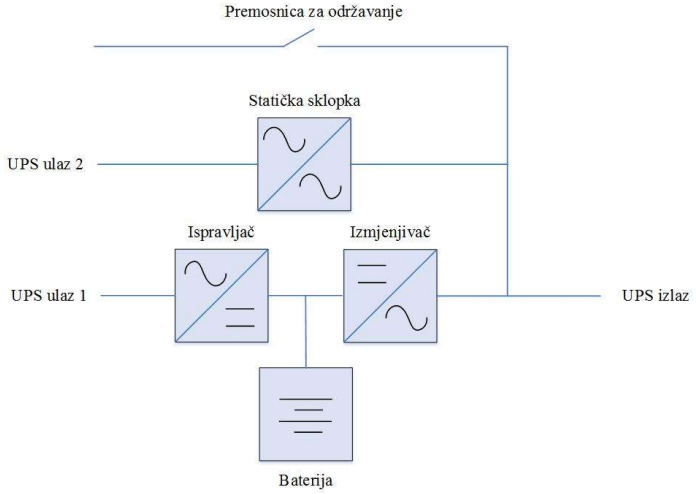
Slika 3.9: Istosmjerni sustav

Konvencionalni UPS uređaji su zasnovani na AC razvodu, te se visok stupanj raspoloživosti postiže paraljeljenjem sustava gdje je jedan od sustava u paraleli redundantan, te uz pomoć uporabe statičke sklopke i servisne premosnice, kao što je vidljivo na slikama 3.10-3.13. Na slici 3.10 prikazan je osnovni sustav koji je sastoji od ispravljača na ulazu, izmjenjivača na izlazu i spremnika energije na istosmjernoj poveznici između ispravljača i izmjenjivača.



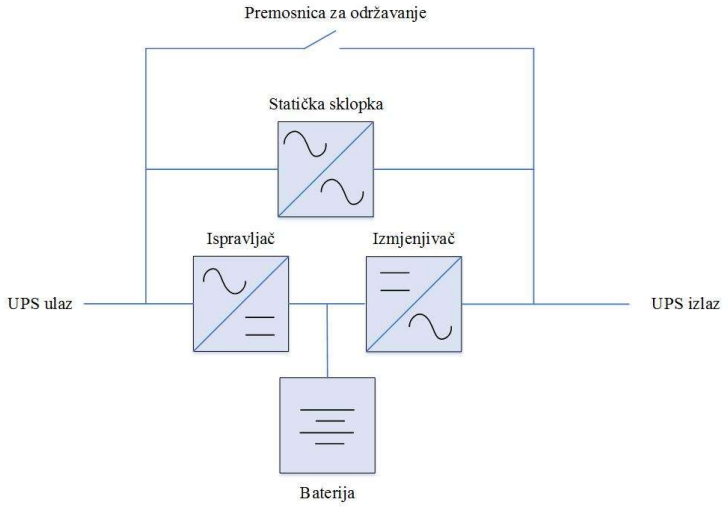
Slika 3.10: UPS sa dvojnom konverzijom

Na slici 3.11 prikazan je UPS sa dvojnom konverzijom sa statičkom sklopkom. Svojstvo tog sustava je da ima dva ulaza koji su najčešće nezavisni te na taj način omogućuje dva nezavisna toka snage. Tok snage se može odvijati na način da je izlaz neovisan od ulaznog napona i frekvencije (preko ulaza 1) ili da je ovisan o mrežnoj frekvenciji i naponu (preko ulaza 2).



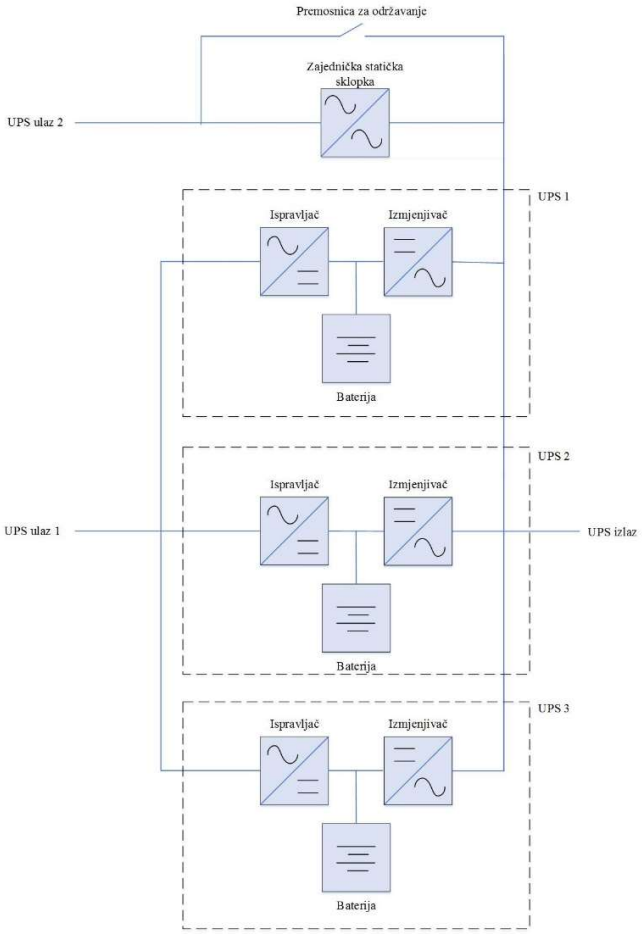
Slika 3.11: UPS sa dvojnom konverzijom i statičkom sklopkom

Na slici 3.12 prikazan je UPS sa jednostrukom konverzijom čije je svojstvo da najčešće da sustav ima samo jedan ulaz a normalni režim rada je da tok snage ide preko statičke sklopke te je na taj način sustav ovisan o ulaznoj frekvenciji i naponu. Ispravljač služi jedino punjenju baterije te je stoga poddimenzioniran u odnosu na izmjenjivač.



Slika 3.12: UPS sa jednostrukom konverzijom

Na slici 3.13 prikazan je model spajanja UPS-ova sa dvojnom konverzijom u paralelni spoj. U tom slučaju postoji samo jedna zajednička statička sklopka koja mora biti dimenzionirana na način da može podnijeti cjelokupni teret. Trase dvojne konverzije (ispravljač - izmjenjivač) se sve napajaju iz iste točke potencijala.

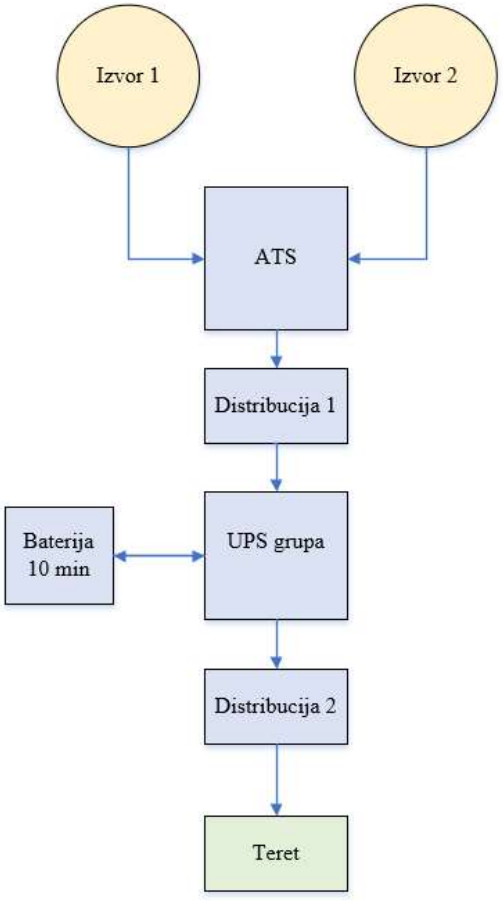


Slika 3.13: Grupa UPS uređaja sa dvojnom konverzijom u paraleli

4. MEĐUDJELOVANJE DISTRIBUIRANIH IZVORA I PODATKOVNE ELEKTRIČKE INFRASTRUKTURE

U svrhu razumijevanja zaštite tereta (poslužitelja) nužno je sagledati cijelu arhitekturu podatkovne infrastrukture, dakle međudjelovanje izvora električne energije i komponenti sadržanih u sustavu. U arhitekturama svih razina od 1 do 4 uvijek se nalaze minimalno dva sustava napajanja od kojih je jedan aktivan a drugi paralelna rezerva [15]. Najčešće je pojna mreža aktivni izvor, a dizel agregat paralelna rezerva. Obzirom da u nekim slučajevima je rentabilnije generirati električnu energiju na samoj lokaciji podatkovne infrastrukture, moguće je i razmotriti druge mogućnosti primjene različitih izvora napajanja, kao što su plinski agregati, gorive ćelije, itd.

Arhitekture Razine 1 su najjednostavnije arhitekture među standardnim arhitekturama. Često su zasnovane na samo jednom izvoru a tek rjeđe imaju automatsku transfer sklopku (ATS) koja omogućuje prebacivanje napajanja sa aktivnog izvora na paralelni rezervni u slučaju loše kvalitete ili kompletnog izostanka napajanja iz aktivnog izvora, kao što je prikazano na slici 4.1.

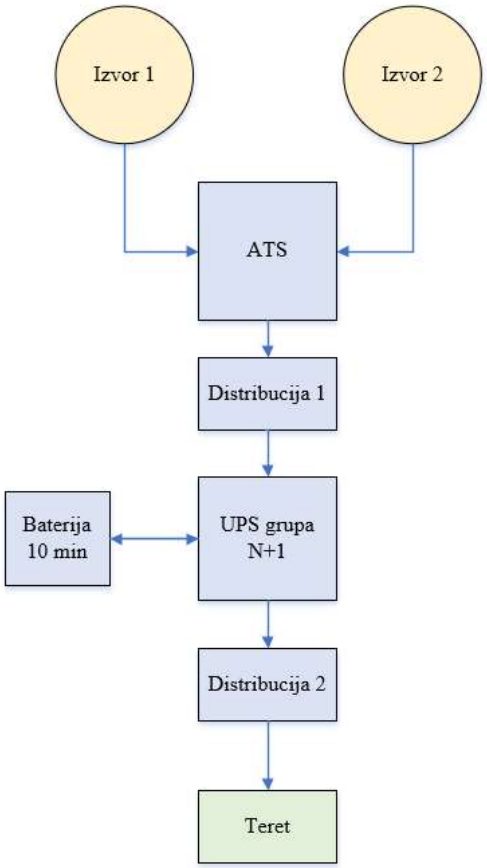


Slika 4.1: Električka arhitektura Razine 1

Za vrijeme prebacivanja zadaća je besprekidnog sustava napajanja da omogući energiju iz svojih spremnika energije, a sve dok paralelni sustav ne dosegne punu snagu i frekvenciju te bude spreman preuzeti teret. Besprekidni sustavi napajanja su monolitički i bez redundancije. Arhitekture Razine 1 najčešće imaju spremnik energije koji omogućava do 10 minuta autonomije a u slučaju najveće autonomije (10 min) poredni dizel agregat nije korišten.

Arhitekture Razine 2 u odnosu na Razinu 1 obavezno imaju automatsku transfer sklopku i dva izvora energije, kao što je prikazano na slici 4.2. Najčešći poredni izvor energije je dizel agregat sa autonomijom do 24 h. Sustav besprekidnog napajanja je realiziran modularnim pristupom obzirom da je nužno postojanje redundancije, odnosno UPS je nužno u N+1 konfiguraciji.

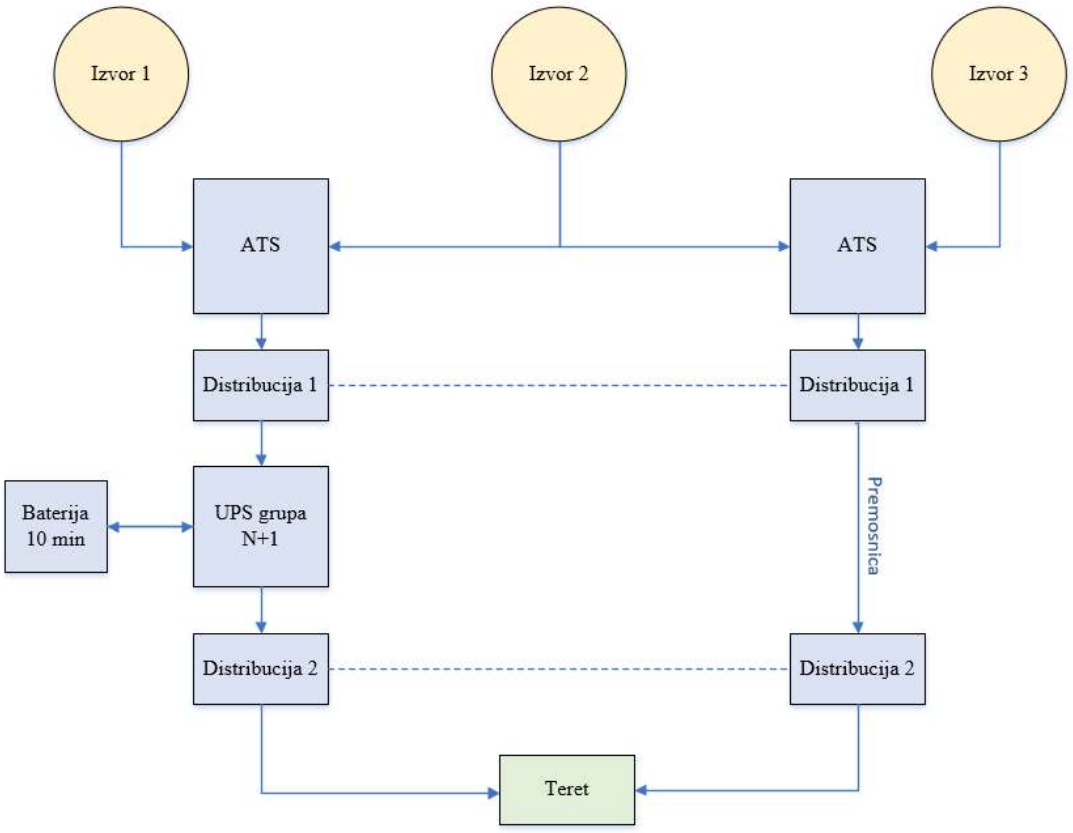
Pristup Razine 2 je poprilično jednostavan i najčešće ne podrazumijeva pomno planiranje razvoda električne energije u postrojenju kao ni planiranje održavanja.



Slika 4.2: Električka arhitektura Razine 2

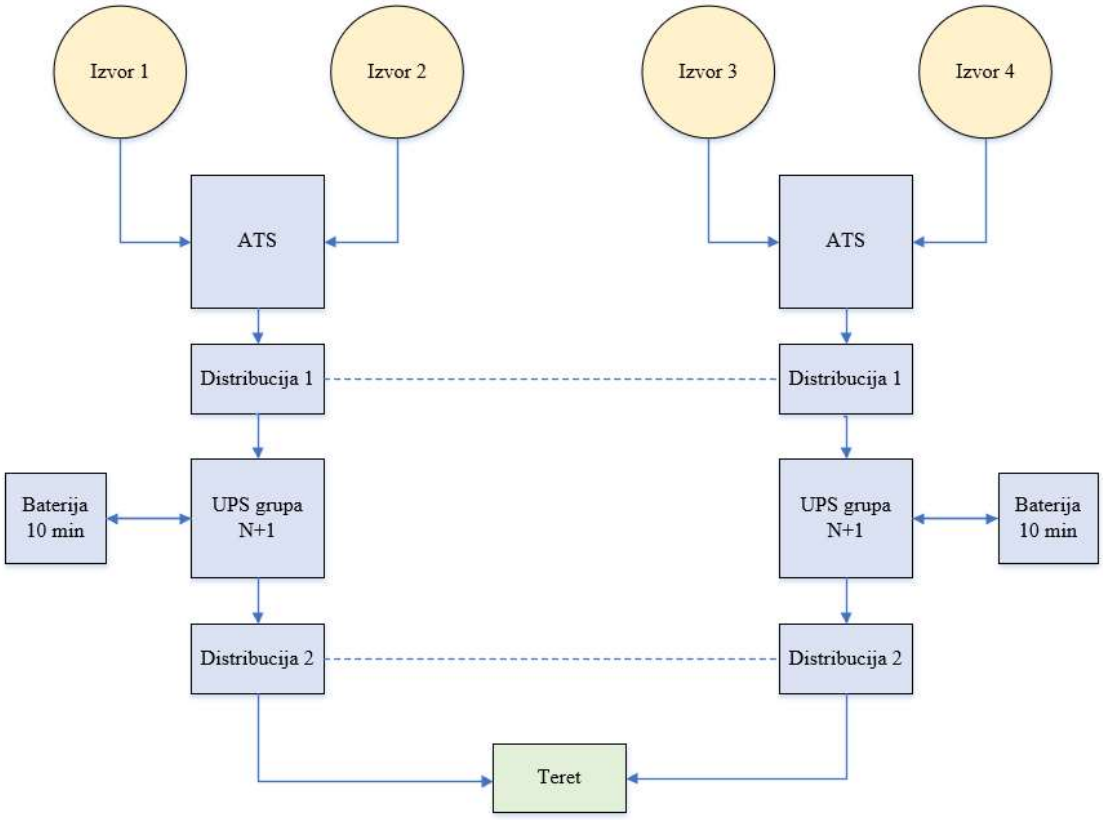
Arhitektura Razine 3 omogućuje napajanje tereta sa dvije strane. Jedna strana je aktivna i sadržava sustave besprekidnog napajanja u N+1 konfiguraciji a u slučaju potrebe za planiranim održavanjem moguće je prebaciti napajanje na samo jednu stranu kako bi se omogućilo sigurno održavanje, sukladno slici 4.3. Obje strane imaju primarna napajanja, obično iz pojne mreže, ali i jedan paralelni rezervni sustav koji može napajati (samo) jednu od strana u slučaju potrebe. Ovakva arhitektura se omogućuje održavanje uz uvjete neprekidnog napajanja tereta.

Arhitekture Razine 3 najčešće imaju autonomiju do 72 h uz uporabu porednih izvora energije. Planiranje takvih postrojenja je pomno te obično imaju sustave vatrodojave i vatrozaštite a podatkovni centar mora funkcionirati čak i u uvjetima ukoliko dođe do požara u trajanju od 1 h.



Slika 4.3: Električka arhitektura Razine 3

Arhitektura Razine 4 je nalik na duplu arhitekturu Razine 4, što omogućuje otpornost na kvarove u bilo kojem dijelu arhitekture, obzirom da je arhitektura u potpunosti isprepletena i posjeduje dupli infrastrukturni kapacitet. Ovakve arhitekture imaju čak četiri izvora napajanja, dva aktivna i dva paralelna rezervna sustava, od kojih su po jedan aktivni i jedan paralelni rezervni dodijeljeni svakoj strani, kao što je prikazano na slici 4.4. Evidentno je, da i aktivni i paralelni rezervni sustavi ukoliko rade zajedno rade na 50% kapaciteta u normalnom režimu rada. U slučaju da je pojna mreža izvor za aktivne sustave potrebno je pomno planiranje zajedno sa operatorom elektroprivrede obzirom da pojni vodovi trebaju doći sa točaka koje trebaju biti što je više moguće neovisne jedna o drugoj.



Slika 4.4: Električka arhitektura Razine 4

5. TEMELJNI MATEMATIČKI MODELI I ALGORITIMI VEZANI UZ POJAM RASPOLOŽIVOSTI I POUZDANOSTI

5.1. Osnovni pojmovi

Pouzdanost se komponente ili sustava definira kao vjerojatnost da će komponenta ili sustav obavljati zadaće i procese tijekom promatranog perioda $(0 \div t)$ a unutar svog životnog vijeka ($0 < t < T$) za koje su stvoreni sukladno zadanim parametrima [65]. Pouzdanost je jedan od kriterija za kvalitetu komponente koja se u nju treba ugraditi prilikom dizajna. Kako bi se pouzdanost komponente ili sustava kvantificirala trebaju postojati logički i matematički modeli kojima se utvrđuju odnosi među podkomponentama ili podsustavima koji čine jednu cjelinu u ukupnoj komponenti ili sustavu. U svrhu procjenjivanja pouzdanosti, nužno je poznavati i razdiobe događaja (kvarova, popravaka, strategija u održavanju, itd.).

Održavanost komponente ili sustava je mjera koja daje indikaciju o lakoći obnavljanja komponente ili sustava u slučaju nastupanja zastoja [66]. Održavanost komponenata je vjerojatnost da će postupak obnavljanja uspješno vratiti komponentu ili sustav u njegovo prvobitno stanje (stanje prije nastupanja zastoja). Raspoloživost [65] je vjerojatnost da komponenta ili sustav funkcionira zadovoljavajuće sukladno zadanim parametrima u bilo kojem vremenu *t* u budućnosti, a ovisi o pouzdanosti i održavanosti. Matematički odnosi između vjerojatnosti kvara, pouzdanosti, funkcija gustoće i učestalosti kvara prikazani su u tablici 5.1.

Tablica 5.1: Matematički odnosi između kvarova, pouzdanosti, funkcija gustoće i učestalosti kvara

	$\boldsymbol{F(t)}$	$\boldsymbol{R(t)}$	$\boldsymbol{f(t)}$	$\boldsymbol{\lambda(t)}$	
$\boldsymbol{F(t)} =$	$F(t)$	$1 - R(t)$	$\int_0^t f(x)dx$	$1 - exp\left(-\int_0^t \lambda(x)dx\right)$	Vjerojatnost kvara
$\boldsymbol{R(t)} =$	$1 - F(t)$	$R(t)$	$\int_t^\infty f(x)dx$	$exp\left(-\int_0^t \lambda(x)dx\right)$	Pouzdanost
$\boldsymbol{f(t)} =$	$\frac{dF(t)}{dt}$	$\frac{dR(t)}{dt}$	$f(t)$	$\lambda(t)exp\left(-\int_0^t \lambda(x)dx\right)$	Funkcija gustoće vjerojatnosti
$\boldsymbol{\lambda(t)} =$	$\frac{\frac{dF(t)}{dt}}{1 - F(t)}$	$\frac{d(\ln R(t))}{dt}$	$\frac{f(t)}{\int_t^\infty f(x)dx}$	$\lambda(t)$	Učestalost kvara

$$MTTR = \frac{Ukupno\ vrijeme\ svih\ održavanja}{Ukupan\ broj\ svih\ održavanja} \tag{5.1}$$

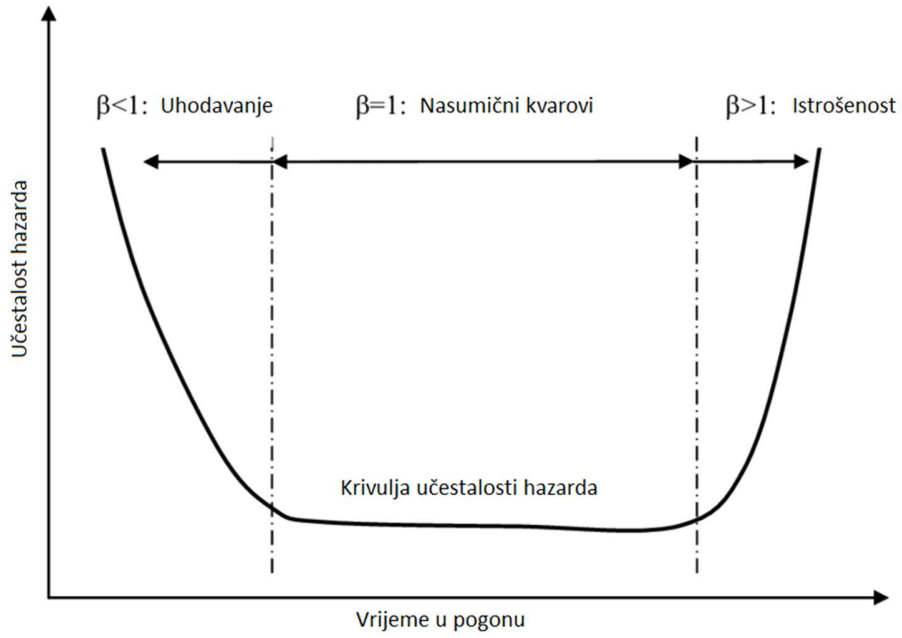
Pouzdanost *m/n* sustava sa *n* nezavisnih komponenti u kojem su pouzdanosti svih jedinica iste, je binomna razdioba pouzdanosti:

$$Rs(k,n,R) = \sum_{R=k}^{n} \binom{n}{r} R^r (1-R)^{n-r} \tag{5.2}$$

Pri čemu je

$$\binom{n}{r} = \frac{n!}{k!\,(n-k)!} \tag{5.3}$$

Krivulja *kade* (eng. *Bathtub curve*), opisuje učestalost kvarova u cijeloj populaciji proizvedenih istovrsnih komponenti, kao što je prikazano na slici 5.1, a zasnovana je na Weibullovoj razdiobi. Krivulja je podijeljena u tri područja: područje uhodavanja, područje nasumičnih kvarova i područje istrošenosti.



Slika 5.1: Krivulja kade

Kada komponenta ili sustav uđu u vremensku domenu nasumičnih kvarova, za β=1, intenzitet kvarova prestaje biti ovisan o vremenu, odnosno događaji kvarovi imaju isti intenzitet te postaju nasumični. Također vrijedi da vrijeme do kvara biva opisano eksponencijalnom razdiobom.

$$\lambda(t) \xrightarrow{konst.} \lambda \tag{5.4}$$

Trenutna raspoloživost (raspoloživost u vremenskoj točki)

$$A(t) = R(t) + \int_0^t R(t-u)m(u)du \tag{5.5}$$

Prosječna raspoloživost se definira kroz cijeli interval životnog perioda komponente ili sustava:

$$A_m(T) = \frac{1}{T}\int_0^T A(t)dt \tag{5.6}$$

Granična odnosno ustaljena raspoloživost definirana je sljedećom jednadžbom:

$$A(\infty) = \lim_{T\to\infty} A(T) \tag{5.7}$$

te, tada vrijedi i sljedeće:

$$A = \frac{MTTF}{MTTF + MTTR} \tag{5.8}$$

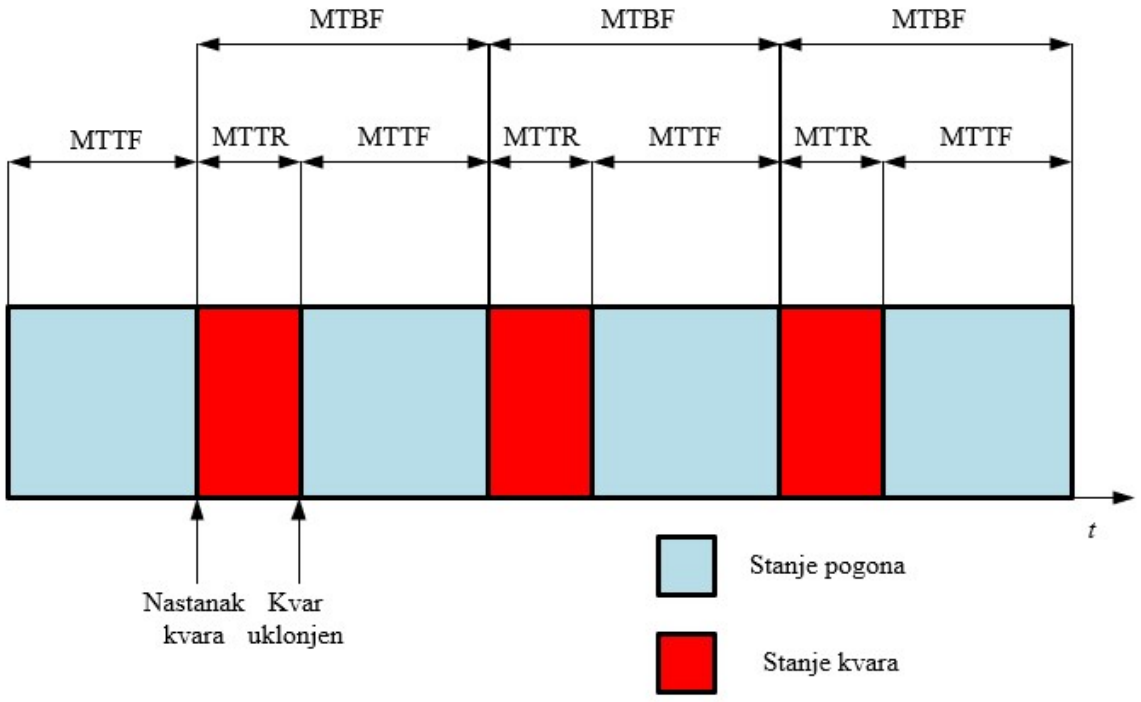
$$A = \frac{Vrijeme\ u\ pogonu}{Vrijeme\ u\ pogonu + Vrijeme\ u\ zastoju} \tag{5.9}$$

Raspoloživost sustava ili komponente se najčešće izražava „brojem devetki“ čija interpretacija je u tablici 5.2.

Tablica 5.2: Broj *devetki* i korespondirajući vrijeme neraspoloživosti u jednoj godini

Broj devetki	Raspoloživost	Vrijeme neraspoloživosti u jednoj godini
2	99,0%	90 h
3	99,9%	9 h
4	99,99%	0,9 h
5	99,999%	5 min
6	99,9999%	0,5 min
7	99,99999%	3 sec

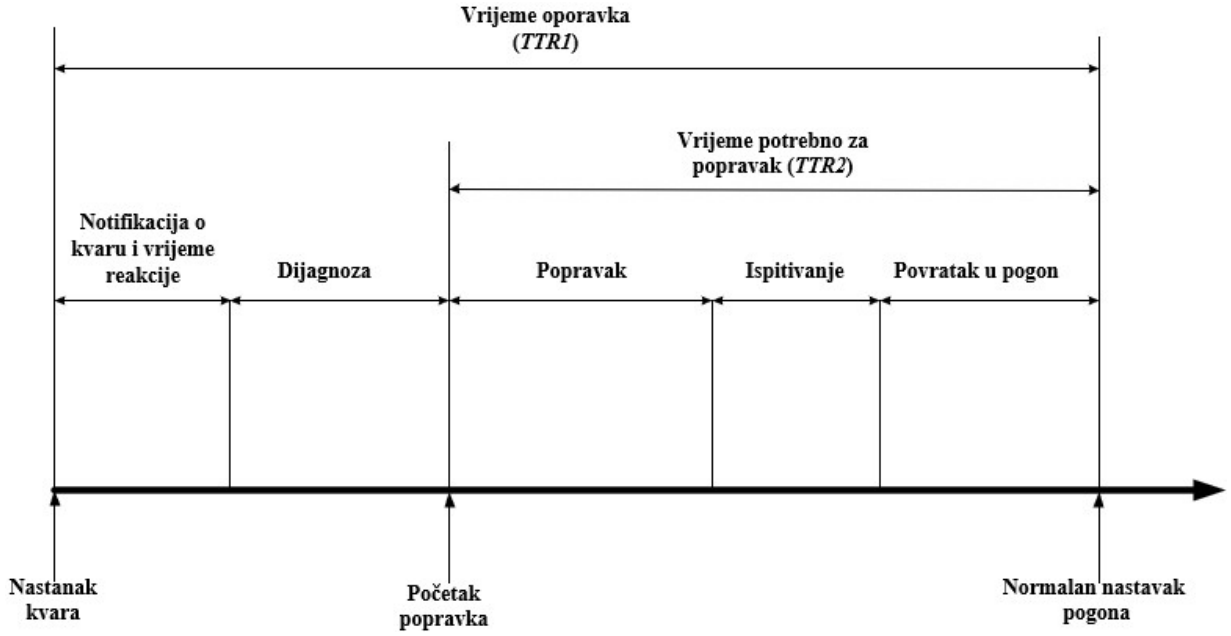
Sukladno jednadžbama 5.4 – 5.9 u ustaljenom stanju raspoloživost sustava ili komponente ovisi o dvama varijablama – srednjem vremenu između kvarova (MTBF) i srednjim vremenima popravka ili remonta (MTTR). Odnos između raspoloživosti, MTBF i MTTR grafički je ilustriran na slici 5.2.



Slika 5.2: Raspoloživost komponente

U teoriji održavanja potrebno je razlikovati vremena za popravak *TTR* (eng. *Time to Repair*), *TTR2* i ukupno vrijeme oporavka *TTR1*, [67], kako je prikazano na slici 5.3. Vremenska domena *TTR2* započinje početkom popravka i obuhvaća vremena potrebna za popravak, ispitivanje i

ponovno puštanje u pogon, dok vremenska domena *TTR1* obuhvaća uz *TTR2* i vremena notifikacije o kvaru i dijagnozu.



Slika 5.3: Vrijeme oporavka i vrijeme popravka [67]

5.2. Funkcije razdiobe vjerojatnosti

Obzirom da se teorija pouzdanosti i raspoloživosti zasniva na statistici, nužno je razmotriti i vrste razdioba koje se najčešće upotrebljavaju i od kojih će neke biti primijenjene i u predmetnoj disertaciji. Funkcije razdiobe imaju pridružene funkcije gustoće vjerojatnosti koja je jednaka vjerojatnosti da će slučajna varijabla X postići određenu vrijednost [68].

$$X = \begin{pmatrix} x_1\, x_2 \ldots x_i \ldots \\ p_1\, p_2 \ldots p_i \ldots \end{pmatrix} \tag{5.10}$$

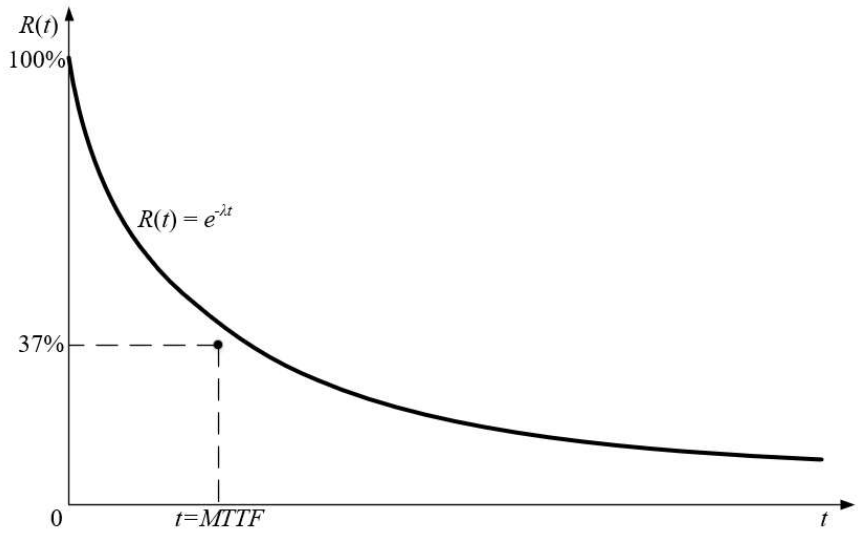
U tablici 5.3 opisane su četiri promatrane razdiobe: eksponencijalna, Weibullova, uniformna i normalna, sa pripadnim matematičkim izrazima za funkcije gustoće i najčešće primjene u teoriji pouzdanosti.

Tablica 5.3: Vrste razdioba

Razdioba	**Funkcija gustoće vjerojatnosti**	**Primjena**
Eksponencijalna	$f(t) = \lambda e^{-\lambda t}$	Elektroničke komponente i složeni sustavi
Weibullova	$f(t) = \frac{\beta}{\eta}\left(\frac{t}{\eta}\right)^{\beta-1} e^{-\left(\frac{t}{\eta}\right)^{\beta}}$	Mehaničke komponente
Uniformna	$f(t) = \begin{cases} \frac{1}{b-a}, & za\ a \le t \le b \\ 0, & za\ t < a\ ili\ t > b \end{cases}$	Ispitivanje nasumičnosti, generator slučajnih (paslučajnih) brojeva
Normalna	$f(t) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(t-\mu_\eta)^2}{2\sigma^2}}$	Analiza proizvodnje komponenti ili analiza mehaničkih kvarova

5.2.1. Eksponencijalna razdioba

Eksponencijalna razdioba se smatra praktičnom za primjenu u domeni pouzdanosti, obzirom da ovisi o samo jednoj varijabli, intenzitetu kvara λ ili njegovom inverzu – srednjem vremenu do kvara (*MTTF*), te se može smatrati specijalnim slučajem Weibullove razdiobe u slučaju kada je $\beta = 1$. Često se koristi u svrhu modeliranja elektroničkih komponenti kao što su diode, kondenzatori ili tranzistori, dok ju je potrebno izbjegavati u slučajevima kada se modeliraju mehaničke komponente podložne mehaničkim naprezanjima i koroziji. Eksponencijalna razdioba funkcije pouzdanosti prikazana je na slici 5.4.



Slika 5.4: eksponencijalna razdioba

Funkcija gustoće vjerojatnosti:

$$f(x) = \frac{1}{\beta} e^{-\frac{x-\mu}{\beta}} \qquad \forall x \geq \mu \,\&\, \beta > 0 \tag{5.11}$$

pri čemu je μ parametar lokacije a β parametar skale. U slučaju kada je $\mu = 0$ i $\beta = 1$ riječ je o standardnoj eksponencijalnoj distribuciji koja je dana jednadžbom:

$$f(x) = e^{-x} \quad \forall x \geq 0 \tag{5.12}$$

Funkcija kumulativne distribucije:

$$F(x) = 1 - e^{-\frac{x}{\beta}} \qquad \forall x \geq 0 \,\&\, \beta > 0 \tag{5.13}$$

5.2.2. Primjena konstantne učestalosti kvara u eksponencijalnom modelu

Konstantna učestalost kvara se koristi isključivo u modelima zasnovanim na eksponencijalnoj razdiobi. Promatrajući krivulju *kade*, uporaba konstantne učestalosti kvara (slika 5.5) u modelima koji nisu zasnovani na eksponencijalnoj razdiobi ima za posljedicu izostavljanja svojstava karakterističnih za periode uhodavanja i istrošenosti, što može dovesti do krivih zaključaka.



Slika 5.5: konstantna učestalost kvarova

$$\lambda(t) = \frac{f(t)}{R(t)} = \lambda$$

$$f(t) = \lambda e^{-\lambda} \;\; za\; \lambda > 0, t \geq 0 \tag{5.14}$$

$$R(t) = e^{-\lambda t} = 1 - F(t)$$

$$R(x|t) = P_r(T > t + x|T > t) = \frac{e^{-\lambda(t+x)}}{e^{-\lambda t}} = e^{-\lambda x} = R(x)$$

Statistička svojstva:

$$MTTF = \frac{1}{\lambda}$$

$$R(MTTF) = e^{-\lambda MT} \quad = e^{-1} = 0{,}36788 \tag{5.15}$$

$$Var(T) = \frac{1}{e^2}$$

$$Median = \ln(2)\frac{1}{\lambda} = 0{,}69315\ MTTF$$

5.2.3. Primjena Weibullovog modela pouzdanosti

Weibullova razdioba može biti temeljena na dva ili tri parametra. Najznačajniji aspekt uporabe Weibullove razdiobe je utjecaj parametra oblika β u dvoparametarskom obliku. U slučaju uporabe tri parametra uvodi se također i parametar η koji se naziva i faktor svojstvenog preživljavanja tijekom životnog perioda.

$$f(t) = \frac{\beta}{\eta}\left(\frac{t}{\eta}\right)^{\beta-1} e^{-\left(\frac{t}{\eta}\right)^{\beta}} \quad \beta>0,\ \eta>0,\ t\geq 0$$

$$R(t) = e^{-\left(\frac{t}{\eta}\right)^{\beta}} = 1 - F(t) \tag{5.16}$$

$$\lambda(t) = \frac{f(t)}{R(t)} = \frac{\beta}{\eta}\left(\frac{t}{\eta}\right)^{\beta-1}$$

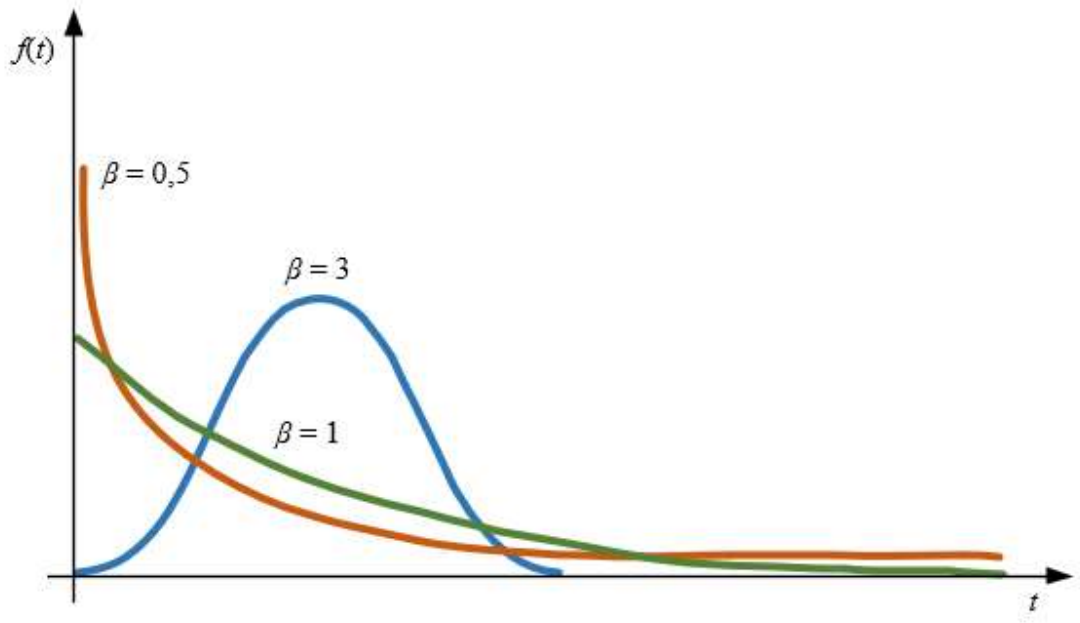
Statistička svojstva:

$$MTTF = \eta \int_0^{\infty} t^{\frac{1}{\beta}} e^{-t} dt = \eta\Gamma\left(1 + \frac{1}{\beta}\right)$$

$$Var = \eta^2\left[\Gamma\left(1 + \frac{2}{\beta}\right) - \left(\Gamma\left(1 + \frac{1}{\beta}\right)\right)^2\right] \tag{5.17}$$

$$Median = \eta(ln2)^{\frac{1}{\beta}}$$

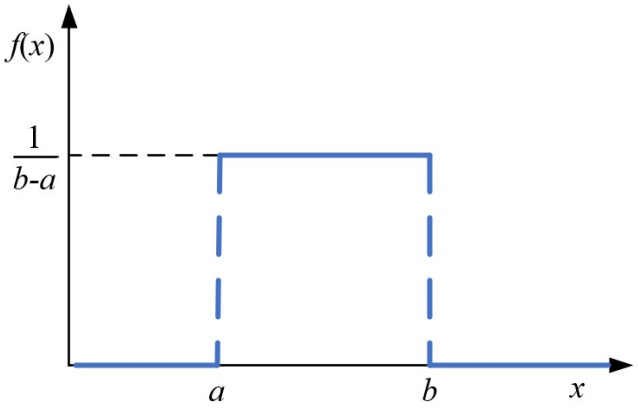
U slučaju kada je $\beta < 1$ učestalost kvarova se smanjuje sa vremenom, te se taj slučaj također naziva i rano-životnim kvarovima, odnosno kvarovima u periodu uhodavanja. U slučaju kada je $\beta = 1$ ili približno, komponenta se opisuje konstantnom učestalosti kvara. U slučaju $\beta > 1$ učestalost kvarova se povećava sa vremenom što se može smatrati istrošenosti. Dakle, uporaba Weibullove razdiobe je pogodna za opisivanje krivulje *kade*. Na slici 5.6 prikazane su sve tri varijante Weibullove razdiobe sa $\beta < 1$, $\beta = 1$ i $\beta > 1$.



Slika 5.6: Prikaz Weibullove razdiobe u ovisnosti o faktoru β

5.2.4. Uniformna razdioba

Kontinuirana uniformna razdioba pripada vrsti simetričnih statističkih razdioba. Svi intervali na istoj duljini su jednako vjerojatni, kao što je prikazano na slici 5.7, te se stoga najčešće koristi kao neinformativni prior. Koristi se u slučajevima kada su vjerojatnosti svih događaja (kvarova) jednake. Obzirom da uniformna razdioba ima svojstvo neinformativnog priora, moguće je koristiti ju u slučajevima kada ne postoje nikakve raspoložive informacije, kao npr. u svrhu stvaranja generatora slučajnih (paslučajnih) brojeva.



Slika 5.7: Funkcija gustoće vjerojatnosti uniformne razdiobe

Funkcija gustoće vjerojatnosti je definirana kao:

$$f(x) = \begin{cases} \dfrac{1}{b-a}, & za\ a \le x \le b \\ 0, & za\ x < a\ ili\ x > b \end{cases} \tag{5.18}$$

Kumulativna funkcija razdiobe je definirana kao:

$$F(x) = \begin{cases} 0, & za\ x < a \\ \dfrac{x-a}{b-a}, & za\ a \le x \le b \\ 1, & za\ x > b \end{cases} \tag{5.19}$$

Vjerojatnost da uniformno distribuirana varijabla pada u bilo koji interval fiksne duljine je neovisna o lokaciji samog intervala, dokle god se interval nalazi u samoj razdiobi.

5.3. Osnovni modeli i strukture raspoloživosti

Serijska raspoloživost:

$$f(x) = x_1 x_2 \dots x_n = \prod_{i=1}^{n} x_i \tag{5.20}$$

Paralelna raspoloživost:

$$f(x) = 1 - (1 - x_1)(1 - x_2) \dots (1 - x_n) = 1 - \prod_{i=1}^{n}(1 - x_i) \tag{5.21}$$

k od *n* sustav:

$$f(x) = \begin{cases} 1, & ako\ je \sum_{i=1}^{k} x_i \geq k \\ 0, & u\ suprotnom \end{cases} \tag{5.22}$$

5.4. Dinamičko stablo kvara

Modeliranje pouzdanosti i raspoloživosti tehničkog sustava u predmetnom radu zasnovano je na metodologiji dinamičkog stabla kvara (eng. *Dynamic Fault Tree Analysis*) [69]. Model je grafički ilustriran i intuitivan, a zasniva se na Boolovoj algebri u kombinaciji sa Monte Carlo simulacijom [70] ili Petrijevim mrežama [71]. Proces stvaranja stabla kvara započinje na način da se hijerarhijski najviša točka proziva neželjenim događajem kojega se želi evaluirati a potom se grana u niže hijerarhijske skupine koje opisuju mogućnost dovođenja do neželjenog stanja. Glavne dvije skupine elemenata u stablu kvara su *događaji* i (logička) *vrata*. Najčešća vrata su I, ILI, NILI, prioritetna I, rezervna, itd. Fundamentalna razlika između stabla kvara i dinamičkog stabla kvara je što dinamička stabla kvara imaju vrata poput prioritetnih i rezervnih, koja se oslanjaju na statističke metode zasnovane Monte Carlo simulacijama ili Petrijevim mrežama, za razliku od standardnog stabla kvara koje je isključivo zasnovano na Boolovoj algebri. U predmetnoj disertaciji upotrjebljena su sljedeće vrata: I, ILI, prioritetna I, i rezervna.

Pri modeliranju je korišten software paket Windchill Quality Solutions 10.2.

5.4.1. I (*AND*) logička vrata

I logička vrata imaju svojstvo aktivacije u slučaju ako nastupe svi ulazni događaji. U slučaju da sustav koji se sastoji od dvije komponente A_1 i A_2 ulazi u stanje kvara jedino u slučaju da su obje komponente istovremeno u stanju kvara. Slika 5.8 ilustrira Markovljev model I logičkih vrata.

$$A_1 \cap A_2 \text{ ili } A_1A_2$$

$$P(A_1A_2) = (A_1|A_2)P(A_2) = (A_2|A_1)P(A_1) \tag{5.23}$$

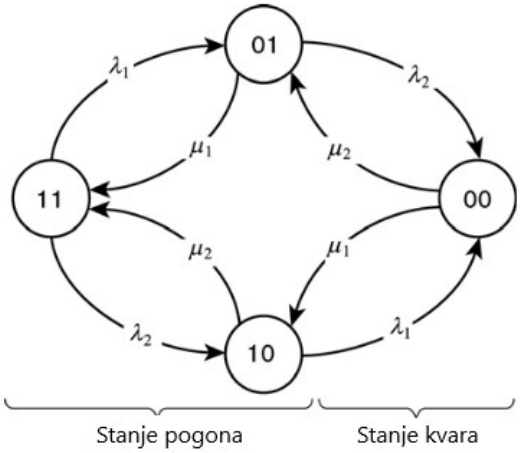
Ukoliko su događaji A_1i A_2 nezavisni vrijedi:

$$(A_1|A_2) = P(A_1)$$

$$(A_2|A_1) = P(A_2)$$

$$P(A_1A_2) = P(A_1)P(A_2)$$

$$P(A_1A_{2\ldots}A_N) = P(A_1)P(A_2)\ldots P(A_N) \tag{5.24}$$



Slika 5.8: Markovljev model I logičkih vrata

5.4.2. ILI (*OR*) logička vrata

ILI logička vrata imaju svojstvo aktivacije u slučaju ako nastupe bilo koji od ulaznih događaja. Sustav koji se sastoji od dvaju komponenata A_1 i A_2 biti će u stanju kvara ukoliko bilo koja od komponenti bude u stanju kvara. Slika 5.9 ilustrira Markovljev model ILI logičkih vrata.

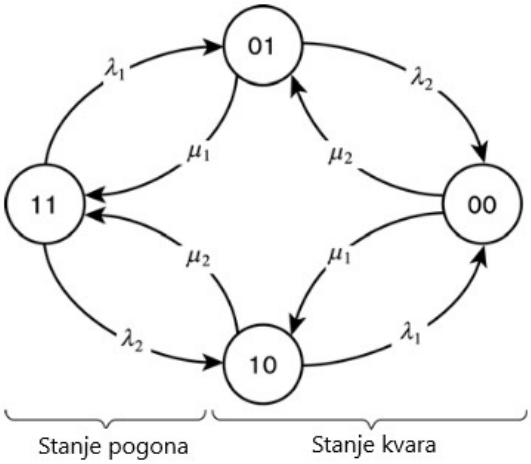
$A_1 \cup A_2$ ili $A_1 + A_2$

$$P(A_1 + A_2) = P(A_1) + P(A_2) - P(A_1A_2)$$

$$P(A_1 + A_2) = P(A_1) + P(A_2) - P(A_1)P(A_2) \tag{5.25}$$

$$P(A_1 + A_2 + \cdots + A_N) = \sum_{n=1}^{N} P(A_n) - \sum_{n=1}^{N-1} \sum_{m=n+1}^{N} P(A_n A_m) + \sum_{n=1}^{N-2} \sum_{m=n+1}^{N-1} \sum_{k=n+2}^{N} P(A_n A_m A_k) - \cdots + (-1)^{N-1} P(A_1 A_2 \ldots A_N)$$

$$P(A_1 + A_2 + \cdots + A_N) = 1 - \prod_{n=1}^{N} [1 - P(A_n)] \tag{5.26}$$



Slika 5.9: Markovljev model ILI logičkih vrata

5.4.3. Prioritetna I vrata (PAND)

Prioritetna I vrata (eng. Priority AND gate), imaju statistička svojstva kao i obična I vrata, no uz iznimku da je redoslijed grana ispod njega od velike važnosti, obzirom da se uvažava redoslijed kvarova na pojedinim komponentama, odnosno komponenta položena najviše lijevo mora biti prva u kvaru da bi se moglo razmatrati i kvarove sljedećih komponenti prema desno [72]. Isto kao što

je i slučaj kod standardnih I vrata tek u slučaju kvara svih komponenti vrata poprimaju svojstvo stanja kvara. Ako $F_t(A)$ i $F_t(B)$ označavaju vremena kvarova, odnosno događaja A i B, tada se vrijeme kvara PAND vrata definira kao $F_t(OUT)$, te za njega vrijedi:

$$F_t(OUT) = \begin{cases} F_t(B), \ ako \ F_t(A) < F_t(B) \\ F_t(A) ili \ F_t(B), \ ako \ F_t(A) = F_t(B) \\ \infty, \ \ ako \ F_t(A) > F_t(B) \end{cases} \tag{5.27}$$

5.4.4. Rezervna vrata

Rezervna vrata (eng. Spare Gates) su dinamički tip vrata svojstven dinamičkim stablima kvara. Rezervna vrata prelaze u stanje kvara u slučaju ako paralelna rezerva nije dostatna. Također, rezervna vrata mogu preći u stanje kvara iako komponenta ispod ne treba obavljati nikakvu funkciju, obzirom da je komponenta podložna učestalosti kvara, a koja je pod ovim vratima niža zbog djelovanja stupnja inhibicije, nego što bi to bilo u normalnom pogonu [73]. Ukoliko je učestalost kvara definirana sa λ, tada je učestalost kvara pod rezervnim vratima jednaka $\alpha\lambda$, gdje je α faktor inhibicije i definiran je na domeni $0 \leq \alpha \leq 1$.

5.5. Monte Carlo metoda

Monte Carlo je simulacijska metoda sa širokom primjenom u mnogim inženjerskim disciplinama i izvan njih. Za razliku od fizičkih eksperimenata, Monte Carlo metoda radi nasumično uzorkovanje i provodi znatan broj eksperimenata korištenjem računala. Potom, razmatraju se rezultati eksperimenata i donose zaključci zasnovani na provedenim statističkim eksperimentima. Osnovno načelo Monte Carlo simulacije je:

$$y = f(x_1, x_2, \dots, x_n) \tag{5.28}$$

gdje su $x_1, x_2, \dots, x_n$ slobodne lažno slučajne (umjetno stvorene, odnosno generirane) varijable [74]. Generiranje slučajnih brojeva potpomognuto računalom a uporabom prikladnog algoritma se u stvarnosti ne može smatrati istinski slučajnim procesom te se stoga u predmetnoj disertaciji za takve brojeve koristi izraz paslučajni (lažno slučajni, pseudo-slučajni) brojevi.

Statističke razdiobe odnosno razdiobe vjerojatnosti opisuju ishode nasumične varijable i stoga vjerojatnost događaja. Nasumično uzorkovanje u statistici se naziva uzorak. Generator nasumičnih brojeva je računalni ili fizički uređaj s kojim se stvaraju sekvence brojeva koji trebaju biti međusobno nezavisni te se podvrgavaju nizu različitih ispitivanja. Obzirom da se proces simulira tada treba govoriti zapravo o generatorima paslučajnih brojeva.

U svrhu provedbe Monte Carlo simulacije u predmetnom radu korišten je softwar-ski paket Microsoft Excel 2010 i njegova ugrađena *rand()* funkcija koja je zasnovana na Mersenne Twister MT19937 32-bitnom algoritmu. Spomenuti algoritam je superiorniji Wichman – Hillovom algoritmu obzirom da je isti u iznimno rijetkim okolnostima mogao proizvesti negativne rezultate. U predmetnom radu generator paslučajnih brojeva je zasnovan na uniformnoj razdiobi sa intervalom od 0 do 1.

Uporaba Monte Carlo metode započinje stvaranjem determinističkog modela u svrhu razumijevanja fizikalnih odnosa među tehničkim komponentama i određivanja početnog stanja svake komponente. Sljedeći korak je uporaba metode inverzne transformacije koja omogućuje najjednostavniji način za nasumično uzorkovanje iz razdiobe. U tu svrhu se koristi inverz funkcije gustoće vjerojatnosti pomoću koje se paslučajno generirani broj između 0 i 1 pretvara u nasumičnu vrijednost za ulaznu razdiobu. Ako se pretpostavi da je X kontinuirana nasumična varijabla koja slijedi funkciju gustoće vjerojatnosti f, tada je kumulativna razdioba vjerojatnosti označena s F i vrijedi sljedeći algoritam:

1. Generiranje $U \sim \mathrm{U}(0,1)$
2. Vraćanje $X = F^{-1}(U)$

Razlozi uporabe Monte Carlo simulacija u teoriji pouzdanosti i raspoloživosti su mnoge, kao npr. u svrhu određivanja duljine trajanja zastoja ili učestalosti zastoja, no za uspješnu i suvislu primjenu metode potrebno je poznavati i razdiobe pojedinih fenomena koje se želi istražiti. Analitičke metode omogućuju jednostavniji pristup rješavanju problema, te imaju prednost nad Monte Carlo metodom utoliko što nema potrebe za većim brojem ponavljanja i nisu zahtjevne, no ne mogu omogućiti razumijevanje dinamike podprocesa unutar sustava.

Glavna motivacija za uporabu Monte Carlo metode u predmetnom radu je u svrhu razumijevanja opterećenja pojedinih paralelnih izvora energije, a u svrhu estimacije troškova potrebnog goriva kao i emisije štetnih plinova u atmosferu.

5.6. Teorija informacija – entropija

Entropija je mjera nesigurnosti nasumične varijable [75]. Sukladno principu maksimalne entropije, ukoliko ništa nije poznato o statističkoj razdiobi osim u koju vrstu pripada tada valja pretpostaviti da je riječ o razdiobi s najvećom entropijom. Razlozi tome su dvojaki: maksimiziranjem entropije smanjuje se količina inicijalnih informacija ugrađenih u razdiobu i također se poštuje opažanje vezano za fizikalne sustave da kroz vrijeme teže ka entropiji.

Ako je X diskretna varijabla označena sa χ i funkcijom težinske vjerojatnosti $p(x) = P\{X = x\}, x \in \chi$, vrijedi sljedeća jednadžba za entropiju $H(X)$:

$$H(X) = -\sum_{x \in \chi} p(x) \log p(x) \tag{5.29}$$

Uniformna razdioba na intervalu [*a, b*] ima najveću entropiju u usporedbi s bilo kojom drugom razdiobom koja bi mogla vrijediti na intervalu [*a, b*], te je stoga gustoća razdiobe izvan intervala [*a, b*] jednaka nuli. Ako se interval [*a, b*] razdjeli na podintervale sa prikladnim vjerojatnostima $p_1, p_2, \dots, p_k$ čiji je ukupni zbroj jedan, a tako da vrijedi $a = a_0 < a_1 < \cdots < a_k = b$ tada se razmatra klasa svih kontinuiranih razdioba tako da vrijedi:

$$P\left(a_{j-1} \leq X < a_j\right) = p_j, za\ j = 1, \dots, k \tag{5.30}$$

Gustoća maksimalne entropije za opisanu klasu je konstantna na svim intervalima $\left[a_{j-1}, a_j\right)$.

Sukladno načelu indiferentnosti, koje se još u Bayesianskoj teoriji vjerojatnosti naziva još i najjednostavniji neinformativni prior, uniformna distribucija se može koristiti ukoliko definira jednu najmanje poznatu veličinu, no u slučaju da postoji više veličina podjednako nepoznatih samo jedna od njih se smije estimirati uniformnom razdiobom.

Za eksponencijalnu funkciju vrijedi da ima najveću entropiju među svim kontinuiranim razdiobama na intervalu [*0, ∞*] koje imaju specifičnu srednju vrijednost od 1/λ.

5.7. Teorija održavanja sa primjenom u podatkovnim i telekomunikacijskim postrojenjima

Strategije održavanja u telekomunikacijskoj i podatkovnoj infrastrukturi se može podijeliti u četiri kategorije: pogon do kvara, nestrukturirano održavanje, strukturirano održavanje i potpomognuto održavanje [10].

Pogon do kvara – metodologija ne podrazumijeva nikakvu prihvaćenu strategiju. Operator očekuje niske troškove i malu štetu u slučaju kvara ili se pouzda u zalihe sustave.

Nestrukturirano održavanje – održavanje postrojenja se obavlja, no, ne postoji jasna dokumentacija ili plan akcije. U ovakvu slučaju operator prepušta održavanje sustava proizvođačima opreme, no, bez holističkog uvida i razumijevanja o uporabi komponenti.

Strukturirano održavanje – vrijeme u pogonu se maksimizira smanjenjem ljudskog faktora. Održavanje je proaktivno, dokumentacija slijediva, ispitivanje opreme i osoblja je često.

Potpomognuto održavanje – najviši je red održavanja koji se sastoji od strukturiranog održavanja u kombinaciji sa strukturalnim dizajnom postrojenja. Dizajnom se utvrđuje arhitektura koja omogućuje nesmetano održavanje i nesmetano snabdjevenije tereta. Infrastruktura ima aktivne sustave za prikupljanje i analizu podataka u svrhu maksimiziranja stupnja djelovanja i smanjenja troškova.

Osim navedenih metoda održavanja potrebno je navesti i alternativnu sistematizaciju koja obuhvaća preventivno održavanje, korektivno održavanje i održavanje prema pouzdanosti.

Preventivno održavanje – podrazumijeva održavanje komponente ili postrojenja prije nego što nastupi kvar. Može biti zasnovano na određenom vremenskom intervalu. Prediktivno preventivno održavanje se obavlja uz postojanje aktivnog sustava nadzora pomoću čijih podataka se određuje potreba za održavanjem. Održavanje s obzirom na stanje komponente ili sustava je varijanta preventivnog održavanja u koju se kreće u slučaju događaja koji mogu navijestiti da bi moglo doći do neželjenog kvara.

Korektivno održavanje – set aktivnosti koje obavlja posada postrojenja ili ovlašteni inženjeri održavanja. Korektivno održavanje se treba obaviti u što kraćem vremenskom roku zbog visokih troškova vezanih za zastoj. Zbog navedenog, operateri telekomunikacijske ili podatkovne infrastrukture imaju ugovore sa proizvođačima opreme koji jamče dolazak ekspertne grupe na lokaciju postrojenja unutar 2 ili 4 sata od nastanka kvara. Troškovi korektivnog održavanja rastu kako oprema podvrgnuta održavanju stari.

Održavanje prema pouzdanosti – sustavna metoda uporabe preventivnog i korektivnog održavanja sa primarnim ciljem minimiziranja troškova, a uz zadržavanje najveće razine pouzdanosti i raspoloživosti komponente ili postrojenja.

5.8. Metodologija modeliranja i simuliranja

Pristupanje zasnivanju modela distribuiranih izvora energije, a posebice izvorima temeljenim na energiji sunca i vjetra kao primarnog izvora, moguće je korištenjem dvije metode:

- statičke
- dinamičke

Statička metoda podrazumijeva zasnivanje modela na srednjim mjerenim vrijednostima proizašlim iz mjerenja obavljenih tijekom perioda vremena, te za takove modele, također, vrijedi pravilo da sustav u trenutnom stanju ne pamti stanje iz prethodnog stanja.

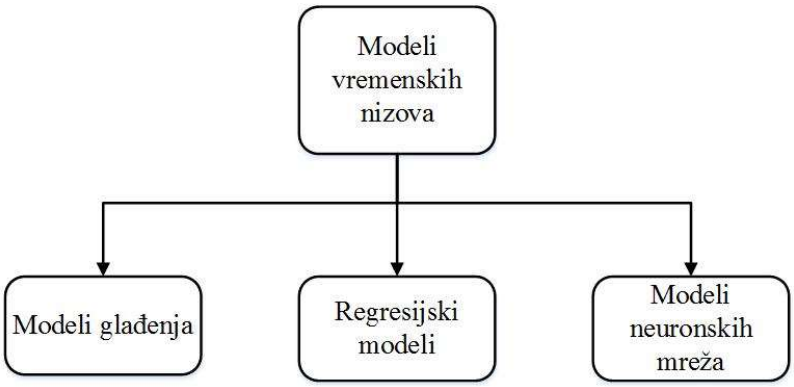
Za razliku od statičke metode, dinamička podrazumijeva uporabu (mjernih) vrijednosti dediciranih svakoj pojedinoj točki u vremenu, te se stoga takvi modeli se slobodno mogu smatrati i modelima sa memorijom obzirom da svako novo stanje ovisi o prethodnom stanju.

5.9. Predviđanje vremenskih nizova

Predviđanje vremenskih nizova modeliranjem je zadnjih godina veliko područje koje je pobudilo interes znanstvene i tehničke zajednice. Glavni cilj ovog područje je pažljivo sakupljanje i obrada

podataka u svrhu stvaranja modela koji omogućuju generiranje budućih vrijednosti koje čine vremenske nizove u budućnosti. Postoje mnoge metode pomoću kojih se mogu stvarati predikcijski modeli, no također je važno za napomenuti da je odabir metode od krucijalne važnosti a u ovisnosti je o vrsti problema koji se želi elaborirati, načinu prikupljanja podataka kao i vrsti podataka.

Općenito, modeli vremenskih nizova se daju podijeliti u tri osnovne grupe kao što je prikazano na slici 5.10.



Slika 5.10: Podjela modela vremenskih nizova [76]

5.9.1. Modeli glađenja

Metoda poznata pod nazivom na engleskom jeziku *Smoothing method*, te za glavni cilj ima umanjiti učinke oscilacija u vremenskim nizovima.

Neke od najvažnijih metoda glađenja:

- Pomična srednja vrijednost (eng. Moving Average, MA)
- Eksponencijalno glađenje
- Kalmanov filter
- Holt-Winter metoda

Kao najnaprednija metoda među metodama glađenja ističe se Holt-Winter [77], također, poznata i kao metoda trostrukog eksponencijalnog glađenja. Metodu je najbolje primijeniti kada podatci nisu stohastički, niz ima trend i postoji komponenta sezonalnosti u nizu.

Ako se promatrani vremenski niz označi sa y_1, y_2,..., y_n tada je predviđanje y_{t+h} označeno kao $\hat{y}_{t+h|t}$ za h perioda u budućnosti.

$$\hat{y}_{t+h|t} = l_t + b_t h + s_{t-m+h_m^+}$$

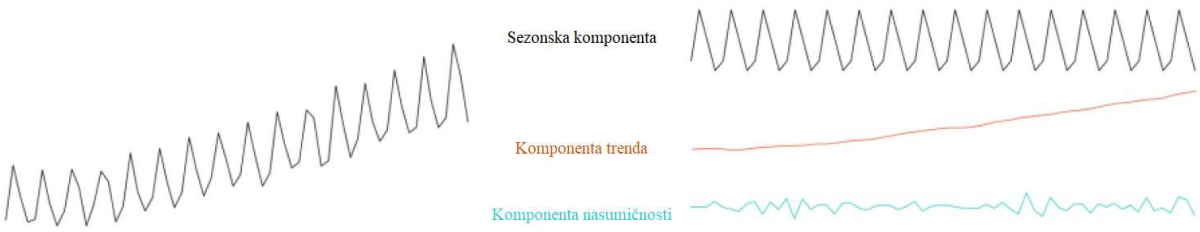
$$l_t = \alpha(y_t - s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1})$$

$$b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1} \tag{5.31}$$

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1-\gamma)s_{t-m}$$

$$h_m^+ = [(h-1) mod\ m] + 1$$

U jednadžbama m je duljina sezone, l_t razina niza, b_t prirast, s_t sezonska komponenta. Na slici 5.11 prikazane su komponente Holt-Winter metode: sezonska komponenta, komponenta trenda i komponenta nasumičnosti.



Slika 5.11: Prikaz komponenti Holt-Winter metode [76]

5.9.2. ARIMA modeli

Akronim metode vrijedi za *Auto Regressive Integrated Moving Average* na engleskom jeziku odnosno u prijevodu Autoregresivna integrirana pomična srednja vrijednost i predstavljaju ekstenziju na autoregresivne modele. Metodu su popularizirali Box i Jenkins [78] te se stoga u literaturi metoda još naziva i Box-Jenkinsovom metodom, a može se smatrati glavnom metodom regresijskih modela.

Glavna pretpostavka metode je da je vremenski niz linearan, te da slijedi specifičnu statističku distribuciju. Također, postoje mnoge podgrupe ove metode kao što su:

- Autoregresija (eng. *Autoregression*, AR)

- Autoregresivna integrirana pomična srednja vrijednost (eng. *Auto Regressive Integrated Moving Average*, ARMA)
- Sezonska autoregresivna integrirana pomična srednja vrijednost (eng. *Seasonal Auto Regressive Integrated Moving Average*, SARIMA)
- Model nasumičnog hoda
- Model nasumičnog trenda

Ukoliko se sagleda komponente ARIMA modela, autoregresija se može modelirati kao $y_t = a_1 y_{t-1} + \cdots + a_p y_{t-p} + e_t$, integrirano podrazumijeva stupanj diferenciranja vremenskog niza dok pomična srednja vrijednost (MA) podrazumijeva šum ugrađen u svrhu poboljšanja kvalitete predviđanja, te ima oblik: $y_t = e_t + b_1 e_{t-1} + \cdots + b_q e_{t-q}$.

U konačnici ARIMA model poprima sljedeći oblik:

$$y_t = a_1 y_{t-1} + \cdots + a_p y_{t-p} + e_t + b_1 e_{t-1} + \cdots + b_q e_{t-q} \tag{5.32}$$

Najčešći načini podešavanja Box-Jenkinsovog modela su temeljeni na uporabi metode najmanjih kvadrata i estimaciji najveće vjerojatnosti [79].

5.9.3. Simuliranje vremenskih nizova pomoću modela umjetnih neuronskih mreža

Umjetne neuronske mreže (UNM) su zasnovane na modelu ljudskog mozga obzirom da se sastoje od međusobno povezanih neurona. Jednako kao što je slučaj s ljudskim mozgom, umjetna neuronska mreža funkcionira na način da svaki neuron reagira na podražaj kojeg mu šalje drugi neuron. To svojstvo omogućava UNM učenje obrazaca temeljem kojih mogu realizirati prepoznavanje i kategoriziranje nikad viđenih predmeta ili pojava. UNM tijekom procesa uvježbavanja prepoznaje obrasce među datim podatcima. Nakon što je UNM uvježbana može se primijeniti na drugi set ulaznih vrijednosti u svrhu predviđanja ishoda.

U usporedbi s drugim metodama simulacija, poput metoda navedenih prethodno, zahvaljujući svojim dinamičkim svojstvima UNM omogućuje najbolje rezultate pri procesiranju nelinearnih vremenskih nizova [80]-[87].

Modeli se predikcije zasnovani na UNM mogu podijeliti na više vrsta modela i podmodela među kojima su tri vrste modela najznačajnije za predviđanje nelinearnih vremenskih nizova: nelinearni autoregresivni modeli s vanjskim ulazom, (*eng. Nonlinear AutoRegressive with Exogenous Inputs - NARX*), nelinearni autoregresivni model (*eng. Nonlinear AutoRegressive - NAR*) i nelinearni ulaz – izlaz (*eng. Nonlinear Input-Output - NIO*).

Uvježbavanje UNM je jedno od njezinih glavnih svojstava. Kroz proces uvježbavanja određuju se parametri h i $\varepsilon(t)$. Parametar h se određuje kroz proces uvježbavanja UNM, te je nepoznata unaprijed. Kroz proces treniranja UNM provodi se postupak optimiziranja težinskih faktora i veza među neuronima. Parametar $\varepsilon(t)$ označava grešku (šum) aproksimirane vrijednosti *y* u vremenu *t*. Parametar *p* se naziva zatezanjem povratne veze. Konačna topologija mreže se stječe kroz metodu pokušaja i pogrešaka, te je važno izabrati dostatan broj neurona u unutarnjem sloju budući da premali broj neurona neće davati dovoljno dobre rezultate dok s druge strane prevelik broj neurona će otežati proces treniranja što se može odraziti na vrijeme potrebno za simulaciju.

U svrhu uvježbavanja UNM najčešće se koristi Levenberg - Marquardtov algoritam povratnog širenja (*eng. Levenberg-Marquardt Backpropagation Procedure - LMBP*). Algoritam se inače koristi za rješavanje problema nelinearnih najmanjih kvadrata a sadrži najbolja svojstva metode padajućeg gradijenta i Gauss-Newtonove metode obzirom da se tjemena funkcije traže pomoću padajućeg gradijenta te se potom pomoću Gauss-Newtonove metode traži ekstrem. Algoritam funkcionira na način da aproksimira derivacije drugog reda bez izračunavanja Hessianove matrice, što u konačnici omogućuje veću brzinu uvježbavanja UNM. Algoritam započinje inicijalnim pogađanjem x_0 a potom se *x* ugađa pomoću parametra δ i to jedino za korake na niže.

$$(\boldsymbol{J^T J} + \lambda \boldsymbol{I})\delta = \boldsymbol{J^T} r \tag{5.33}$$

gdje je $\boldsymbol{J}$ Jakobijeva matrica derivacija reziduala u odnosu na parametre, λ parametar opadanja odnosno adaptivne ravnoteže između dva koraka, a parametar *r* rezidualni vektor.

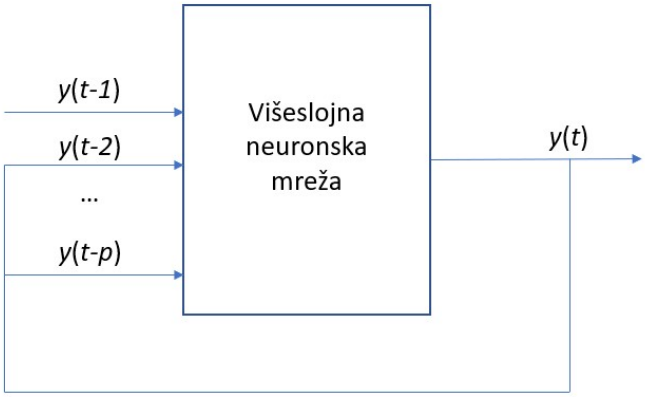
Vremenski nizovi poput sunčeve radijacije ili brzine vjetra su nelinearnog karaktera, te to ukazuje na opravdanost uporabe nelinearnih umjetnih neuronskih mreža.

Nelinearni autoregresivni model

Nelinearne autoregresivne UNM imaju primjenu pri modeliranju nelinearnih, autoregresivnih, diskretnih modela, koji se mogu opisati sljedećom jednadžbom:

$$y(t) = h\big(y(t-1), y(t-2), \dots, y(t-p)\big) + \varepsilon(t) \tag{5.34}$$

U suštini, NAR model je zapravo algoritam povratnog širenja s funkcijom zatezanja, prikazan na slici 5.12. Model predikcije koristi rekurzivnu predikcijsku metodu što rezultira smanjenom greškom predikcije.

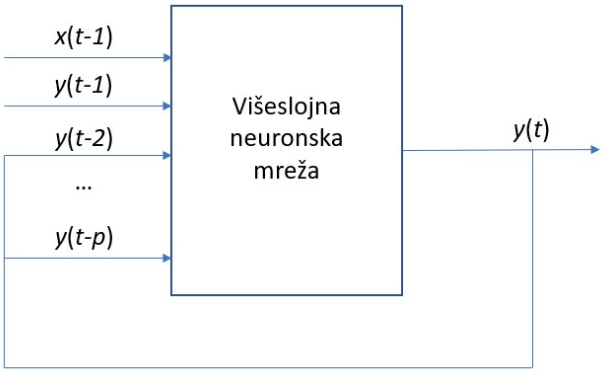


Slika 5.12: NAR tip UNM [85]

Nelinearni autoregresivni modeli s vanjskim ulazom (NARX)

NARX je nelinearni model koji estimira buduće vremenske nizove u ovisnosti o eksternim podatcima i podatcima generiranim preko povratne veze, prikazan na slici 5.13. Prednost ove metode je u modelima koji podrazumijevaju pojave koje ovise o više faktora među kojima postoji korelacija. Model se može opisati jednadžbom:

$$y(t) = h\big(y(t-1), y(t-2), \dots, y(t-p), x(t-1), x(t-2), \dots, x(t-p)\big) + \varepsilon(t) \tag{5.35}$$

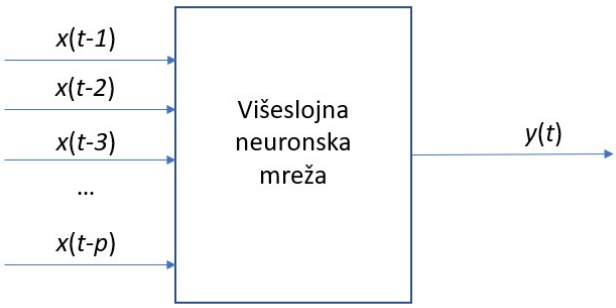


Slika 5.13: NARX tip UNM [85]

Nelinearni ulaz – izlaz (NIO)

U NIO modelu UNM izlazni niz vrijednosti $y(t)$ je prediciran u ovisnosti o ulaznom nizu vrijednosti $x(t)$ bez povratne veze, odnosno bez utjecaja prijašnje generiranih generacija nizova $y(t)$. Model je prikazan na slici 5.14, a može se opisati jednadžbom:

$$y(t) = h\big(x(t-1), x(t-2), \dots, x(t-p)\big) + \varepsilon(t) \tag{5.36}$$



Slika 5.14: NIO tip UNM [87]

5.10. Modeliranje uporabom neizrazite logike, Delphi i TOPSIS metode

5.10.1. Neizrazita logika

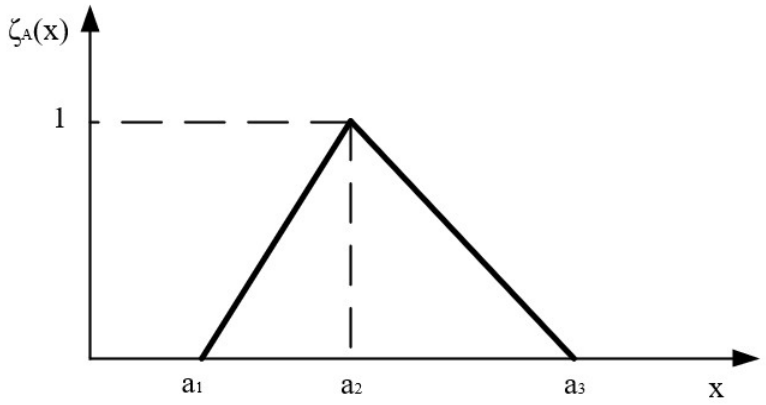
Neizrazita logika je oblik logike s više vrijednosti u kojoj istinite tvrdnje (vrijednosti) mogu biti bilo koji realni broj na intervalu [0, 1], što je kontrast Boolovoj logici gdje vrijednosne tvrdnje mogu biti isključivo 0 ili 1. Neizrazita logika je zasnovana na promatranju načina kako ljudi donose prosudbu na temelju nepreciznih nebrojčanih informacija. Vrijednosti i brojevi neizrazite logike imaju jako široku primjenu u inženjerstvu zbog svog svojstva da mogu predočiti informacije s manjim stupnjem sigurnosti [88].

Glavna razlika između setova s brojčanim vrijednostima i neizrazitih setova se očituje u uvođenju pojma *funkcije pridruživanja* [89]. Ukoliko postoji konačni set $X = \{x_1, x_2, \dots, x_n\}$ tada se podskup A skupa X sastoji od jediničnog elementa x_1 i može se opisati n-dimenzionalnim vektorom pridruživanja $Z(A) = (1, 0, 0, \dots, 0)$ te, također vrijedi konvencija da broj 1 na i-tom mjestu ukazuje na x_i koji pripada A. Ako se set B sastoji od elemenata x_1 i x_n tada je opisan vektorom $Z(B) = (1, 0, 0, \dots, 1)$. Neizraziti set $\tilde{A}$ se definira kao $\tilde{A} = \{(x, \zeta_A(x)) : x \in A, \zeta_A(x) \in [0, 1]\}$. Element x pripada podskupu A, a element $\zeta_A(x)$ pripada intervalu $[0, 1]$ te se naziva funkcija pridruživanja.

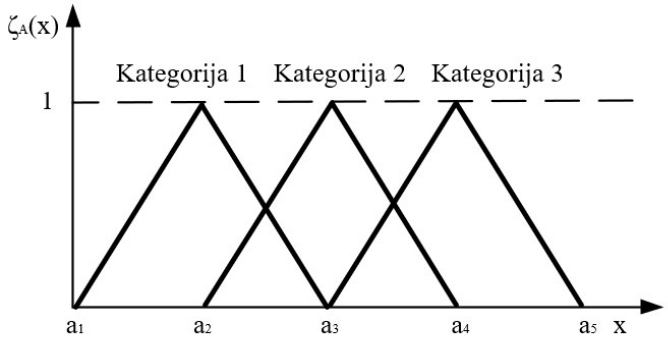
Ukoliko je neizraziti broj predočen pomoću seta od tri točke naziva se trokutastim neizrazitim brojem [90] a može se definirati kao triplet (a_1, a_2, a_3), te je tada funkcija pridruživanja definirana kao:

$$\zeta_{\tilde{A}}(x) = \begin{cases} 0, & x < a_1 \\ \dfrac{x - a_1}{a_2 - a_1}, & a_1 \le x \le a_2 \\ \dfrac{a_3 - x}{a_3 - a_2}, & a_2 \le x \le a_3 \\ 0, & x > a_3 \end{cases} \tag{5.37}$$

Na slici 5.15 je grafički prikaz neizrazitog broja zasnovanog na trokutastoj funkciji odnosno zasnovanoj na tripletu. Na slici 5.16 prikazana je funkcija pridruživanja sa primjerom od tri kategorije (npr. hladno, mlako i vruće) zasnovana na trokutastoj funkciji pridruživanja.



Slika 5.15: Prikaz neizrazitog broja u trokutastoj funkciji pridruživanja [90]



Slika 5.16: Kategorije sa trokutastom funkcijom pridruživanja [88]

5.10.2. Neizrazita Delphi metoda

Procesiranje prosudbenih informacija statističkim alatima ne dozvoljava problemima pristranosti i nesigurnosti da se uzmu u obzir. Klasična Delphi metoda se zasniva na teoriji da je prosudba grupe ljudi vrjednija od individualne prosudbe. Obično svi sudionici u procesu odlučivanja ostaju anonimni čak i nakon završetka konačnog izvještaja što je nužno u svrhu suzbijanja mogućnosti međusobnog utjecanja [91]. U neizrazitoj Delphi metodi uzima se, također, u funkcija pridruživanja prosjeka grupe [92].

Proces se odvija na sljedeći način [93]:

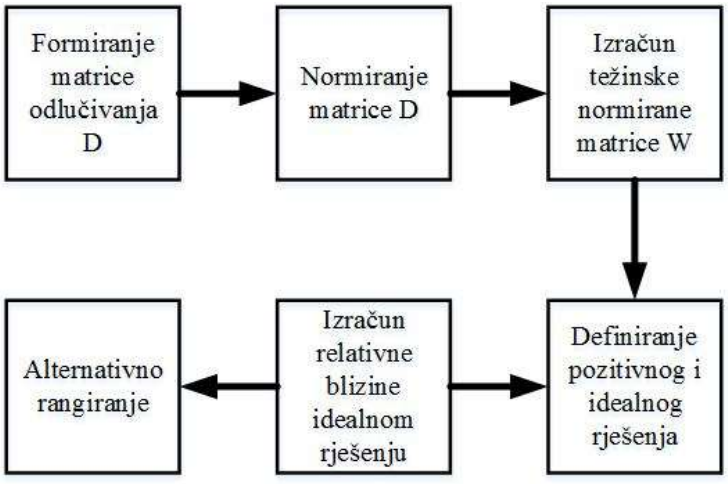
1. Određivanje kvalitativnih podataka (događaja) koji formuliraju prvi upitnik

2. Određivanje funkcije pridruživanja trokutastog oblika za svaki događaj. U ovom koraku se određuju minimalne, maksimalne i srednje vrijednosti
3. Nadopunjavanje upitnika s vrijednostima izračunatim u koraku 2 i ponovno izdavanje nadopunjenih upitnika ekspertima na evaluaciju
4. Provedba statističkog testiranja u svrhu utvrđivanja ako su funkcije pridruživanja konvergirale
5. Ukoliko su funkcije pridruživanja konvergirale iznalazi se neizraziti broj koji opisuje lingvistički termin

5.10.3. TOPSIS metoda

TOPSIS je višekriterijska analitička metoda zasnovana na konceptu da najbolja alternativa ima najkraću geometrijsku udaljenost od pozitivnog idealnog rješenja i najdalju od geometrijsku udaljenost od negativnog idealnog rješenja [94]-[97]. Akronim TOPSIS stoji za naziv na engleskom jeziku *Technique for Order of Preference by Similarity to Ideal Solution*.

Metoda započinje definiranjem problema nakon čega se stvara polje mogućih alternativnih rješenja na koje se primjenjuje metoda i na kraju razmatra ishod. Hodogram provedbe TOPSIS metode je ilustriran na slici 5.17.



Slika 5.17: TOPSIS procedura [96]

1. Definiranje ulazne matrice odlučivanja (D):

$$D = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \tag{5.38}$$

2. Izračun normirane matrice odlučivanja (R):

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^{m} X_{ij}^2}} \tag{5.39}$$

$$R = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ r_{21} & r_{22} & \dots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1} & r_{m2} & \dots & r_{mn} \end{bmatrix} \tag{5.40}$$

3. Izračun težinske matrice:

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{m1} & w_{m2} & \dots & w_{mn} \end{bmatrix} \tag{5.41}$$

4. Izračun težinske normirane matrice

$$V = \begin{bmatrix} r_{11}w_1 & r_{12}w_2 & \dots & r_{1n}w_n \\ r_{21}w_1 & r_{22}w_2 & \dots & r_{2n}w_n \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1}w_1 & r_{m2}w_2 & \dots & r_{mn}w_n \end{bmatrix} \tag{5.42}$$

5. Određivanje pozitivnog idealnog (A^+) i negativnog idealnog (A^-) rješenja

$$A^+ = \left\{(max\ v_{ij} | j \in J), (min\ v_{ij} | j \in J') | i = 1, 2, \dots, m\right\} = \left\{v_1^+, v_2^+, \dots, v_j^+, \dots, v_n^+\right\} \tag{5.43}$$

$$A^- = \left\{(min\ v_{ij} | j \in J), (max\ v_{ij} | j \in J') | i = 1, 2, \dots, m\right\} = \left\{v_1^-, v_2^-, \dots, v_j^-, \dots, v_n^-\right\} \tag{5.44}$$

gdje J predstavlja kriterije sa beneficijama a J' troškovne kriterije

6. Proračunavaju se mjere udaljenosti pomoću n-dimenzionalne Euklidove udaljenosti za pozitivnu i negativnu varijantu

$$S_i^+ = \sqrt{\sum_{j=1}^{m} \left(V_{ij} - V_j^+\right)^2} \tag{5.45}$$

$$S_i^- = \sqrt{\sum_{j=1}^{m} \left(V_{ij} - V_j^-\right)^2} \tag{5.46}$$

7. Izračun relativne blizine idealnom rješenju alternative A_i u odnosu na A^+:

$$P_i = \frac{S_i^-}{S_i^+ + S_i^-} \tag{5.47}$$

Obzirom da su udaljenosti $S_i^+ \geq 0$ i $S_i^- \geq 0$ tada je evidentno $P_i \in [0, 1]$.

8. Rangiranje rješenja na način da najbolje rješenje ima najviši P_i

6. MODELI RASPOLOŽIVOSTI

6.1. Modeli raspoloživosti distribuiranih izvora energije

6.1.1. Raspoloživost sunčeve elektrane

Pri dimenzioniranju Sunčevih elektrana uzeta je u obzir degradacija kapaciteta proizvodnje [98]-[100] Sunčeve elektrane u iznosu od 1% godišnje (s obzirom na prvi dan instalacije a ne progresivno) tijekom perioda eksploatacije od 10 godina, te je stoga Sunčeva elektrana predimenzionirana za dodatnih 10% povrh ugrađene redundancije za slučaj kvara.

U slučaju Sunčevih elektrana donesena je pretpostavka da je operativna raspoloživost panela jednaka inherentnoj raspoloživosti obzirom da je vjerojatnost kvara samog panela jako mala nakon probnog perioda, te jedino što može ometati rad Sunčeve elektrane je neodržavanje koje se očituje u vidu onečišćenja što u konačnici rezultira smanjenim proizvodnim kapacitetom. U modelu se smatra da je održavanje provedeno savršeno, a troškovi održavanja su estimirani na 2% godišnje s obzirom na kapitalnu investiciju.

Korišteni su 12V paneli od 250W izlazne snage složeni u električku seriju tako da čine *grupu* od 60 panela na naponskoj razini 720V i 15kW na izlazu nominalno [6]-[8]. Grupe su složene u *nizove* od po pet grupa, te stoga jedna grupa na svom izlazu može omogućiti 75kW nominalno. U smislu raspoloživosti model je predstavljen serijskom raspoloživosti panela. U tablici 6.1 su iskazane pripadne vrijednosti MTBF, MTTR i A_I za panele grupe i nizove, sukladno prethodno spomenutom načelu modeliranja.

Tablica 6.1: Predložene konfiguracije fotonaponskih panela modelirane SE

	MTBF (h)	MTTR (h)	A_I
12V panel	5 256 000	8	0,999998
720V grupa	87 600	8	0,999909
niz	17 520	8	0,999544

6.1.2. Raspoloživost vjetroelektrane

Problem iznalaženja optimalnog rješenja za hibridni sustav je već opisan u prethodnim dijelovima rada. Evidentno je da uporaba više manjih vjetroelektrana povoljnije djeluje u odnosu na uporabu samo jedne velike koja omogućava potrebni kapacitet. Vjetroelektrane na kopnu snage od 250 kW naviše imaju operativnu raspoloživost u iznosu od 97% [25]. Ta razina raspoloživosti nije dovoljno dobra za podatkovni centar Razine 4, te je u tu svrhu izrađena tablica koja proizlazi iz binomne razdiobe u svrhu razumijevanja koliko redundancije se treba ugraditi kako bi se dostigla potrebna razina raspoloživosti od *3x9* ili *4x9*. S *k* je označen broj vjetroelektrana potrebnih za zadovoljavanje kapaciteta, a sa *n* ukupan broj vjetroelektrana potrebnih za zadovoljavanje tražene razine raspoloživosti, kao što je naznačeno u tablici 6.2.

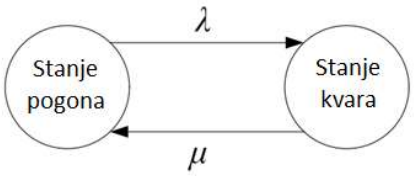
Tablica 6.2: Prekapacitiranost grupe vjetroagregata u svrhu postizanja tražene razine raspoloživosti

k	N (3x9)	3x9	Prekapacitet	N (4x)	4x9	Prekapacitet
1	2	0,9991	100%	3	0,999973	200%
2	4	0,999894	100%	5	0,999996	150%
3	5	0,999742	67%	6	0,999988	100%
4	6	0,999496	50%	7	0,999974	75%
5	7	0,999137	40%	8	0,999949	60%
6	8	0,99865	33%	9	0,99991	50%
7	10	0,999853	43%	11	0,99999	57%
8	11	0,999774	38%	12	0,999984	50%
9	12	0,99967	33%	13	0,999974	44%
10	13	0,999534	30%	14	0,999961	40%
11	14	0,999363	27%	15	0,999943	36%
12	15	0,999152	25%	16	0,99992	33%
13	17	0,999889	31%	18	0,99999	38%
14	18	0,99985	29%	19	0,999986	36%
15	19	0,999801	27%	20	0,99998	33%
16	20	0,999742	25%	21	0,999973	31%
17	21	0,999669	24%	22	0,999964	29%
18	22	0,999583	22%	23	0,999953	28%
19	23	0,99948	21%	24	0,999938	26%
20	24	0,999359	20%	25	0,999921	25%
21	25	0,999219	19%	26	0,9999	24%
22	26	0,999057	18%	27	0,999875	23%

23	28	0,999845	22%	29	0,999981	26%
24	29	0,999809	21%	30	0,999976	25%
25	30	0,999767	20%	31	0,99997	24%
26	31	0,999719	19%	32	0,999962	23%
27	32	0,999663	19%	33	0,999953	22%
28	33	0,999598	18%	34	0,999942	21%
29	34	0,999525	17%	35	0,99993	21%
30	35	0,999441	17%	36	0,999915	20%

6.1.3. Raspoloživost dizel agregata

Model pretpostavlja uporabu monolitičkog sustava koji je u mogućnosti na svom pragu proizvoditi 1 MWe snage. Obzirom da su korištene cijene za 1 kWe izlazne snage za Razinu 4 raspoloživosti može se smatrati da je zalihost pri dimenzioniranju dostatna u svrhu ispunjavanja kriterija Razine 4. Unatoč tome što se u ovom modelu dizel generator upotrebljava kao pomoćni izvor električne energije on sukladno pravilima Razine 4 arhitekture za podatkovne centre treba biti dimenzioniran kao kontinuirani dizel generator te je iz tog razloga operativna raspoloživost u iznosu od 0,9969 [101] i sukladno parametrima prikazanim u tablici 6.3. Predloženi model raspoloživosti dizel agregata prikazan je na slici 6.1 i dozvoljava dva stanja – stanje pogona i stanje kvara zajedno sa pripadnim intenzitetima kvara (λ) i popravka (μ).



Slika 6.1: Predloženi model raspoloživosti dizel agregata zasnovan na Markovljevom modelu

Tablica 6.3: Indikatori raspoloživosti dizel agregata [101]

	Kontinuirani	**Pomoćni**
A_I	0,998287624	0,999742312
A_O	0,99692725	0,997409685
MTBF	15 033,8 h	70 932,0 h
MTTR	25,74 h	18,28 h
Kvar pri startu	0,15%	0,60%

6.1.4. Raspoloživost plinskih agregata

Plinski agregati su s obzirom na svoja svojstva jako slični dizel agregatima, te je stoga model plinskog agregata u ovom radu zasnovan na istom načelu kao i u slučaju dizel generatora, izuzev činjenice da su inherentna i operativna raspoloživost više u odnosu na dizel agregate. Obzirom da su i plinski i dizel agregat gotovo isti strojevi koji koriste različito gorivo, pretpostavlja se da je glavni razlog razlici među raspoloživostima tih strojeva ta da dizel generator mora imati tank dostatan za 72 h autonomije odakle se gorivo distribuira prema agregatu pomoću crpki, te su stoga crpke zapravo podsustavi koji čine razliku u raspoloživosti, budući da se plinski agregat opskrbljuje izravno iz plinske mreže koja je pod tlakom. U tablici 6.4 su glavni parametri za modeliranje raspoloživosti komponente.

Tablica 6.4: Indikatori raspoloživosti plinskih agregata [101]

A_I	0,999791533
A_O	0,999743425
MTBF	4 796 923 h
MTTR	1 h

6.1.5. Raspoloživost gorivih ćelija

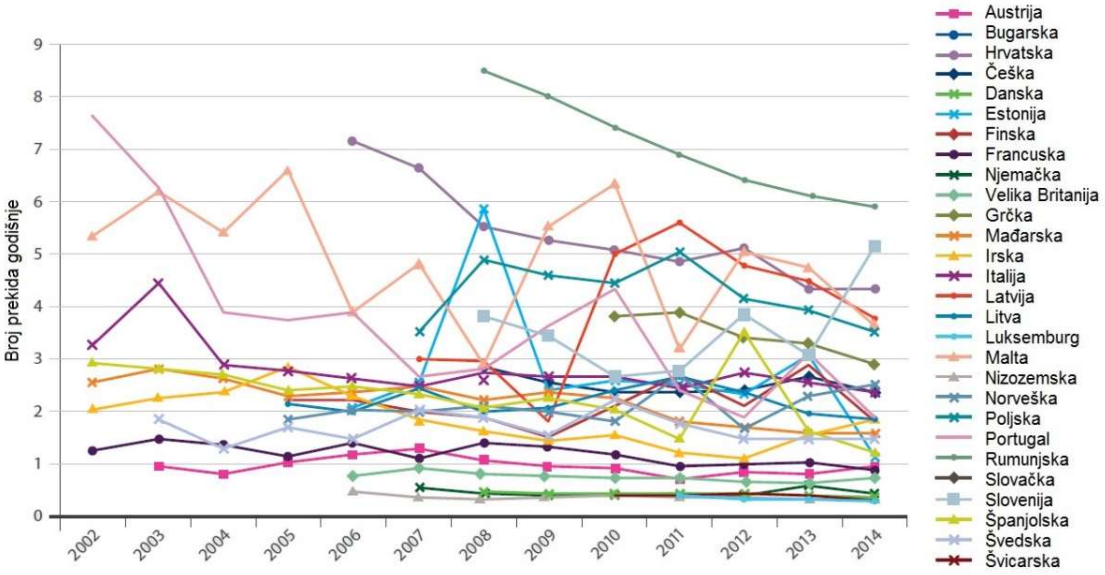
Operativna raspoloživost 200 kW SOFC varijante gorivih ćelija sa stogovima od 50 kW je 0,999999 [37], te se za model od 1 MW koristi pet blokova od 200 kW. Iz tog razloga model raspoloživosti sustava gorivih ćelija od 1 MW je serijski model od pet komponenti.

6.1.6. Raspoloživost krute mreže

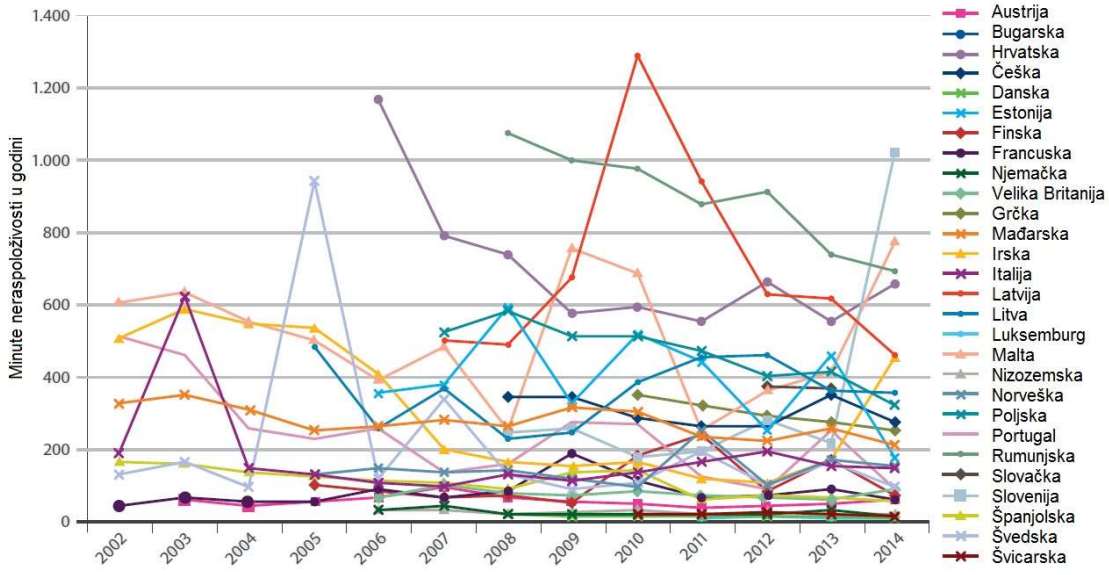
Raspoloživost spoja na krutu javnu mrežu je modelirana tako da iznosi jednako kao i sama raspoloživost krute mreže. U model je uključena transformatorska stanica nužna za napajanje iz pojne mreže za koju se pretpostavlja da je na srednjem naponu. Kritični element u smislu raspoloživosti je sam transformator sa srednjeg na niski napon koji ako je implementiran u suhoj izvedbi ima raspoloživost od 0,999999 te se stoga može i zanemariti njegov utjecaj na ukupnu raspoloživost spoja u odnosu na razinu raspoloživosti same mreže.

Raspoloživosti same komercijalne mreže se razlikuju po zemljama [102], sukladno prikazima na slikama 6.2 i 6.3. Na slici 6.2 prikazani su podaci o godišnjem broju ispada pojne mreže za EU-28

zemlje kroz godine. Na slici 6.3 prikazani su podaci o godišnjoj neraspoloživosti pojnih mreža u EU-28 kroz godine.



Slika 6.2: Broj prekida opskrbe u zemljama EU-28 [102]



Slika 6.3: Neraspoloživost pojne mreže u izraženo u minutama godišnje u zemljama EU-28 [102]

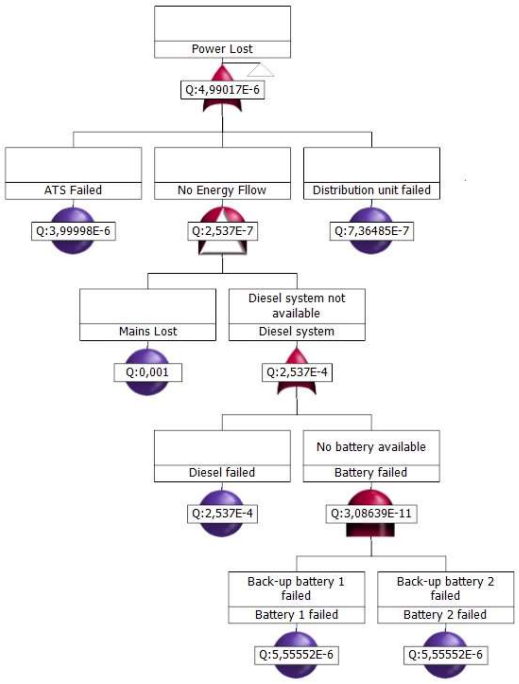
6.2. Raspoloživost podatkovne i telekomunikacijske infrastrukture

Jedan od najvažnijih elemenata u električnoj arhitekturi podatkovne i telekomunikacijske infrastrukture je besprekidni sustav napajanja (eng. *uninterruptible power supply* - UPS), koji ima dvostruku funkciju. U normalnom režimu rada napajanja iz primarnog izvora treba omogućiti visoku kvalitetu opskrbe s električnom energijom potrošača na način da umanjuje učinke uzrokovane prenaponima, propadima napona, omogući otvaranje prekidača u slučaju kratkog spoja itd. U slučaju nestanka napajanja iz primarnog izvora zadaća UPS-a je da premosti vrijeme na način da preuzme teret na sebe sve do uspješnog pokretanja paralelnog izvora energije, a uporabom vlastitog spremnika energije [5], [9].

Ako se uvaži prethodno navedeno, bitno je razumjeti ulogu UPS-a i kako istoga modelirati u modelima pouzdanosti i raspoloživosti. Obzirom da je u predmetnom radu tema raspoloživost bitno je ukazati na to kako je modeliranje UPS-a zapravo logički drugačije od jednakog kako se može naći u većini relevantne literature. Naime, namjena UPS-a je da potpomogne povećanje raspoloživosti arhitekture, a ne da bude još samo jedna komponenta u sustavu koja ima svoj vjerojatnost kvara. To je posebice uočljivo u slučaju uporabe paralelnog spremnika energije (baterija) budući da kvar na baterijama neće imati utjecaj na pravilno funkcioniranje UPS-a obzirom da je UPS tako konstruiran. U slučaju kvara baterije ista će se od spojiti od UPS-a, a njegovo djelovanje će nastaviti normalno funkcionirati. Kvarovi na baterijama se uklanjaju na način da se zamjeni neispravni blok, te nakon što je zamjena obavljena, UPS ima mogućnost nesmetano davati energiju iz baterije. Iz tog razloga se često baterije strukturiraju sukladno (N+1) principu, da u slučaju kvara na jednom baterijskom nizu UPS i dalje može nesmetano koristiti ostatak baterijske rezerve i to jedino u slučaju ako opskrba energijom iz primarnog izvor energije bude prekinuta.

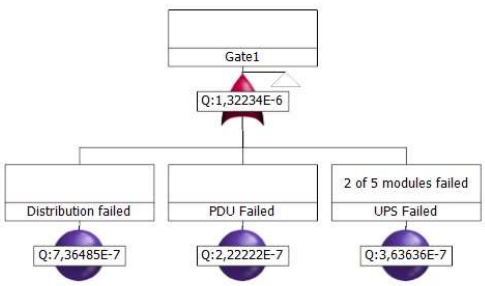
Poradi navedenih razloga, procjenjivati samu raspoloživost UPS-a je besmisleno budući da je bitan njegov doprinos podizanju ukupnoj raspoloživosti električke arhitekture, a ne samo raspoloživost njegovih komponenti. Način kako se može realizirati evaluacija doprinosa različitih tipova UPS jedinica je da se načini evaluacija cjelokupne arhitekture koju isti trebaju podupirati.

Na slikama 6.4 – 6.6 prikazani su modeli raspoloživosti električne arhitekture podatkovnog centra zasnovani na metodi dinamičnog stabla kvara korišteni u radu [9]. Model se sastoji iz tri dijela na način da su ishodi dvaju modela zapravo ulazni podaci u trećem modelu. Na slici 6.4 prikazan je model raspoloživosti aktivnih elemenata poput pomoćnih dizel agregata, pojne mreže i spremnika energije ali i automatske transfer sklopke.



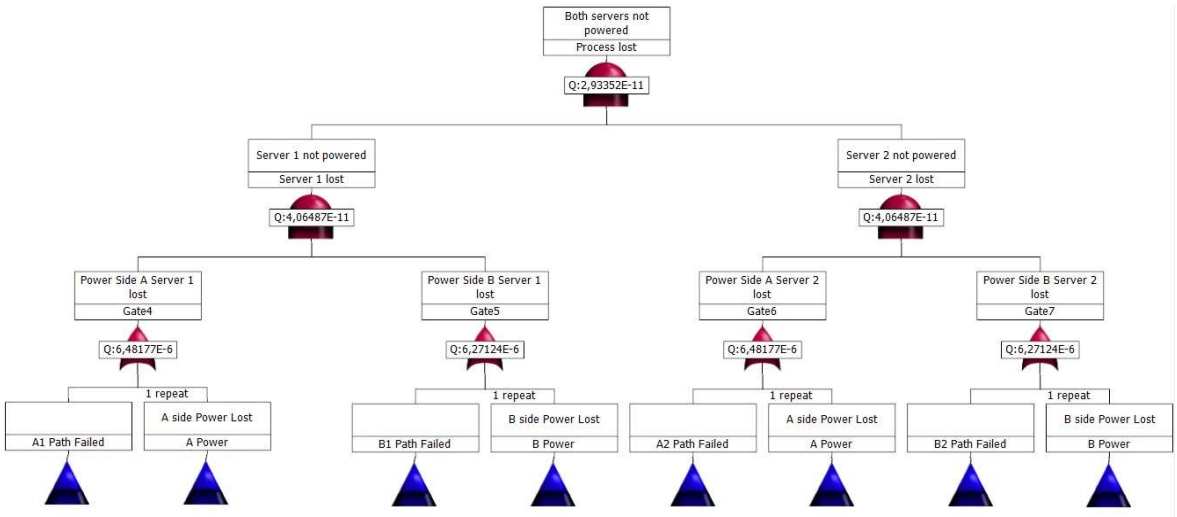
Slika 6.4: DFTA segmenta proizvodnje električne energije za izmjenično zasnovanu električku arhitekturu [9]

Na slici 6.5 prikazan je model raspoloživosti zasnovan na DFTA sa naglaskom na elemente distributivnog polja ali i module besprekidnog sustava napajanja.



Slika 6.5: Segment DFTA za distributivni dio arhitekture [9]

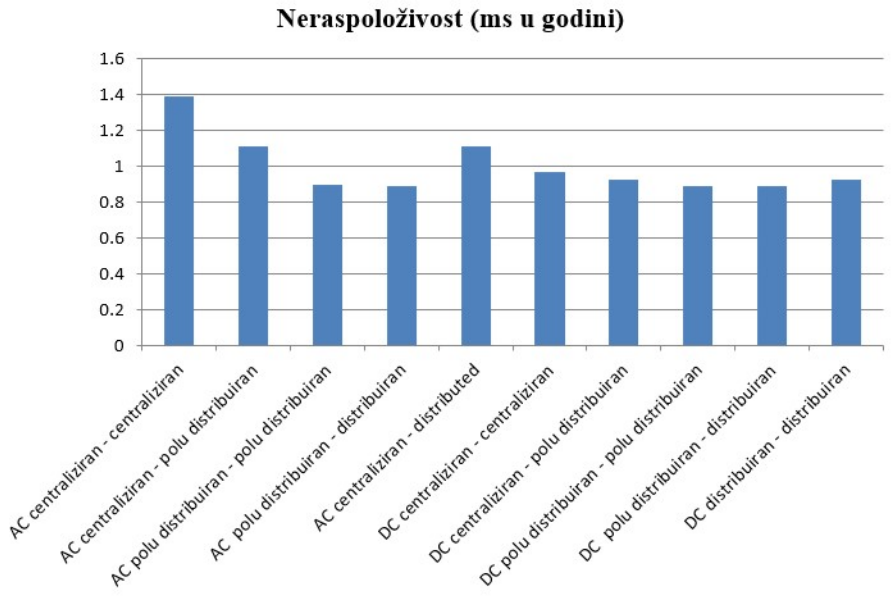
Na slici 6.6 prikazan je konačni model raspoloživosti u kojem se objedinjuju ulazni parametri proizašli iz modeliranja prikazanim na slikama 6.4 i 6.5. Ulazna vrata, odnosno transfer vrata su označena plavim trokutom a obzirom da je preložena arhitektura u radu [9] bila zasnovana na 2N to je ujedno i razlog za konačnu simetriju vrata.



Slika 6.6: DFTA za cijelu arhitekturu [9]

U radu [9] je provedena usporedba električkih arhitektura podatkovnog centra veličine 540 kW u različitim konfiguracijama zasnovanim na istosmjernom razvodu na 400 V_{DC}, -48 V_{DC} i 12 V_{DC} kao i na standardnom razvodu izmjenične električne energije sa centraliziranim, distribuiranim i poludistribuiranim UPS-ovima. Kao najvažniji zaključak rada, iznosi se da je raspoloživost arhitektura neznatno veća u odnosu na arhitekture zasnovane na izmjeničnoj električnoj energiji. U istom radu je također razrađen model migracije procesa i podataka sa poslužitelja kroz *Software Defined Network* paradigmu što praktički udvostručava raspoloživost obzirom da je model zasnovan na migraciji procesa i podataka između dva podatkovna centra Razine 4 raspoloživosti.

Na slici 6.7 prikazani su rezultati istraživanja provedeni u radu [9] na način da svaka od analiziranih arhitektura ima pripadnu godišnju neraspoloživost izraženu u milisekundama godišnje. Indicirana neraspoloživost je inherentnog tipa.

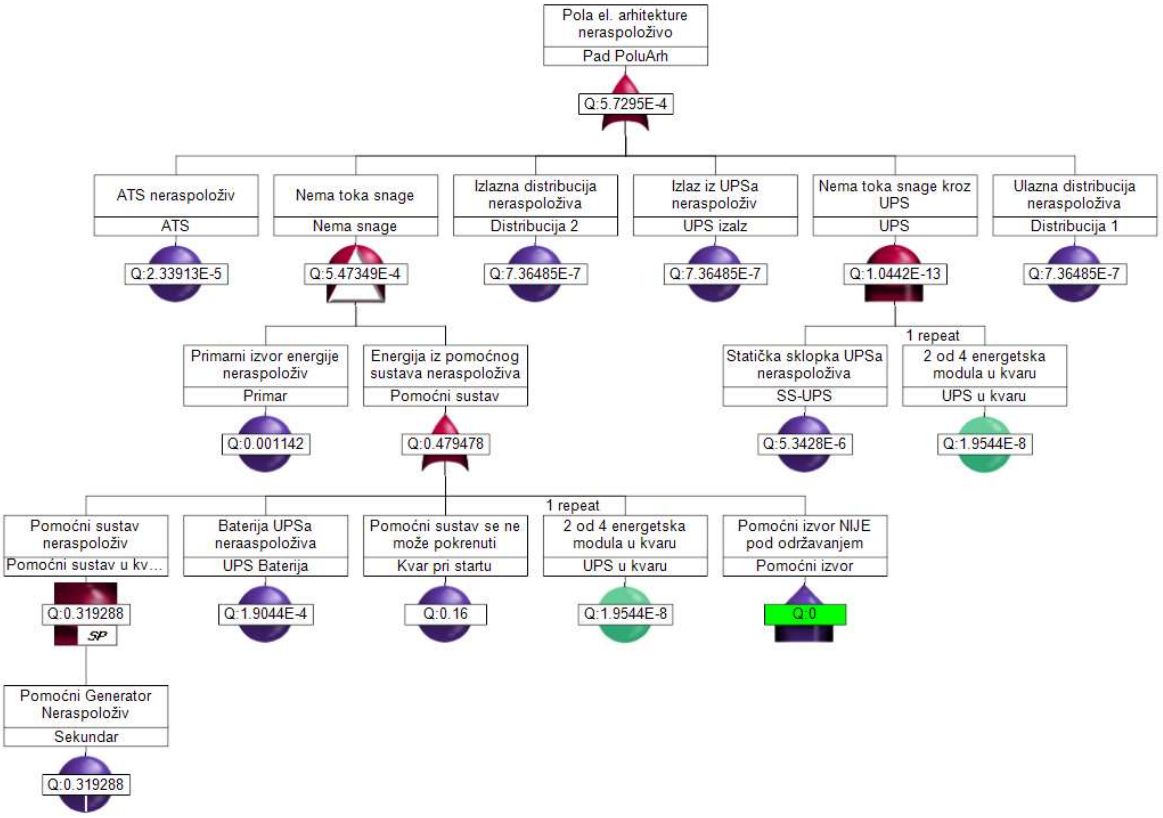


Slika 6.7: Neraspoloživost predloženih AC i DC arhitektura izražena u milisekundama godišnje [9]

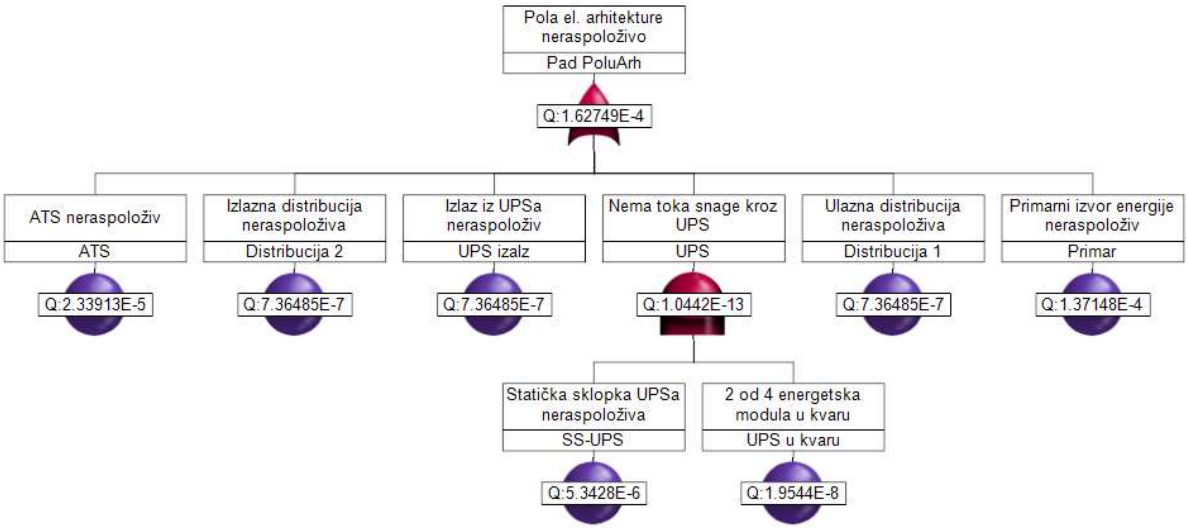
U predmetnoj disertaciji predočen je model raspoloživost cjelokupne električke arhitekture zasnovan na dinamičkom stablu kvara. Predložena su dva osnovna modela od kojih su realizirani derivati konačnih modela za svaku pojedinu arhitekturu koja će biti podvrgnuta evaluaciji.

Model 1 je model napajanja tereta s jedne strane gdje je tok energije omogućen iz glavnog i paralelnog izvora preko automatske transfer sklopke i distributivnog polja u kojem se nalazi UPS. U modelu je posebna pozornost stavljena na činjenicu da baterije UPSa trebaju funkcionirati u trenutku nestanka glavnog napajanja kako bi premostile vrijeme potrebno da se paralelni generator pokrene, sinkronizira na postojeću mrežu i uključi u pogon. Iz tog razloga je baterija smještena u hijerarhijsku razinu s paralelnim generatorom, također i kao vjerojatnost nemogućnosti starta odnosno kvara pri pokretanju paralelnog generatora. Pretpostavlja se da paralelni generator nije pod održavanjem u trenutku kada treba biti pokrenut. Model 1 prikazan je na slici 6.8.

Model 2 je, također, kao i Model 1 model napajanja tereta s jedne strane, prikladan za uporabu s gorivim ćelijama. Obzirom da je to izvor električne energije visoke raspoloživosti za njega će biti korištena posebna arhitektura koja nema paralelni generator, ali i dalje zadržava UPS. Model 2 prikazan je na slici 6.9.

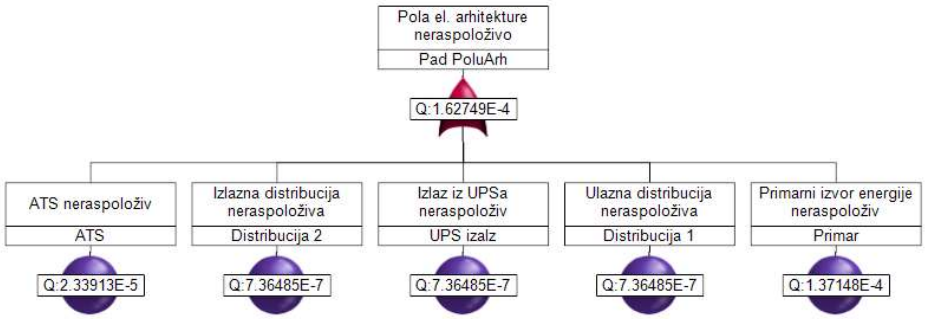


Slika 6.8: DFTA za model 1



Slika 6.9: DFTA za model 2

Model 3, također, kao i prije navedeni modeli je model napajanja s jedne strane prema teretu za evaluaciju na hibridnih rješenja sustava zasnovanih na sunčevim i vjetroelektranama s baterijama i ugrađenom zalihošću. Obzirom da takav sustav već u sebi sadrži znatni spremnik energije i sposoban ga je stvarati u njega je inherentno ugrađena UPS funkcionalnost, te stoga uporaba UPS uređaja u kombinaciji sa takvim sustavom nije potrebna. Model 3 prikazan je na slici 6.10.

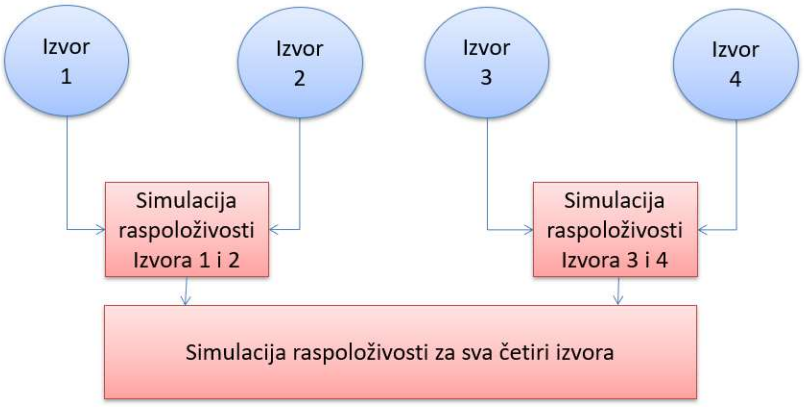


Slika 6.10: DFTA za model 3

U svrhu zasnivanja modela za cjelokupnu električku arhitekturu bitno je spojiti modele u konačni model, ovisno o komponentama arhitekture, kako bi se realizirala cjelovita evaluacija raspoloživosti električke arhitekture, obzirom da je riječ o podatkovnom centru Razine 4 što podrazumijeva dvostruko napajanje tereta.

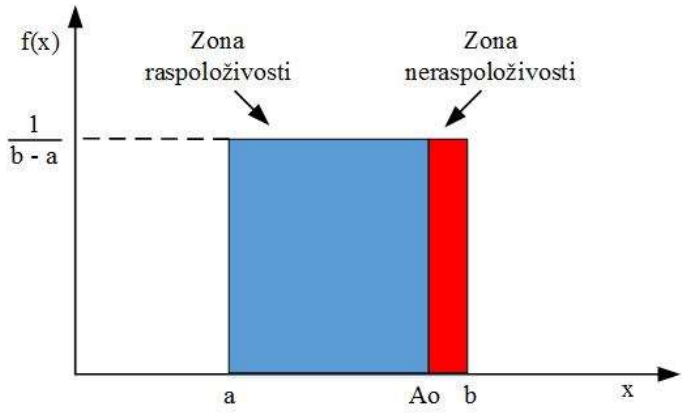
6.3. Zajednička raspoloživost

Prethodno su predočeni modeli raspoloživosti cjelokupne arhitekture, no obzirom da su zasnovani na dinamičkom stablu kvara imaju jedan nedostatak koji se očituje u simulaciji dinamike proizvodnje električne energije iz distribuiranih izvora. U tu svrhu razvijen je model zasnovan na Monte Carlo metodi koja je primijenjena samo na distribuirane izvore uz pretpostavku da je ostatak infrastrukture *crna kutija* u smislu raspoloživosti, sukladno prikazu na slici 6.11.



Slika 6.11: Model distribuiranih izvora za Monte Carlo simulaciju dinamičkih performansi

Obzirom na nedostatak informacija o statističkim razdiobama kvarova, pretpostavlja se da je najbolje za uzeti u razmatranje razdiobu s najvećom entropijom, a to je uniformna razdioba koja je dodatno podijeljena na dvije zone: zone raspoloživosti i neraspoloživosti. Grafička ilustracija dvaju zona, raspoloživosti i neraspoloživosti, prikazana je na slici 6.12.



Slika 6.12: Korištena uniformna razdioba za Monte Carlo simulaciju

Poradi što bolje evaluacije različitih distribuiranih energije u podatkovnom ili telekomunikacijskom postrojenju razvijene su 41 električka arhitektura zasnovana na suvislim permutacijama različitih distribuiranih izvora energije. Simulacija se provodi tako da se generiraju nasumični brojevi za sva četiri izvora prema uniformnoj razdiobi. Za svaki pojedinačni izvor vrijedi:

$$f(x) = \begin{cases} 0, \ za\ a \leq x \leq A_o \leq b \\ 1, \ za\ a \leq A_o \leq x \leq b \\ \emptyset, \ za\ x < a\ ili\ x > b \end{cases} \quad (6.1)$$

U simulacijskom modelu *0* simbolizira uredan pogon i raspoloživost, dok *1* simbolizira neraspoloživost sustava. Paralelno dok se izvodi simulacija pojedinačnog izvora provodi se i zajednička simulacija. Ukoliko je zbroj na izlazu simulacije individualnih izvora za izvor 1 i 2 iz *n*-te iteracije jednak *2*, tada se zaključuje da je u tom događaju došlo do neraspoloživosti oba izvora. Jednako vrijedi i za izvore 3 i 4. Izlaz is simulacije raspoloživosti dvaju izvora se, također, evaluira na način da *0* ukazuje da barem jedan od izvora daje energiju, a to se može točno utvrditi uzimajući u obzir simulaciju prve razine. U konačnici je simulacija za sva četiri izvora za koju vrijede jednaka pravila kao i prethodno; ukoliko je zbroj brojeva jednak *2* tada niti jedan izvor ne daje električnu energiju, odnosno ukupni sustav distribuiranih izvora je neraspoloživ.

Provesti simulaciju upravo na ovakav način je od bitnog značenja obzirom da na taj način se može točno utvrditi koji je izvor raspoloživ ili ne, što je u konačnici važno znati kako bi se moglo razumjeti pomicanje radne točke na krivulji učinkovitosti što se u krajnjem slučaju odražava na troškove pogonskog goriva i na emisiju štetnih tvari, a primarno plina CO_2. Svi distribuirani izvori energije rade na 50% kapaciteta obzirom da su dva u pogonu, a dva u stanju pripravnosti. Izvori 1 i 3 su primarni izvori dok su izvori 2 i 4 redundantni te se koriste kao hladna rezerva. Jedino u slučaju s hibridnim rješenjem predložen je koncept rada koji odstupa od takove zakonitosti a na način da se redoslijed paljenja redundantnih komponenti provodi sekvencijalno odnosno da se u slučaju kvara na primarnom izvoru počne *dizati* drugi, pa treći itd. To je nužno za model s hibridnim izvorom obzirom da isti treba zadovoljiti 100% kapaciteta sukladno zahtjevima Razine 4 raspoloživosti, dok u slučaju ako bi radio u normalnom režimu rada na 50% kapaciteta tada bi bio neiskorišten. Predložene arhitekture s svojstvenim distribuiranim izvorima su izlistane u tablici 6.5.

Tablica 6.5: Predložene arhitekture

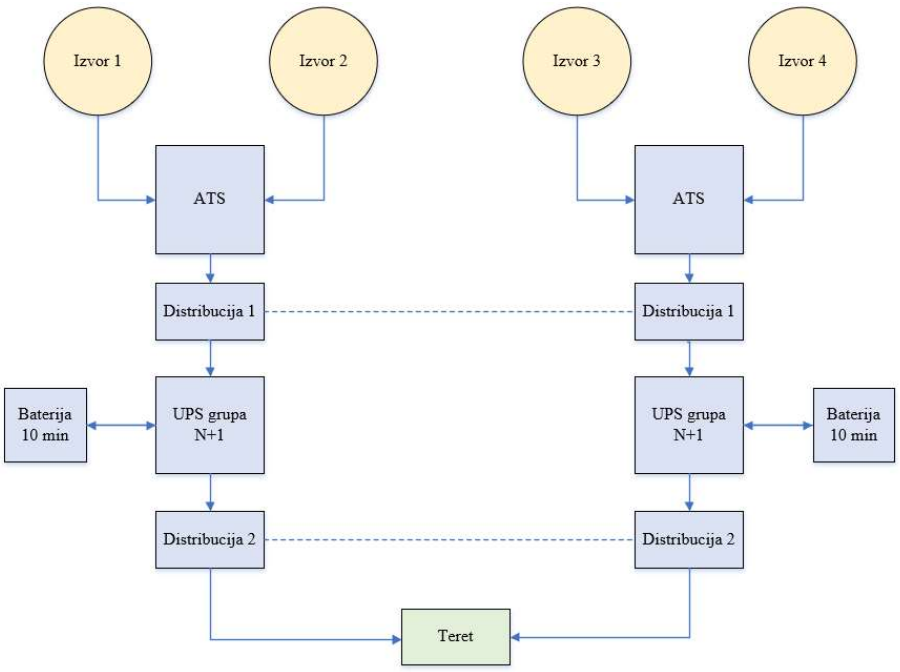
	Izvor 1	**Izvor 2**	**Izvor 3**	**Izvor 4**
Arhitektura 1	Mreža	Dizel	Mreža	Dizel
Arhitektura 2	Plinski generator	Dizel	Plinski generator	Dizel
Arhitektura 3	Plinski generator	Mreža	Plinski generator	Mreža
Arhitektura 4	Mreža	Plinski generator	Mreža	Plinski generator
Arhitektura 5	Hibrid1	0	Mreža	Dizel
Arhitektura 6	Hibrid1	0	Mreža	Plinski generator

Arhitektura 7	Hibrid2	Dizel	Mreža	Dizel
Arhitektura 8	Hibrid2	Plinski generator	Mreža	Plinski generator
Arhitektura 9	Hibrid2	Plinski generator	Mreža	Dizel
Arhitektura 10	Goriva ćelija	0	Mreža	Dizel
Arhitektura 11	Goriva ćelija	Dizel	Mreža	Dizel
Arhitektura 12	Goriva ćelija	Dizel	Mreža	Plinski generator
Arhitektura 13	Goriva ćelija	Dizel	Plinski generator	Dizel
Arhitektura 14	Mreža + sunčeva el.	Dizel	Mreža + sunčeva el.	Dizel
Arhitektura 15	Mreža + sunčeva el.	Dizel	Mreža + vjetro el.	Dizel
Arhitektura 16	Mreža + vjetro el.	Dizel	Mreža + vjetro el.	Dizel
Arhitektura 17	Mreža + sunčeva el.	Plinski generator	Mreža + sunčeva el.	Plinski generator
Arhitektura 18	Mreža + sunčeva el.	Plinski generator	Mreža + vjetro el.	Plinski generator
Arhitektura 19	Mreža + vjetro el.	Plinski generator	Mreža + vjetro el.	Plinski generator
Arhitektura 20	Goriva ćelija	0	Mreža + sunčeva el.	Dizel
Arhitektura 21	Goriva ćelija	0	Mreža + vjetro el.	Dizel
Arhitektura 22	Goriva ćelija	Dizel	Mreža + sunčeva el.	Dizel
Arhitektura 23	Goriva ćelija	Dizel	Mreža + vjetro el.	Dizel
Arhitektura 24	Goriva ćelija	Dizel	Mreža + sunčeva el.	Plinski generator
Arhitektura 25	Goriva ćelija	Dizel	Mreža + vjetro el.	Plinski generator
Arhitektura 26	Mreža	Dizel	Mreža	Dizel
Arhitektura 27	Plinski generator	Dizel	Plinski generator	Dizel
Arhitektura 28	Plinski generator	Mreža	Plinski generator	Mreža
Arhitektura 29	Mreža	Plinski generator	Mreža	Plinski generator
Arhitektura 30	Goriva ćelija	0	Mreža	Dizel
Arhitektura 31	Goriva ćelija	Dizel	Mreža	Dizel
Arhitektura 32	Goriva ćelija	Dizel	Mreža	Plinski generator
Arhitektura 33	Goriva ćelija	Dizel	Plinski generator	Dizel
Arhitektura 34	Mreža	Dizel	Mreža	Dizel
Arhitektura 35	Plinski generator	Dizel	Plinski generator	Dizel
Arhitektura 36	Plinski generator	Mreža	Plinski generator	Mreža
Arhitektura 37	Mreža	Plinski generator	Mreža	Plinski generator
Arhitektura 38	Goriva ćelija	0	Mreža	Dizel
Arhitektura 39	Goriva ćelija	Dizel	Mreža	Dizel
Arhitektura 40	Goriva ćelija	Dizel	Mreža	Plinski generator
Arhitektura 41	Goriva ćelija	Dizel	Plinski generator	Dizel

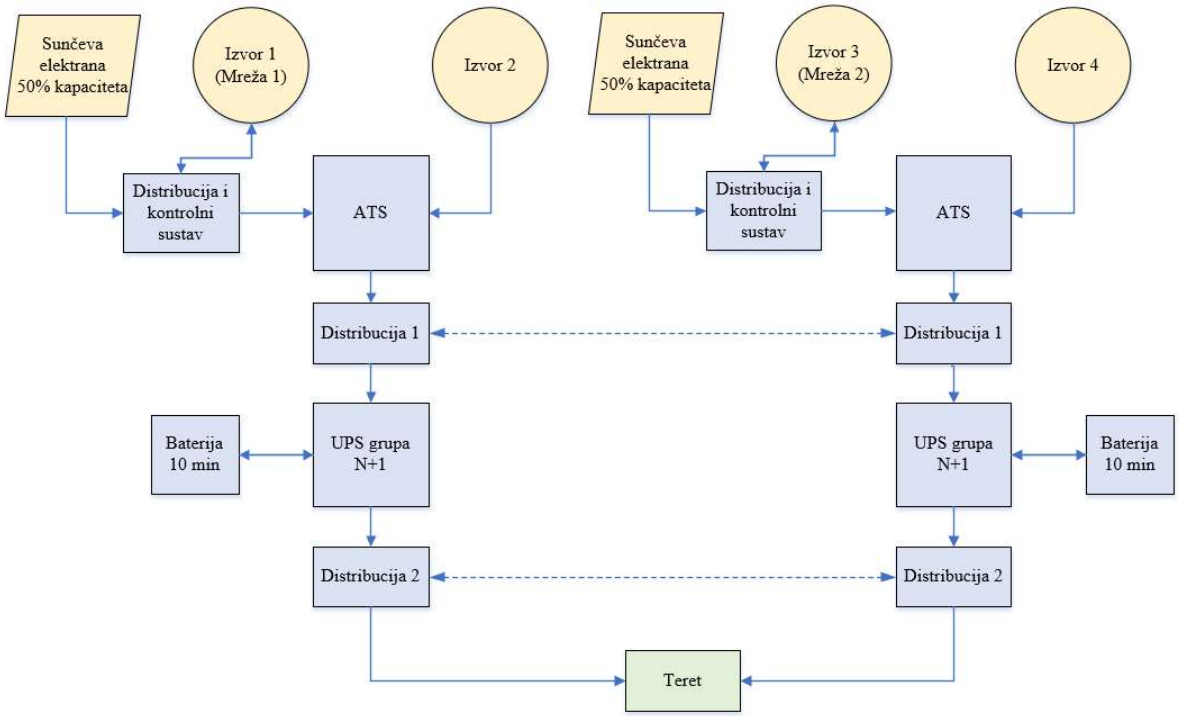
Arhitekture se može razvrstati u četiri skupine:

1. Arhitekture 1-13 su klasične arhitekture izvedene sukladno pravilima Razine 4, prikazano na slici 6.13.

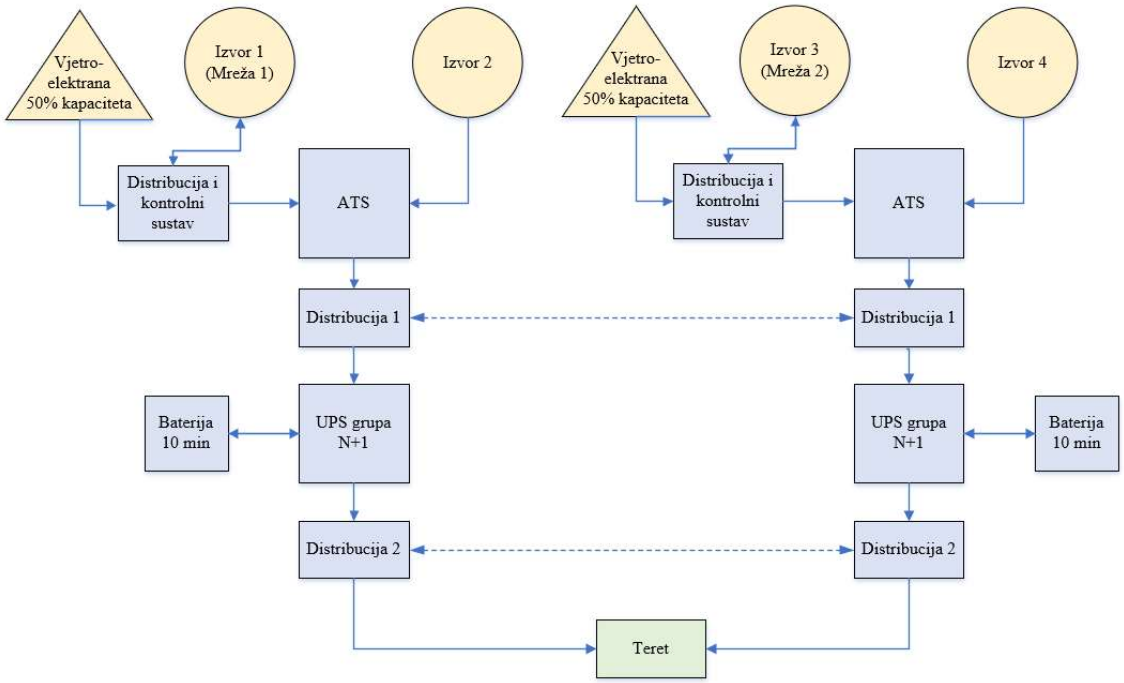
2. Arhitekture 14-25 koriste spoj na javnu mrežu u kombinaciji s obnovljivim izvorima energije koji su optimizirani na način da proizvode dovoljno električne energije prema godišnjoj potrošnji podatkovnog centra, te se na taj način javna mreža koristi kao spremnik energije budući da se pretpostavlja da će ekscesivna energija biti predana u mrežu a potrebna energija tijekom smanjene proizvodnje će se preuzeti iz javne mreže. Cijeli postupak primopredaje električne energije je zamišljen da bude bez ikakvih specifičnih troškova, a količina potrebne energije treba biti jednaka ili manja od iste koja je predata u mrežu. Model je prikazan na slici 6.14 za sustav sa sunčevim elektranama i na slici 6.15 za sustav sa vjetroelektranama.
3. Arhitekture 26-33 su zasnovane na istome principu kao i 1-13 uz postojanje još jednog izvora električne energije zasnovanog na sunčevoj elektrani koja ima instalirani kapacitet od 1 MW te na taj način sva proizvedena energija je konzumirana na lokaciji uz uporabu distribuiranih izvora primara 1 i 3 koji rade sa kapacitetom manjim od 50% u normalnom načinu rada. Model je prikazan na slici 6.16.
4. Arhitekture 34-41 su zasnovane na istom principu kao i Arhitekture 26-33 uz izmjenu budući da se upotrebljavaju vjetroelektrane umjesto sunčeve elektrane. Model je prikazan na slici 6.17.



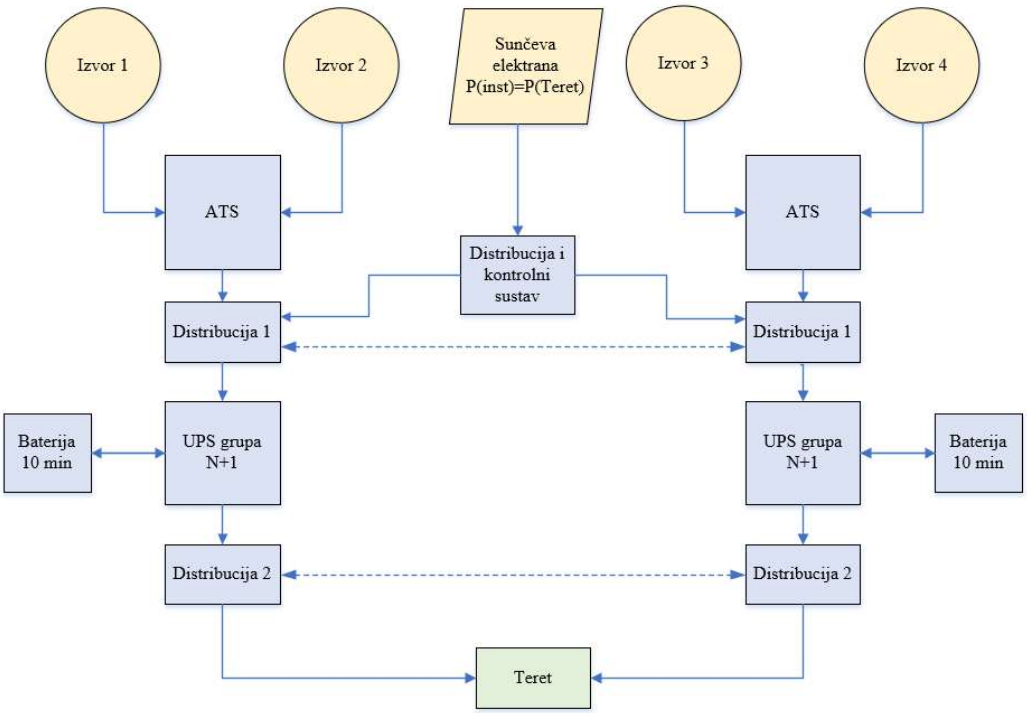
Slika 6.13: Model za arhitekture 1-13



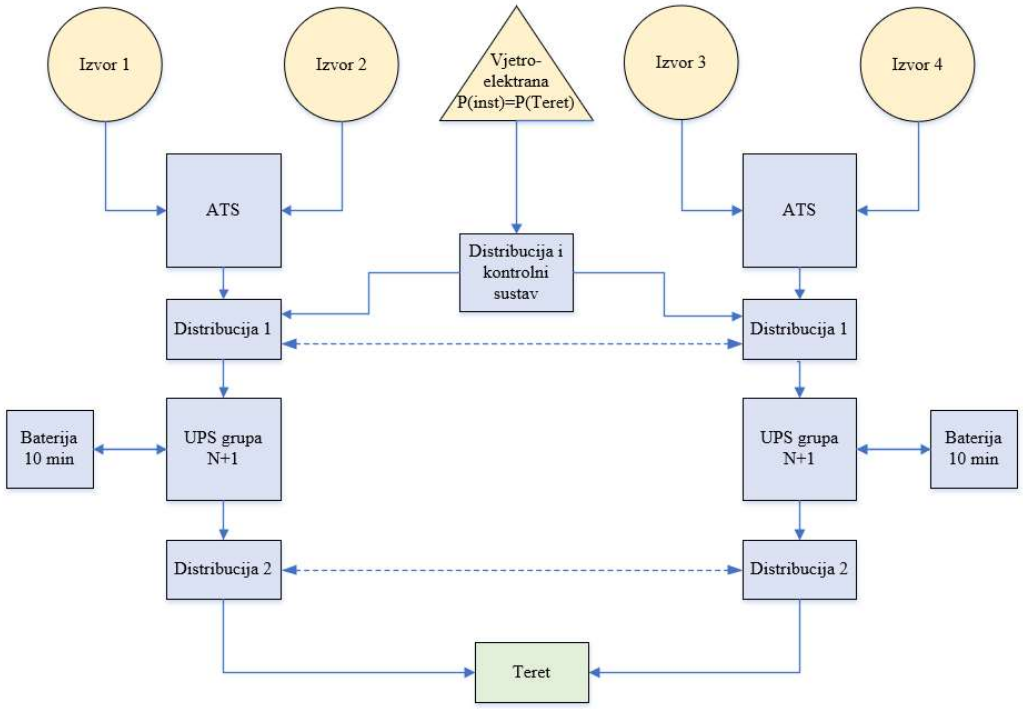
Slika 6.14: Model arhitekture 14-25 sa sunčevim elektranama



Slika 6.15: Model arhitekture 14-25 sa vjetroelektranama



Slika 6.16: Model arhitekture 26-33



Slika 6.17: Model arhitekture 34-41

6.4. Uspostava konačnog modela i postupak evaluacije

Obzirom da se konačni model sastoji od manjih podmodela predložen je postupak kojim se ostvaruje konačni model.

Postupak se provodi sukladno sljedećem hodogramu:

1. Odabir distribuiranih izvora energije sa svim ulaznim parametrima
2. Strukturiranje arhitektura podatkovnog postrojenja
3. Izračun kapitalnih ulaganja za pojedinu arhitekturu
4. Predviđanje proizvodnje električne energije iz sunčevih i vjetroelektrana pomoću UNM
5. Procjena proizvodnje električne energije iz sunčevih i vjetroelektrana
6. Optimizacija hibridnog rješenja pomoću dimenzioniranja spremnika energije, Sunčeve elektrane i vjetroelektrane
7. Monte Carlo simulacija za svaku pojedinu arhitekturu
8. Izračun troškova goriva i emisije CO_2
9. Procjena sigurnosti opskrbe energentima metodom neizrazite logike
10. Odabir najboljeg rješenja TOPSIS metodom

7. PRIMJERI ISTRAŽIVANJA

Predmetna disertacija obuhvaća istraživanje i modeliranje provedeno za teritorij Republike Hrvatske u svrhu iznalaženja optimalnog rješenja u pogledu ukupnog troška vlasništva (*eng. Total Cost of Ownership - TCO*) uz poštivanje kriterija raspoloživosti za električnu arhitekturu Razine 4. Istraženi su potencijali za izgradnju sunčevih i vjetroelektrana, kretanje cijena plina, električne energije i dizel goriva. Posebna pozornost se posvećuje mogućnosti zasnivanja hibridnog rješenja i njegovoj uporabi u okruženju *Razine 4* električne arhitekture. Predloženi model podrazumijeva konstantno napajanje tereta u iznosu od 1 MW.

Validacija modela je provedena na postojećem podatkovnom postrojenju u vlasništvu Emerson Electric korporacije na lokaciji St. Louis, Missouri u SAD-u, snage 100 kW.

7.1. Ograničenja modela

1. Distribuirani izvori energije na pragu omogućuju minimalno 1 MW snage, a učinkovitost daljnjeg električkog razvoda unutar infrastrukture nije uzeta u obzir, te, na taj način je cijela infrastruktura proglašena teretom od 1 MW. Model je zasnovan na način da je agnostičan u pogledu vrste električne arhitekture u nižoj hijerarhiji te je nevažno je li je arhitektura zasnovana na istosmjernom ili izmjeničnom električnom razvodu.
2. Mehanički tereti kao sastavni dio podatkovne i telekomunikacijske infrastrukture nisu uzeti u obzir. Glavnina mehaničkih tereta su uređaji za hlađenje a na njihovu dinamiku kao i dimenzioniranje utječu faktori kao što je gustoća snage u podatkovnim salama, kao i mikrolokacija. Zbog navedenih razloga, isti dio infrastrukture nije uključen u razmatranje.
3. Podaci korišteni za evaluaciju sunčevih i vjetroelektrana su prosječni podaci za cijelu R.H. te se moraju uzeti kao smjernica za razumijevanje potencijala R.H. U stvarnosti je nužno imati podatke vezane za mikrolokaciju na kojoj se razmatra moguća gradnja, obzirom da vrijednosti na godišnjoj razini mogu znatno varirati i navesti konačnu odluku u krivom smjeru.

4. Cijene instaliranog kW sunčeve i vjetroelektrane su zasnovane na težinskim srednjim tržišnim cijenama prema izvješću IRENA za godinu 2017., a objavljeno 2018. Faktor pretvorbe EUR/USD je 1,11383, prema javno dostupnom servisu za pretvorbu valuta, OANDA, na dan 26.8.2019.
5. Pretpostavlja se da cijene instaliranog kW sunčeve i vjetroelektrane uključuju potrebne sustave za kontrolu i nadzor, poput MPPT modula ili uređaja za sinkronizaciju

7.2. Modeli cijena i troškova

7.2.1. Kruta mreža

Podaci o kretanju cijena električne energije iz krute mreže u Republici Hrvatskoj za industrijske korisnike su pribavljena sa EUROSTAT javne Internet stranice. Dostupni podaci su bili za prvu polovicu 2015. godine, za cijelu 2016. i 2017. godinu i drugu polovicu 2018. godine. Podaci za drugu polovicu 2015. i prvu polovicu 2018. godine su izračunate kao srednje vrijednosti susjednih polovica godina.

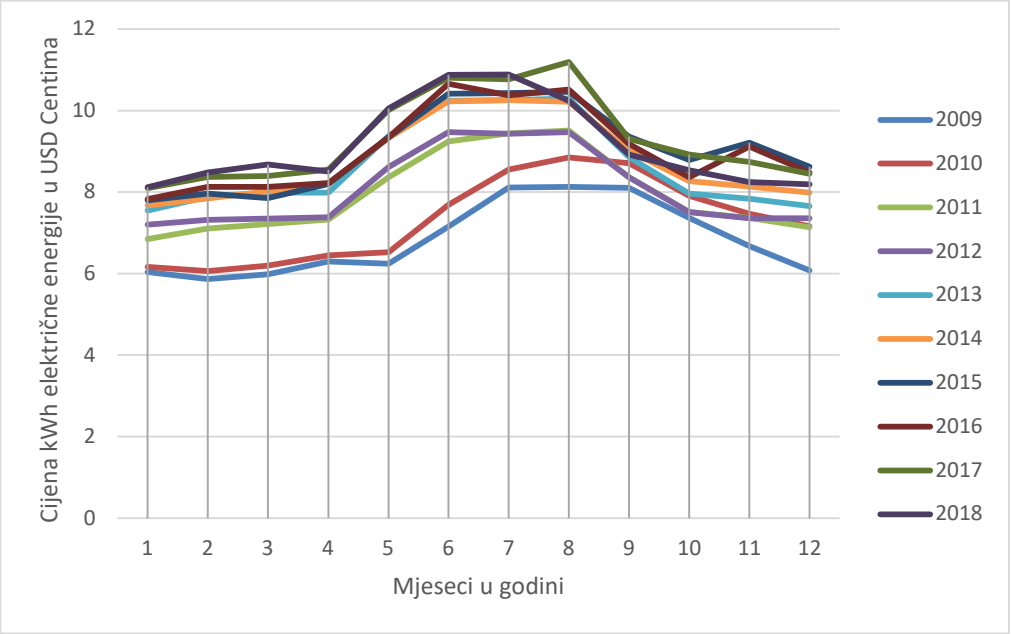
Kapitalni troškovi krute mreže se odnose na izgradnju transformatorske stanice koja omogućuje spajanje srednje naponske distributivne mreže sa niskonaponskim razvodom postrojenja, i pretpostavlja se iznos od 35 000 EUR za cijelu stanicu, a model pretpostavlja da je mjerno mjesto na niskonaponskoj strani te stoga gubici transformatora nisu uzeti u razmatranje. Troškovi održavanja su estimirani na iznos od 2 000 EUR godišnje za prvu godinu, dok su troškovi za svaku sljedeću godinu uvećani za inflatornu stopu od 1% godišnje. U tablici 7.1 su izražene cijene električne energije u EU-28, europskom kontinentu i Republici Hrvatskoj od 2015. do 2018. g. po polugodištima. Polugodišta 2015 S2 i 2018 S1 su izračunata kao srednje vrijednosti okolna dva polugodišta.

Tablica 7.1: Cijene električne energije izražene u EUR / kWh za industrijske korisnike [103]

	2015 S1	2015 S2	2016 S1	2016 S2	2017 S1	2017 S2	2018 S1	2018 S2
EU-28	0,1210	0,1185	0,1160	0,1129	0,1140	0,1118	0,1134	0,1149
Euro regija	0,1100	0,1110	0,1120	0,1158	0,1130	0,1087	0,1115	0,1142
Hrvatska	0,1610	0,1570	0,1530	0,1556	0,1480	0,1449	0,1442	0,1434

Emisija CO_2 u Republici Hrvatskoj za proizvedeni kWh uključujući sve gubitke u prijenosu iznosi 524 g/kWh [104].

Prosječne vrijednosti emisije štetnih čestica za američku državu Missouri alocirane na proizvodnju električne energije su 832 g/kWh CO_2, 2,44 g/kWh SO_2 i 0,61 NO_x u godini 2010., odnosno u godini od interesa za provedbu validacije modela [105]. Na slici 7.1 prikazan je graf sa povijesnim cijenama električne energije u američkoj saveznoj državi Missouri u periodu od 2009. – 2018. godine. Krivulje svih deset godina imaju Gaussijanski oblik sa najvišim iznosima u ljetnim mjesecima.



Slika 7.1: Cijene kWh električne energije u Missouri-u tijekom godina

7.2.2. Dizel agregati i distribuirani izvori električne energije zasnovani na plinskim tehnologijama

Kapitalni trošak dizel agregata sa 1 MW električne snage na izlazu su estimirani na 718 242,46 EUR, obzirom da je cijena po instaliranom kW 800 USD [11], uz faktor pretvorbe EUR/USD = 1,11383. Troškovi održavanja istog dizel agregata su 35 USD po instaliranom kW godišnje [11]. Kapitalni trošak plinskog agregata sa 1 MW električne snage na izlazu je 897 803,08 EUR obzirom da su troškovi po instaliranom kW iznose 1 000 USD [11], dok su troškovi

održavanja plinskih agregata isti onima kao i u slučaju dizel agregata, odnosno 35 USD po instaliranom kW godišnje [11].

Kapitalni troškovi gorive ćelije, SOFC tipa kompanije Bloom iznose 4 000 USD / kW [38], što uključujući ugradnju i potrošni materijal u konačnici rezultira kapitalnim troškom od 5 386 818,46 EUR za postrojenje snage 1 MW. Održavanje gorive ćelije iznosi 0,0133 USD po radnom satu [39].

Korištena cijena prirodnog plina za industrijsku uporabu u R.H. je 0,0283 EUR/kWh, sukladno izvješću EUROSTAT iz Svibnja 2019. godine za drugu polovicu 2018. godine [106].

U validacijskom modelu korišten je model plinske mikroturbine a obzirom da je teret postrojenja 100 kW, ponuđena je konfiguracija od dvije plinske mikroturbine sa instaliranom snagom 65 kW svaka, sukladno tablici 2.4. U svrhu modeliranja upotrjebljene su povijesne cijene plina, sukladno tablici 7.2, za evaluaciju plinskih tehnologija distribuirane proizvodnje električne energije.

Tablica 7.2: Kretanje cijena plina u Missouri-u izražena u USD za m^3 [107]

Godina	Sij.	Velj.	Ožu.	Tra.	Svi.	Lip.	Srp.	Kol.	Ruj.	Lis.	Stu.	Pro.
2009	0,38	0,36	0,36	0,35	0,30	0,26	0,30	0,30	0,30	0,30	0,34	0,32
2010	0,31	0,31	0,31	0,31	0,30	0,30	0,29	0,30	0,31	0,30	0,31	0,31
2011	0,30	0,30	0,31	0,30	0,30	0,30	0,30	0,30	0,30	0,30	0,31	0,29
2012	0,29	0,28	0,29	0,28	0,27	0,26	0,28	0,27	0,26	0,27	0,28	0,27
2013	0,29	0,28	0,28	0,30	0,29	0,29	0,28	0,29	0,30	0,28	0,29	0,30
2014	0,27	0,26	0,28	0,30	0,30	0,30	0,30	0,29	0,28	0,28	0,29	0,30
2015	0,28	0,27	0,28	0,28	0,26	0,27	0,28	0,26	0,28	0,25	0,25	0,24
2016	0,21	0,22	0,22	0,21	0,20	0,21	0,25	0,22	0,22	0,21	0,24	0,25
2017	0,24	0,25	0,25	0,23	0,21	0,21	0,22	0,22	0,21	0,23	0,25	0,24
2018	0,24	0,24	0,24	0,25	0,21	0,20	0,21	0,20	0,21	0,21	0,22	0,24

Obzirom na svojstvo dizel agregata da u svom sustavu također ima i spremnik goriva dostatan za 72 h, godišnji trošak goriva koje se treba ili potrošiti ili zamijeniti, je procijenjen na 38 880 EUR, a cijena litre goriva je procijenjena na iznos od 1,5 EUR, u Republici Hrvatskoj za prvu godinu, a za svaku sljedeću dodana je inflatorna stopa od 1%.

U validacijskom modelu, korištena je prosječna cijena dizelskog goriva u iznosu od 2,37 USD za galon [108], odnosno 0,6261 USD za litru dizelskog goriva. Trošak punog spremnika za 72 h je estimiran na iznos od 1 351,28 USD.

7.2.3. Vjetroelektrane, sunčeve elektrane i VRLA baterije

Cijene instaliranog kW vjetroelektrane ovise o veličini vjetroagregata. U svrhu procjene cijena vjetroagregata od 500 kW do 4 000 kW pretpostavljena je razdioba kako je prikazano na slici 7.2, obzirom da je cijena instaliranog kW opada sa porastom snage instaliranog vjetroagregata, a podaci korišteni su opisani u poglavlju 2.3 predmetne disertacije. Korištena cijena instaliranog kW solarne elektrane u fotonaponskoj izvedbi je težinski normirana cijena u iznosu 1 228 EUR/kW, sukladno podacima iznesenim u poglavlju 2.4 predmetne disertacije. U tablici 7.3 navedeni su faktori konverzije iz EUR u USD od 2011. do 2018. godine. Sukladno pretvorbenim faktorima, u tablici 7.4 prikazane su cijene instaliranog kW vjetroelektrane u EUR i USD od 2011. do 2018. godine izuzimajući 2012. i 2013. godinu.

Tablica 7.3: Faktori pretvorbe iz EUR u USD [109]

	2018	**2017**	**2016**	**2015**	**2014**	**2013**	**2012**	**2011**
EUR/USD	1,18	1,13	1,11	1,11	1,33	1,33	1,28	1,39

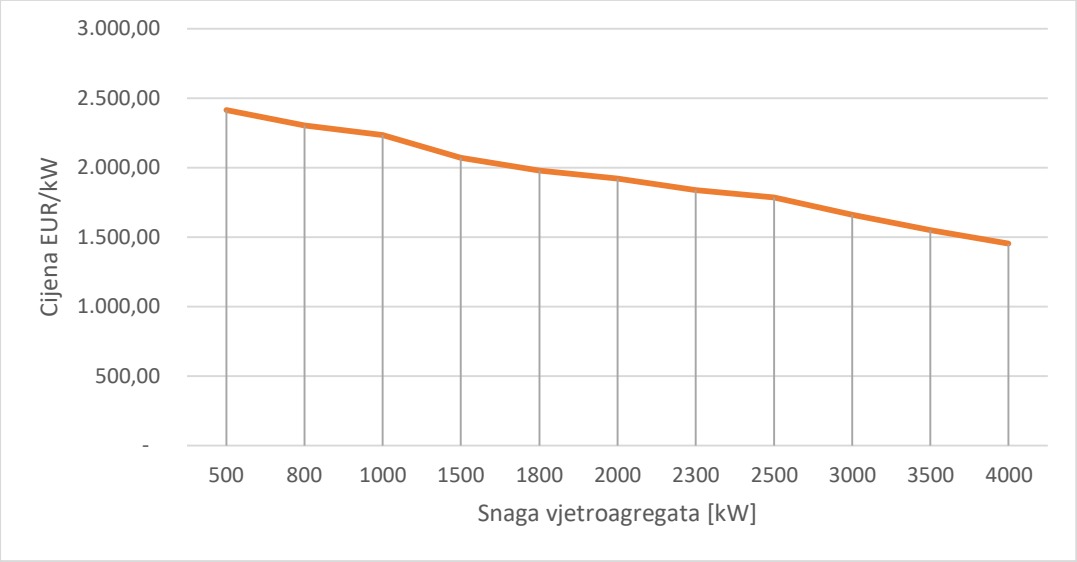
Tablica 7.4: Cijena instaliranog kW vjetroagregata pretvoreno iz USD u EUR

	2018	**2017**	**2016**	**2015**	**2014**	**2013**	**2012**	**2011**
USD	1477	1490	1500	1730	1750	X	X	1843
EUR	1251,70	1318,58	1351,35	1558,56	1315,79	X	X	1325,90

U svrhu zasnivanja validacijskom modela u Missouri-u za Emerson podatkovni centar, pretpostavlja se daje nabavna cijena instaliranog kW sunčeve elektrane 3 000 USD u godini 2010.

Korištena cijena za visokociklirajuće VRLA baterije proizvođača Enersys su 1 275,31 EUR za jednu ćeliju od 2 V i 3 900 Ah. Informacija o cijeni je dobivena od proizvođača, odnosno kompanije Enersys u vidu budžetske cijene. Nužno je za naglasiti kako su cijene VRLA baterija podložne promjenama budući da trošak olova ima znatan udio u ukupnom trošku proizvodnje, a on je podložan mešetarenju na Londonskoj burzi metala.

Na slici 7.2 estimirana je krivulja cijene instaliranog kW vjetroelektrane u ovisnosti o snazi vjetroagregata.



Slika 7.2: Estimirana karakteristika troškova instalirane snage vjetroelektrane u ovisnosti o veličini vjetroelektrane

7.3. Simulacija proizvodnje električne energije iz sunčevih i vjetroelektrana

7.3.1. Predviđanje vremenskih nizova

Podaci prikupljeni u svrhu analize i predviđanja su javno dostupni u sklopu EMHIRES projekta i SETIS (*eng. Strategic Energy Technologies Information System*) inicijative Europske Komisije, čija je svrha omogućiti članicama EU-28 razmatranje utjecaja na klimatske promjene (https://setis.ec.europa.eu/EMHIRES-datasets). U predmetnoj disertaciji korišteni su setovi podataka o proizvodnji električne energije iz sunčevih i vjetroelektrana u razlučljivosti od jednog sata tijekom perioda od deset godina (2005. – 2015. godine), iako setovi pokrivaju period od trideset godina. Podaci su prikazani za svaki sat u periodu kao omjer trenutne snage, odnosno isporučene električne energija iz danog izvora, i instalirane snage.

Vremenski nizovi uzimaju u obzir ukupnu instaliranu snagu u zemlji koja je ekstrahirana iz godišnjih podataka ENTSO-E. Instalirana snaga pri NUTS1, NUTS2 i NUTS3 je izračunata

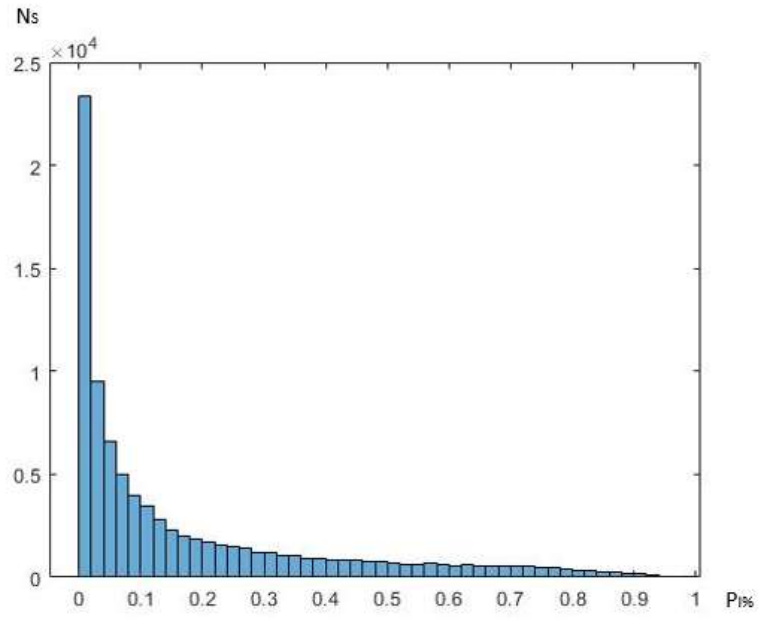
pomoću teoretskog potencijala NUTS2 te nadalje normalizirana i usklađena sa ENTSO-E podacima pojedine zemlje.

Nužno je za napomenuti, da setovi podataka održavaju prosjek za cijelu R.H. te su pogodni za razmatranje kao smjernica u pogledu istraživanja sveukupnog potencijala sunčevih ili vjetroelektrana a u stvarnosti je imperativno izvršiti mjerenja na stvarnoj mikrolokaciji gdje bi se implementacija izvršila obzirom da značajke mikrolokacije mogu imati znatan utjecaj na proizvodnju električne energije iz obnovljivih izvora.

U svrhu predviđanja buduće proizvodnje električne energije iz SE i VE stvorena je neuronska mreža uporabom software-skog paketa Matlab 2018b.

7.3.2. Simulacija vjetroelektrane u R.H.

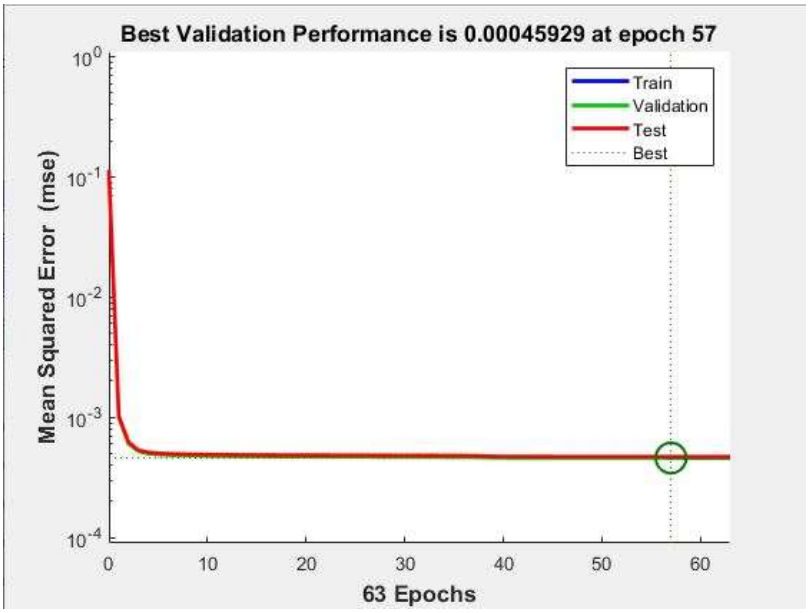
Analizom podataka prosječne snage proizvodnje električne energije iz vjetroelektrana utvrđenja je razdioba normirane snage kako je prikazano na slici 7.3. Evidentno je da prikazana razdioba ne prati Weibullovu razdiobu vjetra, što je uzrokovano činjenicom da prva diskretna varijabla u nizu opisuje stanje nulte proizvodnje koja je u odnosu na ostale varijable najveća.



Slika 7.3: Statistička distribucija generirane električne snage iz vjetra u Republici Hrvatskoj

Model neuronske mreže za simulaciju podataka o generiranoj prosječnoj normiranoj snazi dobivenoj iz VE, u razlučivosti od jednog sata za period od deset godina (87 600 podataka) na teritoriju R.H. je zasnovan na nelinearnom autoregresivnom modelu neuronske mreže (NAR). Obzirom na svojstva NAR tipa UNM, algoritam povratnog širenja temeljen na rekurzivnoj predikcijskoj metodi izlazni parovi su zapravo izravni derivati ulaznih parova. Neuronska mreža koristi deset neurona u skrivenom sloju.

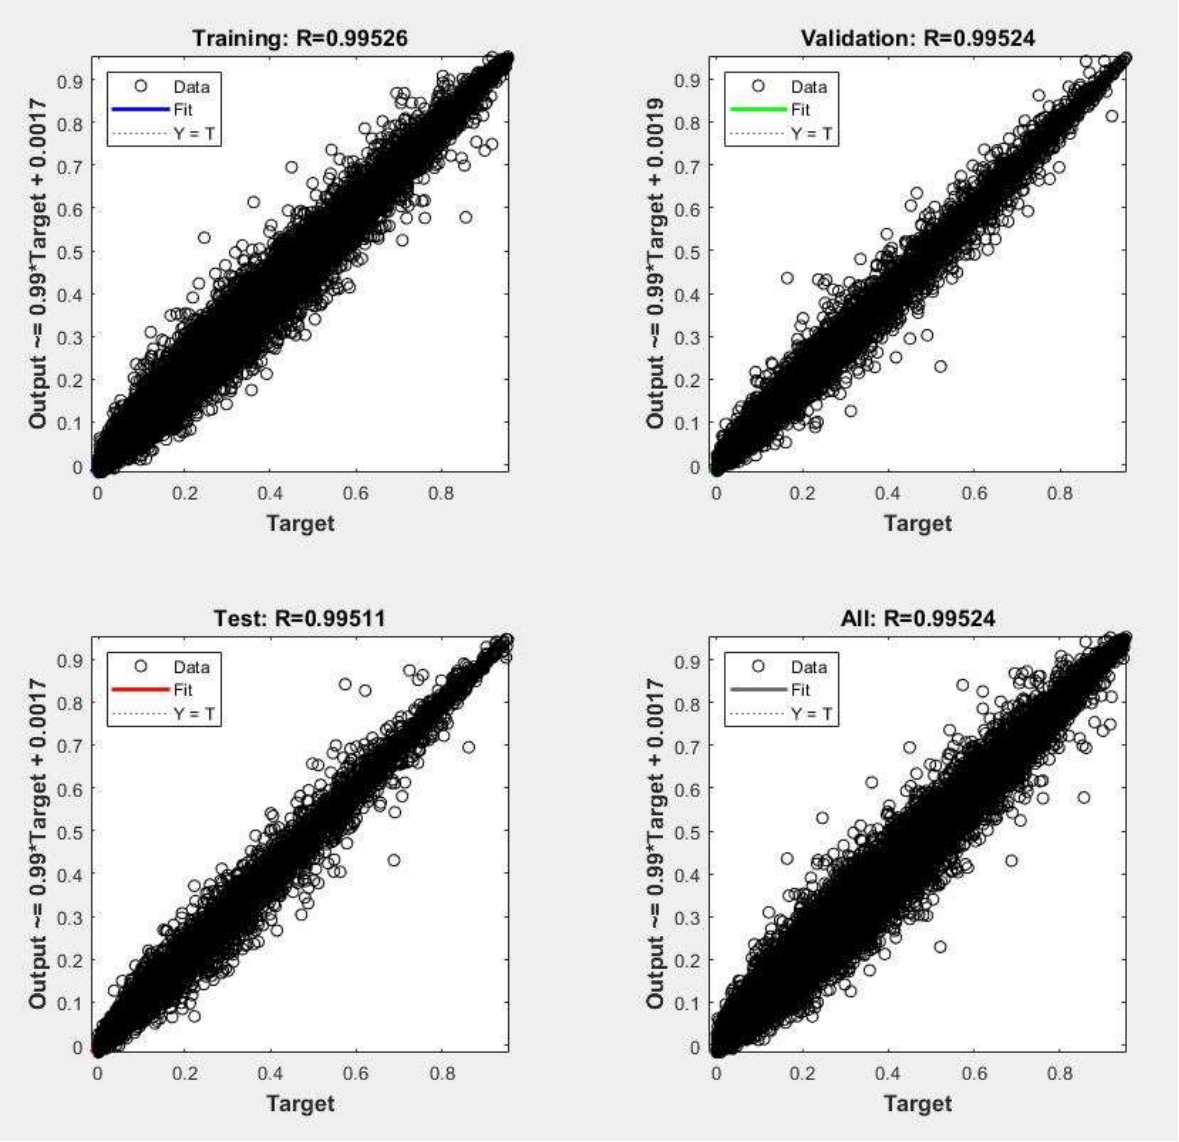
Krivulja konvergencije, prikazana na slici 7.4 ukazuje na uspješnu konvergenciju budući da je postignut rezultat od 0,00045929 u 57 epohi, odnosno iteraciji. Rezultat se može smatrati boljim od traženoga obzirom da bi zadovoljavajući rezultat bio bilo koji rezultat manji od 1%.



Slika 7.4: Validacija performansi neuronske mreže

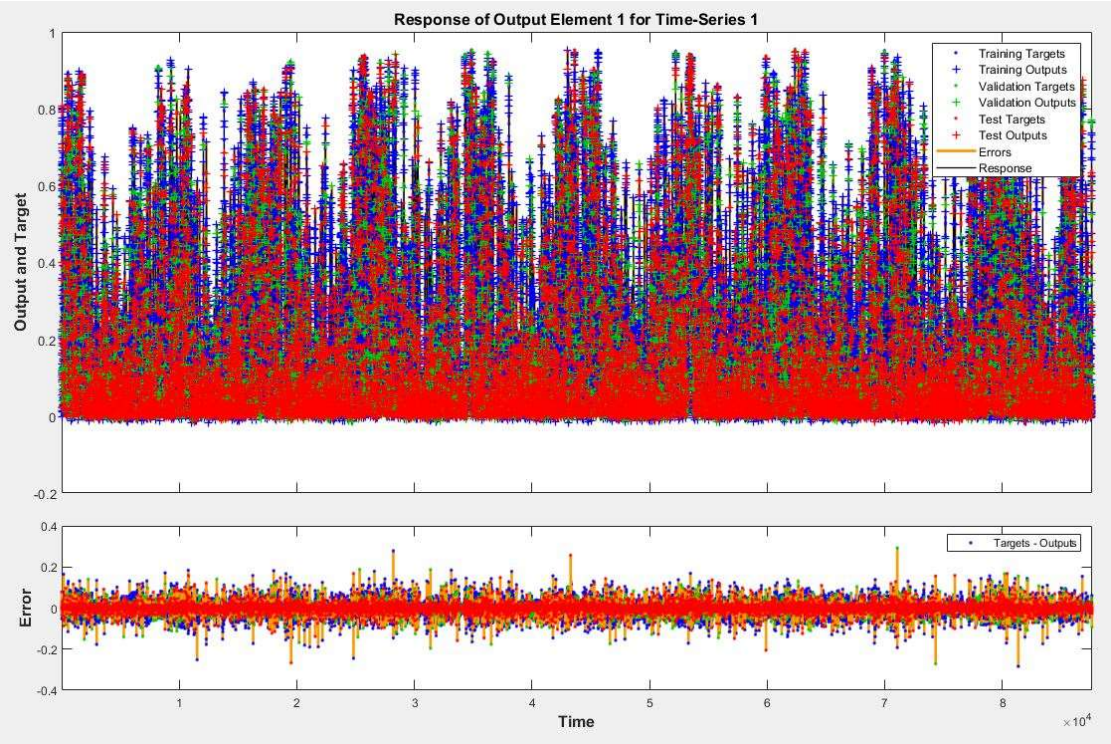
Odstupanje simuliranih nizova proizvodnje električne energije iz VE je prikazano na slici 7.5. Tijekom cjelokupnog procesa 70% vremenske domene (simulacije) je dodijeljeno uvježbavanju neuronske mreže, 15% validaciji i 15% ispitivanju. U svrhu uvježbavanja korišten je je Levenberg-Marquardtov algoritam. Koeficijent korelacije za niz pri uvježbavanju je 0,99526, pri validaciji 0,99524, pri ispitivanju 0,99511, dok združeni koeficijent iznosi 0,99524. Rezultati upućuju na

visok stupanj korelacije ali također ukazuju na manju varijabilnost, što se može smatrati zadovoljavajućim.



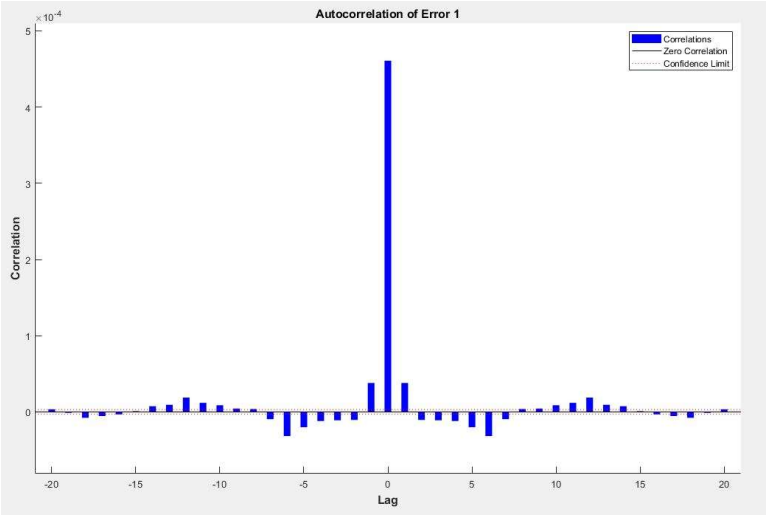
Slika 7.5: Prikaz odstupanja generiranih podataka u odnosu na ulazne

Na slici 7.6 prikazane su sve točke vremenskog niza podvrgnute simulaciji kroz proces uvježbavanja, validacije i ispitivanja u obje varijante – inicijalnog niza i generiranog niza. Razlika među točkama inicijalnog i generiranog niza opisana je pogreškom (lat./eng. *error*).



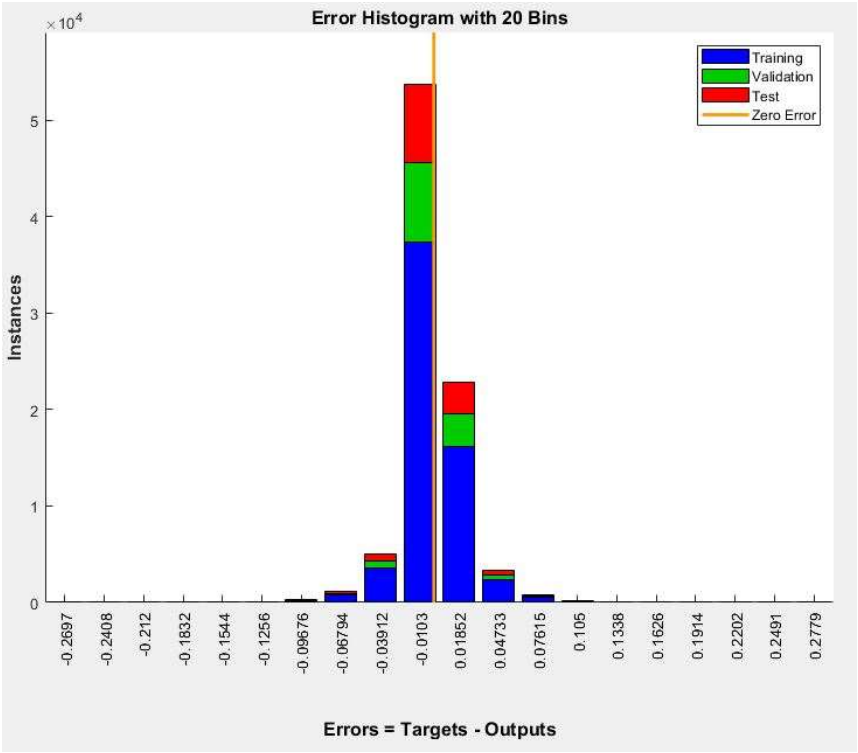
Slika 7.6: Prikaz treniranja neuronske mreže

Ispitivanjem autokorelacije prvog reda grešaka, odnosno serijske korelacije prvog reda grešaka, može se zaključiti da je model postavljen zadovoljavajuće obzirom da korelacija između pojedinim greškama gotovo nasumična što je prikazano na slici 7.7 na način da je glavnina svih korelacija u točki 0. Neznatan broj korelacija je pozitivnog ili negativnog tipa.



Slika 7.7: Prikaz greške autokoorelacije

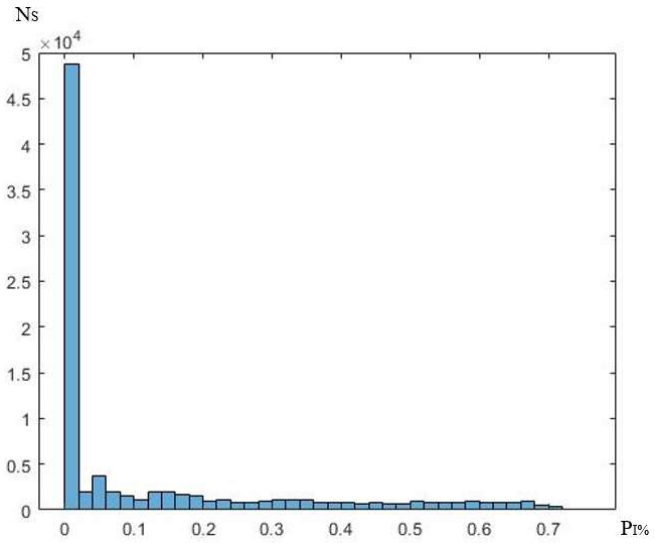
Najviše grešaka, na više od 5x104 simuliranih točaka vremenskog niza ima iznos od -0,0103, kao što je prikazano histogramom grešaka na slici 7.8.



Slika 7.8: Histogram grešaka na izlazu

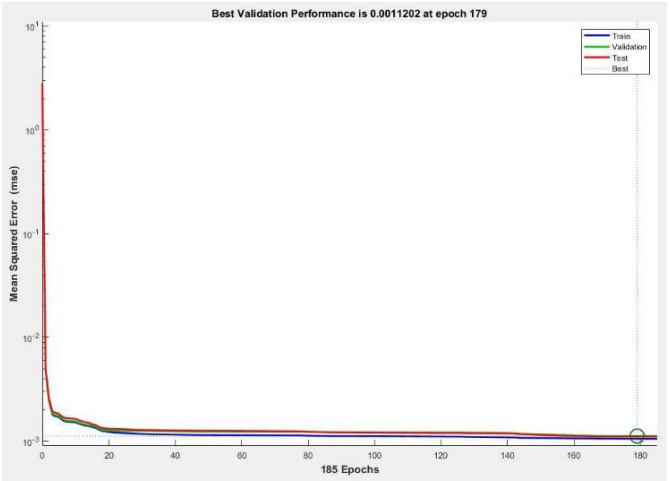
7.3.3. Simulacija sunčeve elektrane u R.H.

Očekivano, najzastupljenija vrijednost proizvodnje električne energije iz sunčevih elektrana je 0, obzirom da sunčeve elektrane mogu funkcionirati jedino za vrijeme dnevnog svijetla. Raspodjela broja sati sa kapacitetom proizvodnje većim od 0 do 70% se može smatrati ravnomjerno raspodijeljenim. Instalirana snaga je najviše iskorištena do 70% kapaciteta, odnosno viši kapaciteti od 70% do 100% nisu zabilježeni, sukladno prikazu na slici 7.9. Razlog ovakvom ishodu se treba potražiti u činjenici da su vrijednosti normirane za cijelu zemlju, te je u takvom kontekstu nemoguće doći do 100% iskorištenog kapaciteta tijekom bilo kojeg promatranog mjernog sata.



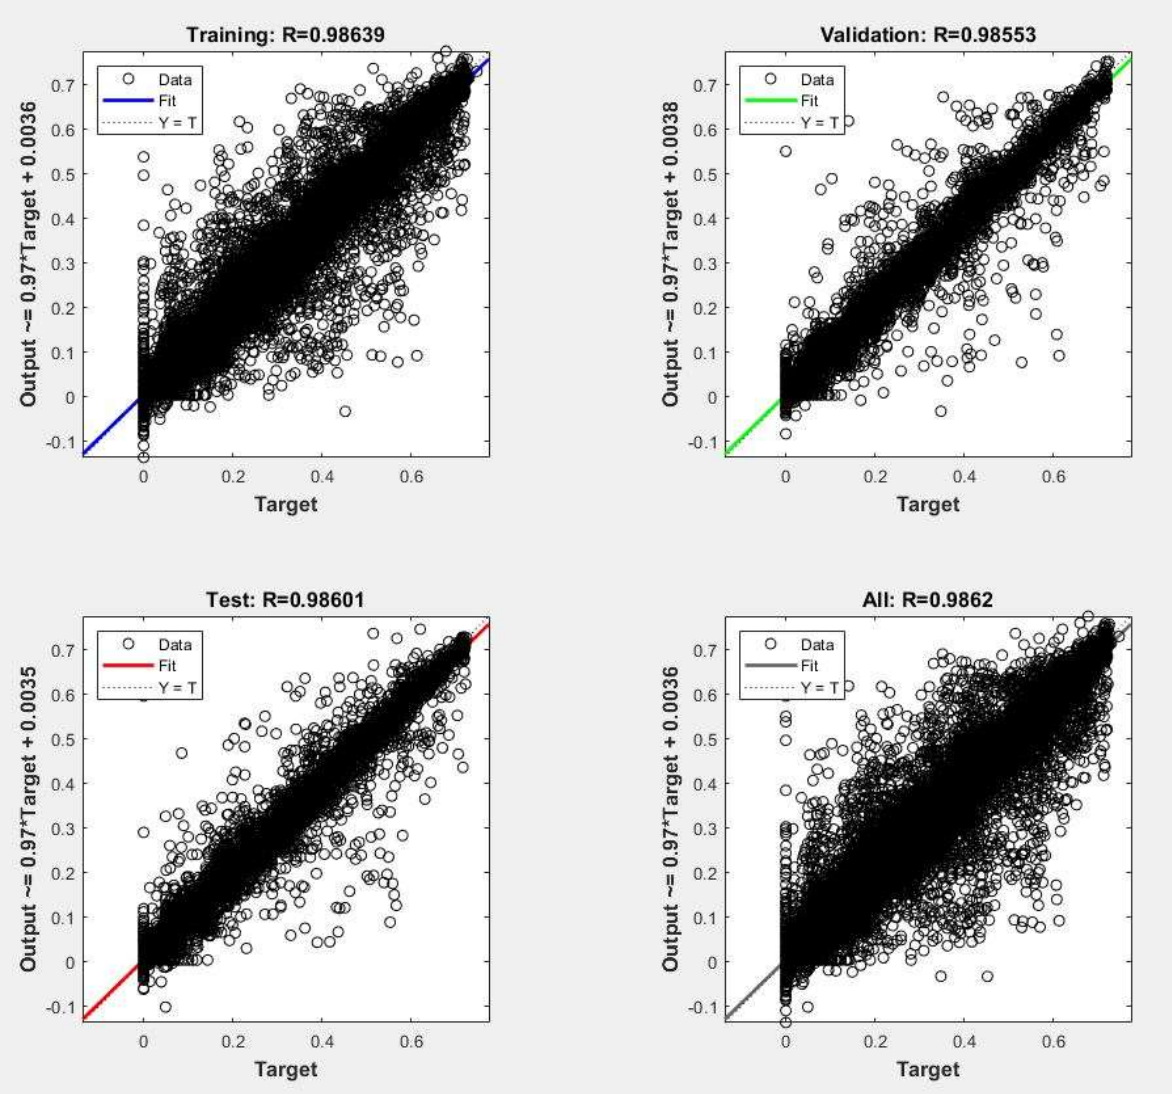
Slika 7.9: Statistička distribucija generirane električne snage iz sunca u Republici Hrvatskoj

Model neuronske mreže za simulaciju podataka o generiranoj prosječnoj normiranoj snazi dobivenoj iz SE, u razlučivosti od jednog sata za period od deset godina na teritoriju R.H. je, također, zasnovan na nelinearnom autoregresivnom modelu neuronske mreže (NAR) na isti način kao što je to bio i slučaj pri simulaciji VE. U ovom modelu, neuronska mreža koristi dvadeset neurona u skrivenom sloju. Krivulja konvergencije, prikazana na slici 7.10 ukazuje na uspješnu konvergenciju budući da je postignut rezultat od 0,0011202 u 179 epoha, odnosno iteracija. Rezultat se može smatrati zadovoljavajućim obzirom da je najbolji rezultat oko 1%.



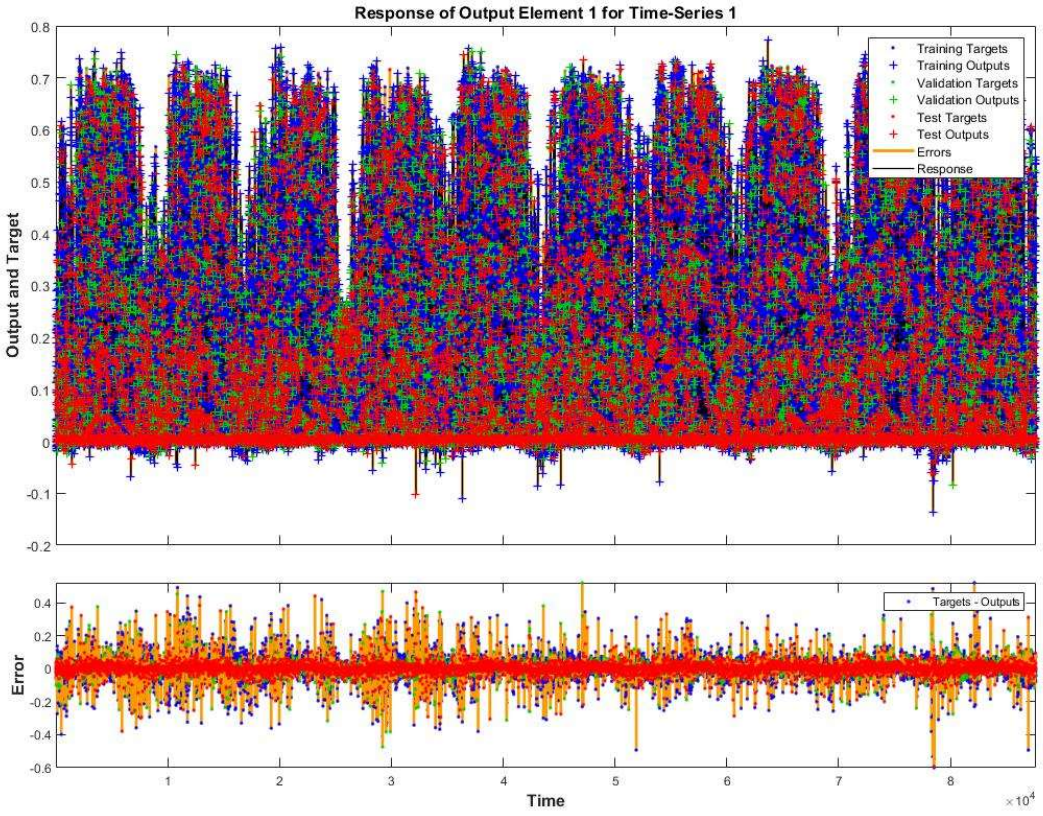
Slika 7.10: Validacija performansi neuronske mreže

Odstupanje simuliranih nizova proizvodnje električne energije iz SE je prikazano na slici 7.11. Tijekom cjelokupnog procesa 70% vremenske domene (simulacije) je dodijeljeno uvježbavanju neuronske mreže, 15% validaciji i 15% ispitivanju. U svrhu uvježbavanja korišten je je Levenberg-Marquardtov algoritam. Koeficijent korelacije za niz pri uvježbavanju je 0,98639 pri validaciji 0,98553, pri ispitivanju 0,98601, dok združeni koeficijent iznosi 0,9862. Rezultati upućuju na zadovoljavajući stupanj korelacije ali također ukazuju na veću varijabilnost nego što je slučaj pri simuliranju proizvodnje električne energije iz VE. Unatoč povećavanju broja neurona u skrivenom dijelu kore neuronske mreže, koeficijent korelacije se ne može značajnije povećati.



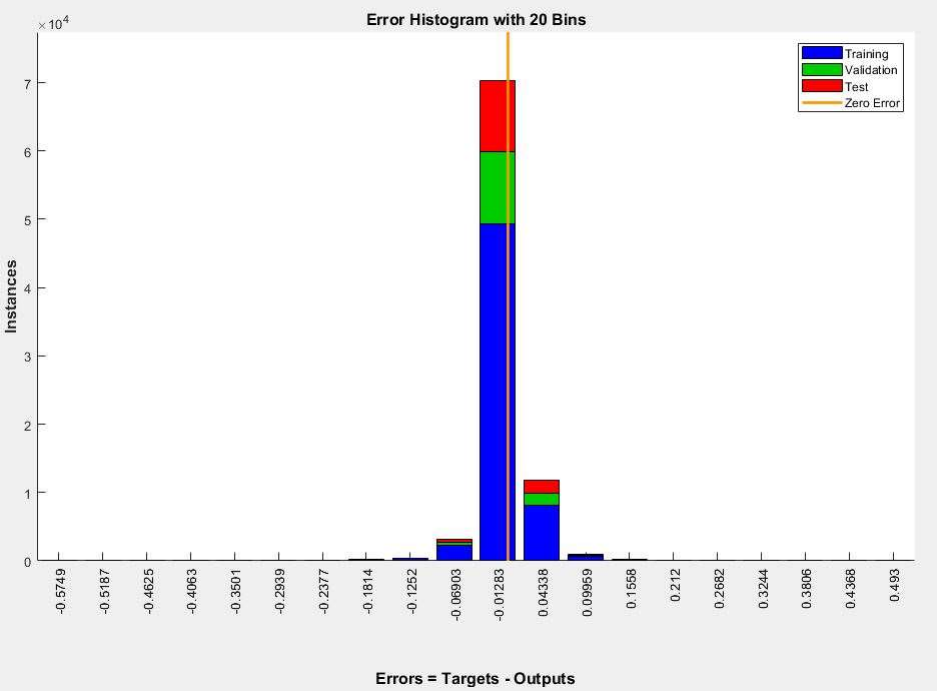
Slika 7.11: Prikaz odstupanja generiranih podataka u odnosu na ulazne

Na slici 7.12 prikazane su sve točke vremenskog niza podvrgnute simulaciji kroz proces uvježbavanja, validacije i ispitivanja u obje varijante – inicijalnog niza i generiranog niza. Razlika među točkama inicijalnog i generiranog niza opisana je pogreškom.



Slika 7.12: Prikaz treniranja neuronske mreže

Glavnina simuliranih točaka vremenskog niza, preko $7x10^4$, ima iznos od -0,01283, kao što je prikazano histogramom grešaka na slici 7.13.



Slika 7.13: Histogram grešaka na izlazu

7.4. Simulacija i optimiziranje hibridnog sustava

U predmetnoj disertaciji posvećena je posebna pozornost na modeliranje i simulaciju hibridnog sustava koji se sastoji od SE, VE i spremnika energije zasnovanog na tehnologiji olovnih baterija sa sulfatnom kiselinom (VRLA tip). Model je zasnovan na matematičkim odnosima između trenutne proizvodnje električne energije iz SE, VE i dinamici punjenja i pražnjenja spremnika energije, te u konačnici metodi analize osjetljivosti. Ulazni podaci korišteni za simulaciju SE i VE su simulirani u modelima u poglavljima 7.3.2 i 7.3.3 koji omogućuju podatke o trenutnoj proizvodnji električne energije za period od deset godina u razlučivosti od jednog sata. Odabir najboljeg rješenja je proveden analizom osjetljivosti, a, model je napravljen u MS Excel 2010 software-u. Detaljne informacije o dimenzioniranju hibridnog sustava se nalaze u Prilogu 1.

Postupak simulacije:

1. Postavljanje ulaznih podataka, normiranih trenutnih električnih snaga proizvodnje za SE i VE
2. Pretvorba trenutnih snaga SE i VE u količinu proizvedene električne energije s obzirom na razlučivost ulaznih podataka, odnosno 1 h
3. Uspostavlja se tablica mogućih rješenja, koja objedinjuje SE i VE, sukladno tablici 7.5

Tablica 7.5: Moguća rješenja hibridnog sustava

	VE 1 MW	**...**	**VE15 MW**
SE 1 MW	H1-1	...	H1-15
...	...	...	...
SE 15 MW	H15-1	...	H15-15

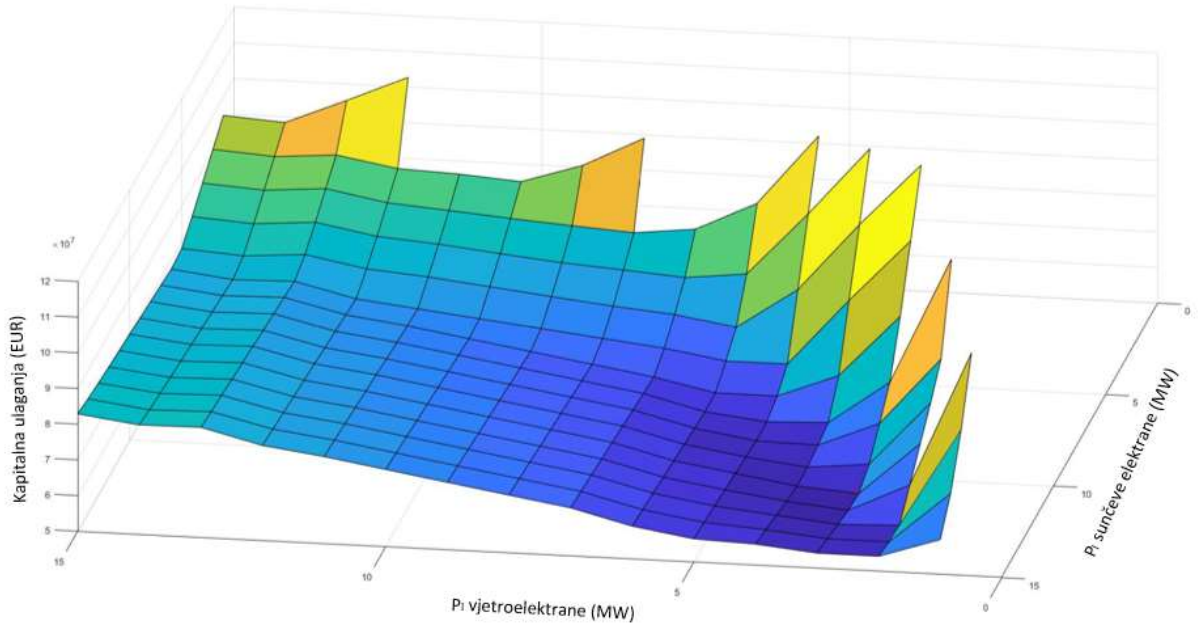
4. Za svaki trenutak t kronološko od t_1 do t_{87600} provodi se algoritam kojim se utvrđuje nužan kapacitet spremnika energije

$$\begin{gathered} \left(P_{VEx} + P_{SEy}\right)\Delta t = W_{PS}(\Delta t) \\ W_T(\Delta t) = 1MWh \\ W_{PS} + W_B \geq W_T \end{gathered} \tag{7.1}$$

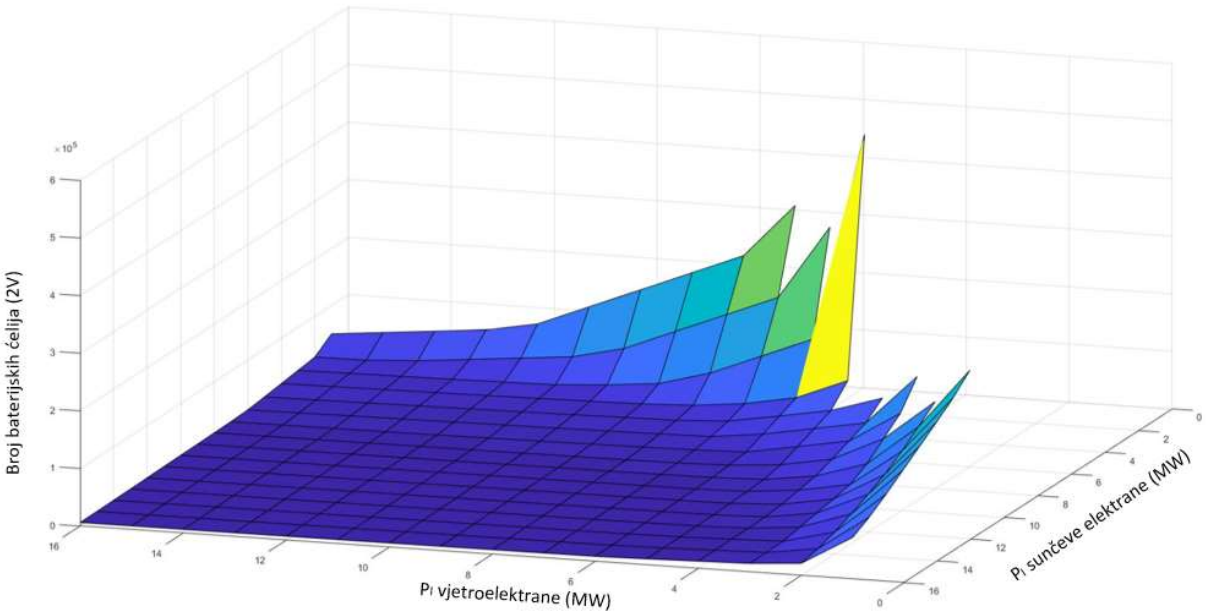
   Na kraju provedbe simulacije provjerava se broj ciklusa punjenja i pražnjenja spremnika energije prema formuli:

$$\frac{\sum_{t=1}^{t=87600} W_{B-}(t)}{W_B} = broj\ ciklusa\ baterije \tag{7.2}$$

   Uporabom navedene formule proveden je *Ranflow algoritam* na *umjetan* način, obzirom da se računa *umjetno* pražnjenje do kraja kapaciteta baterije.
5. Izračun kapitalnih ulaganja, CAP_{BAT}, i operativnih troškova, OP_{BAT}, spremnika energije
6. Izračun kapitalnih ulaganja i operativnih troškova za sva rješenja za period od deset godina. Operativni troškovi su podložni procijenjenoj inflatornoj stopi od 1% godišnje.
7. Traži se rješenje sa najmanjim CAP_{VE}+CAP_{SE}+CAP_{BAT} u cijeloj tablici



Slika 7.14: Prostor mogućih rješenja za hibridni sustav – ovisnost dimenzije spremnika energije o instaliranim snagama SS i VS – najniža točka označava optimum



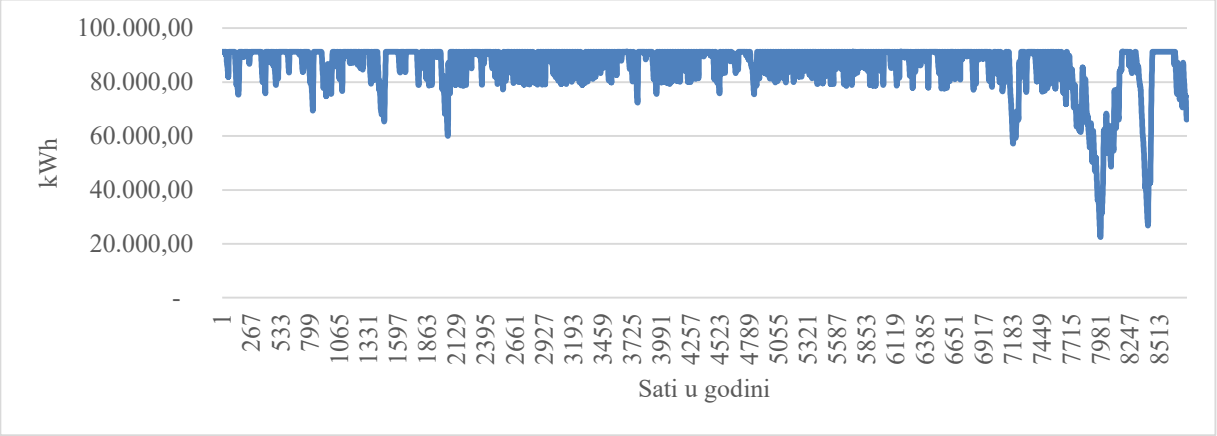
Slika 7.15: Broj baterijskih ćelija za hibridne sustave

Godišnja proizvodnja je zbroj energije proizvedene u SE i VE tijekom svakog sata tijekom jedne godine. U tablici 7.6 prikazani su rezultati simulacije godišnje proizvodnje električne energije za optimalno hibridno rješenje. Evidentno je da unatoč optimizaciji sustav generira znatno više električne energije nego što je to potrebno.

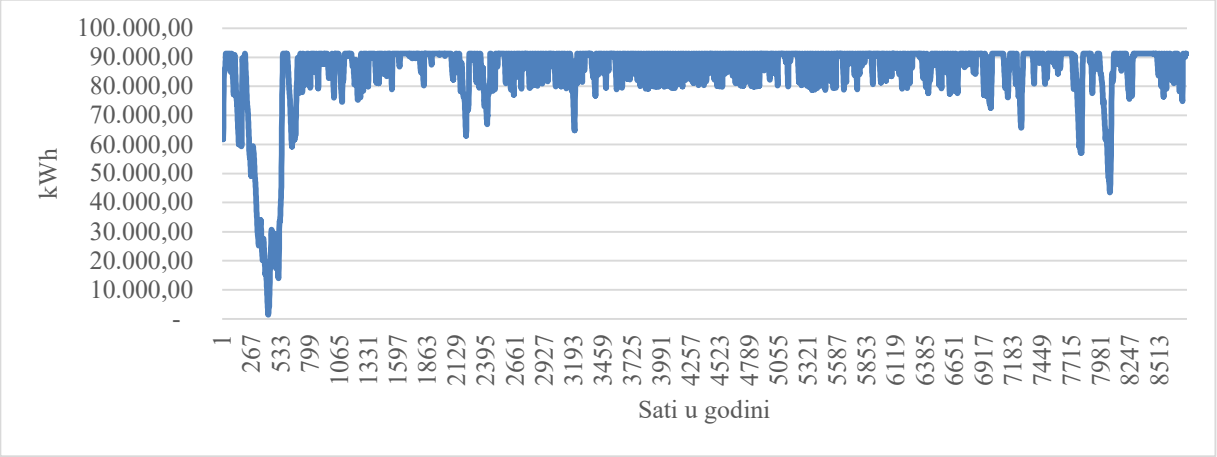
Tablica 7.6: Prikaz godišnje proizvodnje električne energije iz optimiziranog hibridnog rješenja

Godina	kWh proizvedeno u godini	Potrebno kWh	Delta kWh
1	16 619 491 ,90	8 760 000 ,00	7 859 491 ,90
2	16 604 617 ,49	8 760 000 ,00	7 844 617 ,49
3	16 800 377 ,73	8 760 000 ,00	8 040 377 ,73
4	17 281 399 ,14	8 760 000 ,00	8 521 399 ,14
5	17 373 316 ,91	8 760 000 ,00	8 613 316 ,91
6	16 951 579 ,01	8 760 000 ,00	8 191 579 ,01
7	18 075 564 ,98	8 760 000 ,00	9 315 564 ,98
8	17 164 960 ,79	8 760 000 ,00	8 404 960 ,79
9	16 697 550 ,60	8 760 000 ,00	7 937 550 ,60
10	16 813 204 ,04	8 760 000 ,00	8 053 204 ,04

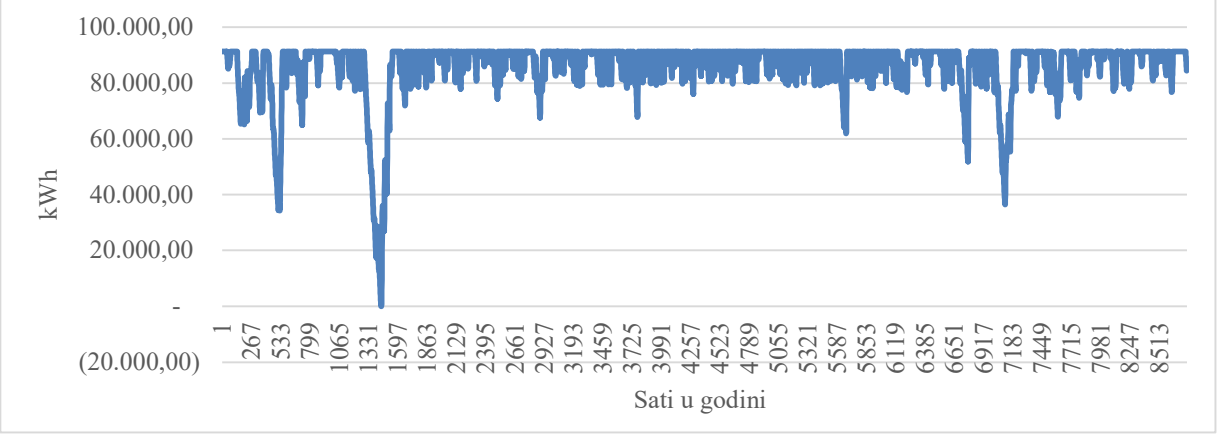
Simulirana dinamika spremnika u periodu od deset godina prikazana je na slikama 7.16 – 7.25. za optimalno hibridno rješenje. Prikaz na slikama 7.16 – 7.25 je prikaz pražnjenja spremnika energije za svaku pojedinu godinu u razlučljivosti od jednog sata dok krivulja ukazuje na emitiranu energiju u slučaju kada krivulja ide prema dolje, odnosno akumuliranu energiju u slučaju kada krivulja ide prema gore.



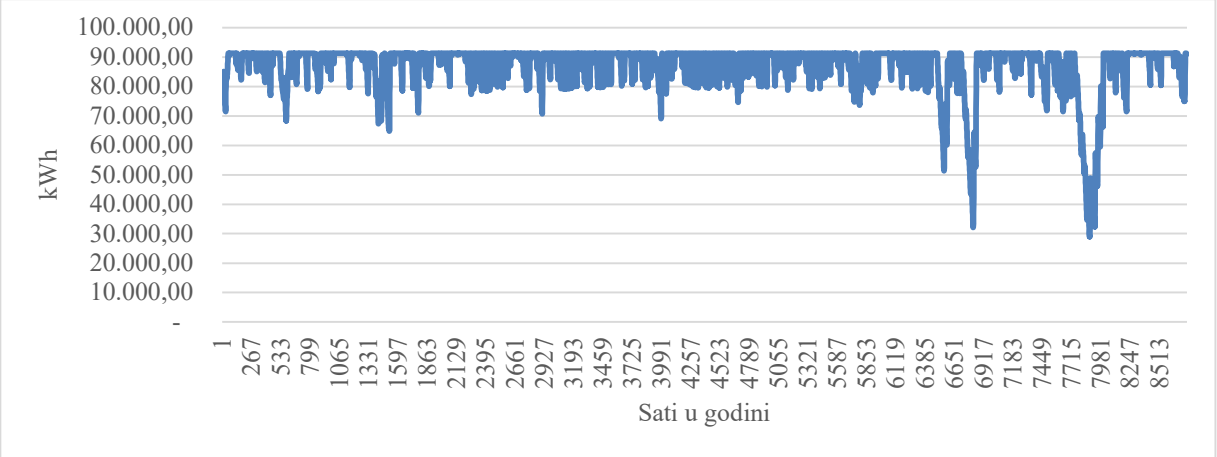
Slika 7.16: Dinamika spremnika tijekom 1. simulirane godine



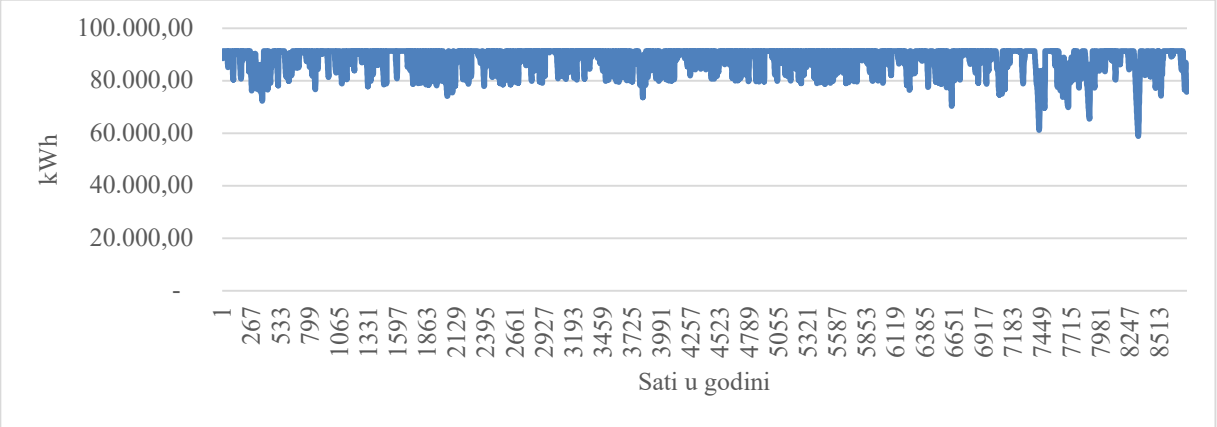
Slika 7.17: Dinamika spremnika tijekom 2. simulirane godine



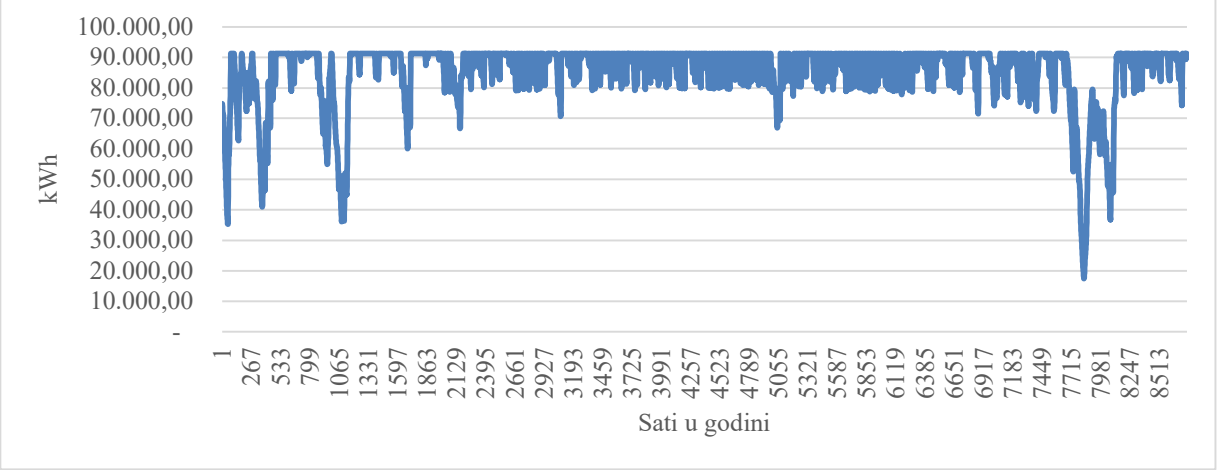
Slika 7.18: Dinamika spremnika tijekom 3. simulirane godine



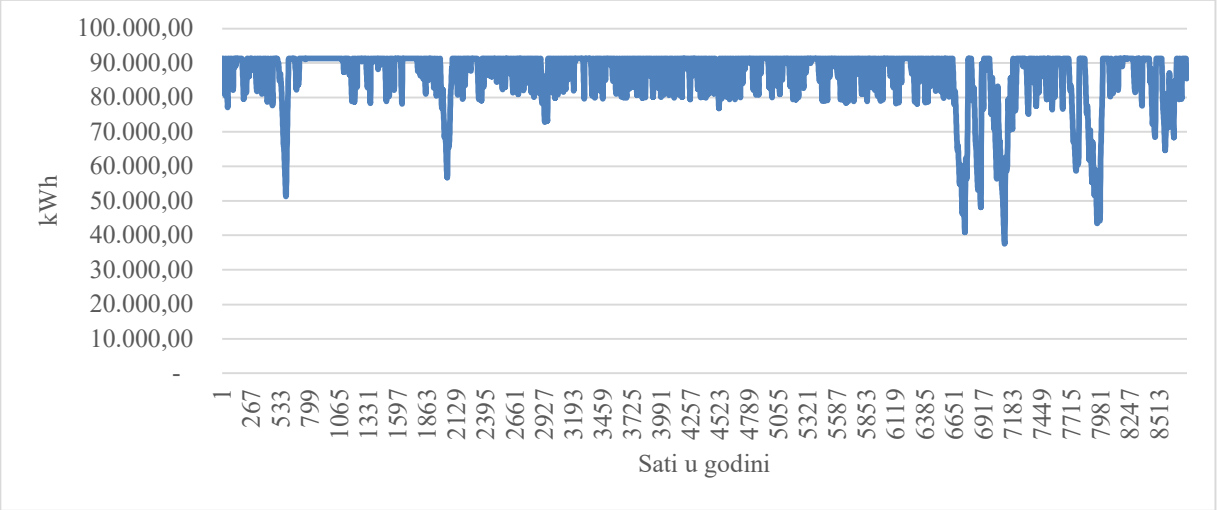
Slika 7.19: Dinamika spremnika tijekom 4. simulirane godine



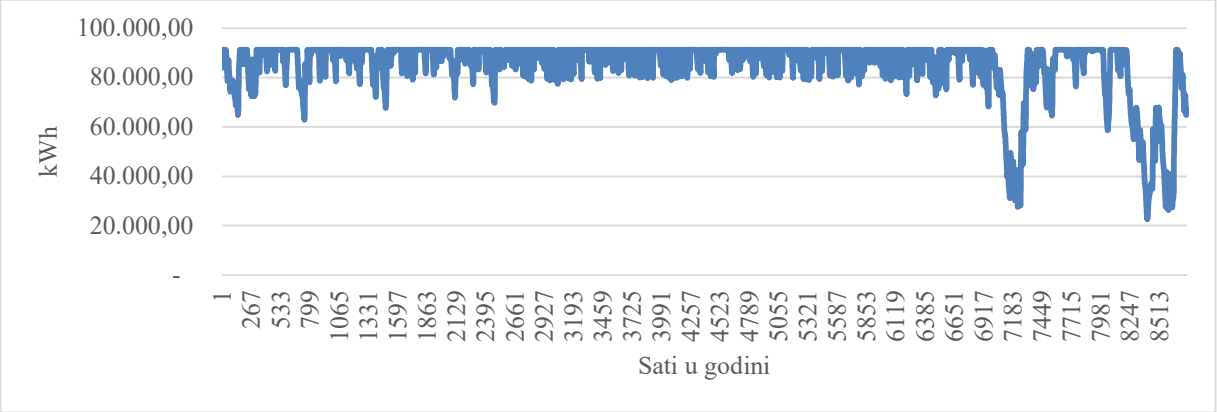
Slika 7.20: Dinamika spremnika tijekom 5. simulirane godine



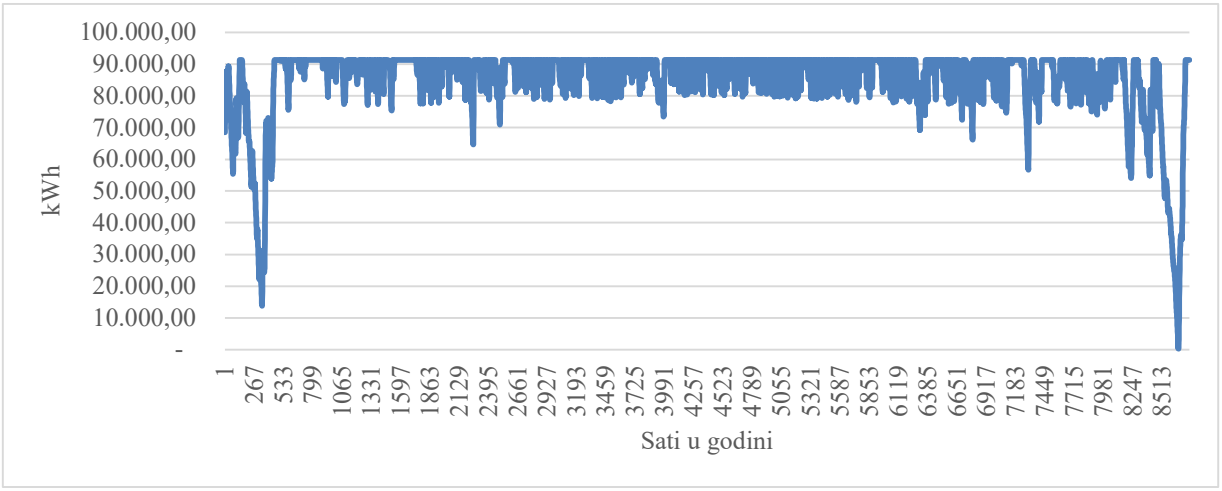
Slika 7.21: Dinamika spremnika tijekom 6. simulirane godine



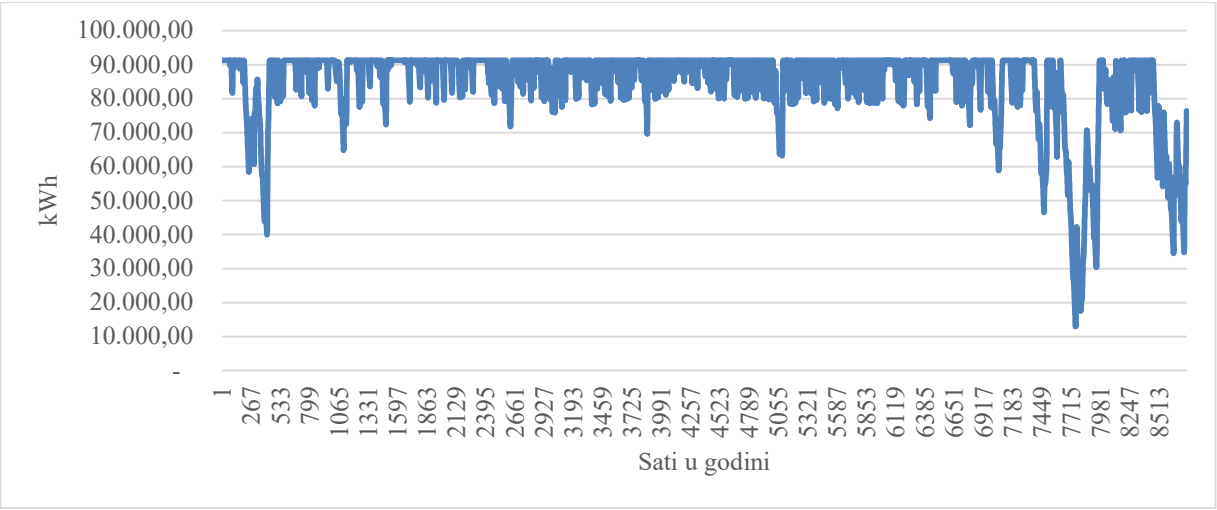
Slika 7.22: Dinamika spremnika tijekom 7. simulirane godine



Slika 7.23: Dinamika spremnika tijekom 8. simulirane godine



Slika 7.24: Dinamika spremnika tijekom 9. simulirane godine



Slika 7.25: Dinamika spremnika tijekom 10. simulirane godine

7.5. Rizici opskrbe energentima u R.H.

Kvantificiranje rizika se nameće kao izuzetno zahtjevan zadatak, te je stoga u predmetnoj disertaciji u tu svrhu korišteni neizrazita logika i neizrazita Delphi metoda, kao alati koji imaju mogućnost pretvorbe lingvističkih vrijednosti u matematičke. Rizici su podijeljeni u tri skupine: rizici vezani za infrastrukturu, dobavljivost energenata i vanjske rizike kao što su teroristički napadi ili hazardni utjecaji vremenskih nepogoda.

Uredba EU 2017/1938 sigurnost opskrbe prirodnim plinom definira kako opskrbu kao sigurnom ukoliko se zadovolji minimalno 100% potreba u zemlji zadovoljeno sa N-1 smjerom dobave [110]. U Republici Hrvatskoj je 2016. godine razina sigurnosti iznosila 89% [110] dok je 2018. godine iznosila 73% [111]. Proizvodnja prirodnog plina se od 2015. do 2019. godine smanjuje prosječnom stopom od 9% a ostatak potreba se nadoknađuje iz dva dobavna pravca (Mađarska i Slovenija) [112]. U izvještaju Odbora za ekonomiju i sigurnost NATO-a [113] ukazano je na problem jednosmjernih dobavnih pravaca prema R.H. kao i na problem da sav taj plin zapravo potječe samo sa jednog mjesta, odnosno Ruske Federacije.

Opskrba naftnim derivatima se odvija iz rafinerija u R.H. i dobavom iz inozemstva koji iznosi gotovo 60% ukupne potrošnje naftnih derivata [112] na teritoriju R.H.

Hrvatski elektroenergetski sustav je neto uvoznik električne energije koji je 2017. godine iznosio 36,7% ukupnih potreba u koje je uključena i polovica proizvodnje iz nuklearne elektrane Krško [112].

Sukladno Delphi metodi, uzeto je mišljenje triju stručnjaka na području sigurnosti i energetike u R.H. i ista mišljenja su pretvorena u neizrazite brojeve korištene za daljnju analizu.

U tablicama 7.7 - 7.10 prikazana je struktura ulaznih podataka u neizrazitu Delphi ulaznu matricu za tri ispitanika.

Tablica 7.7: Ulazni podaci 1, neizrazita Delphi ulazna matrica

	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Nafta	Visoko			Srednje			Visoko		
Plin	Srednje			Nisko			Srednje		
El.en.	Visoko			Visoko			Visoko		
OIE	Vrlo visoko			Vrlo visoko			Srednje		
Nafta	5	7	9	3	5	7	5	7	9
Plin	3	5	7	1	3	5	3	5	7
El.en.	3	5	7	3	5	7	5	7	9
OIE	7	9	9	7	9	9	3	5	7

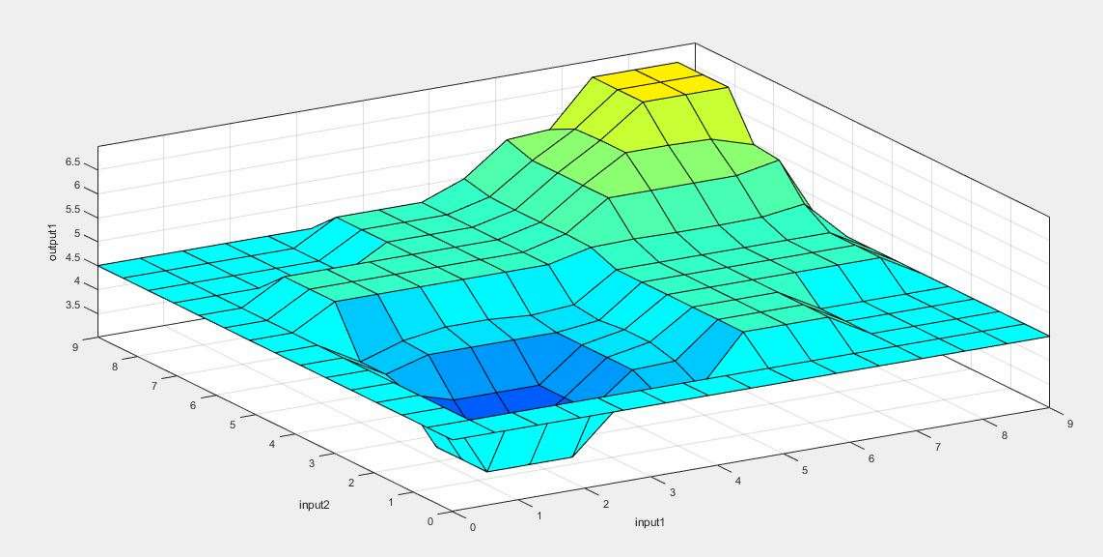
Tablica 7.8: Ulazni podaci 2, neizrazita Delphi ulazna matrica

	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Nafta	Srednje			Visoko			Srednje		
Plin	Srednje			Srednje			Visoko		
El.en.	Visoko			Visoko			Visoko		
OIE	Vrlo visoko			Vrlo visoko			Visoko		
Nafta	3	5	7	5	7	9	3	5	7
Plin	3	5	7	3	5	7	5	7	9
El.en.	5	7	9	5	7	9	5	7	9
OIE	7	9	9	7	9	9	5	7	9

Tablica 7.9: Ulazni podaci 3, neizrazita Delphi ulazna matrica

	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Nafta	Visoko			Srednje			Visoko		
Plin	Srednje			Srednje			Visoko		
El.en.	Visoko			Visoko			Visoko		
OIE	Vrlo visoko			Vrlo visoko			Srednje		
Nafta	5	7	9	3	5	7	5	7	9
Plin	3	5	7	3	5	7	5	7	9
El.en.	3	5	7	3	5	7	5	7	9
OIE	7	9	9	7	9	9	3	5	7

Na slici 7.26 prikazano je polje sa pripadnom neizrazitom funkcijom zasnovanom na dva ulaza i jednom izlazu. Obzirom da su sva tri razmatrana faktora (infrastruktura, dobava i otpornost na vanjske utjecaje) kvalificirani istim identičnim sustavom tada i odnos među milo kojom kombinacijom parova od spomenute trojke nužno mora rezultirati istom funkcijom.



Slika 7.26: Prikaz neizrazite (fuzzy) funkcije

7.6. Višekriterijsko odlučivanje

U predmetnoj disertaciji proveden je proces višekriterijskog odlučivanja zasnovan na TOPSIS metodi. Podvrgnuti TOPSIS metodi su četiri kriterija sa različitim težinskim faktorima: kapitalna ulaganja sa 40%, operativni troškovi sa 30%, emisija CO_2 sa 20% i rangiranje sukladno faktorima rizika i stupnju kvalitete opskrbe (diverzifikacija izvora napajanja) sa 10%. Stupanj kvalitete opskrbe je bodovni sustav a temelji se na provedenoj neizrazitoj Delphi analizi, na način da se zbroje dodijeljeni bodovi za pojedini izvor koji su proizašli iz (obrnutog) rangiranja.

Tijekom provedene Monte Carlo simulacije i ispada pojedinih komponenti napajanja paralelni sustavi preuzimaju teret a učinkovitost samih izvora električne energije je promjenjiva. U tablicama [7.10]-[7.15] se može vidjeti kako pomicanje opterećenja utječe na učinkovitost koja se dalje odražava na pogonske troškove, odnosno troškove goriva i emisiju CO_2. Korištene krivulje učinkovitosti pojedine tehnologije proizvodnje električne energije se nalaze u Prilogu 2.

Tablica 7.10: Učinkovitost plinskih agregata i gorivih ćelija pri 100% opterećenja u standardnoj konfiguraciji

	100%	100%	100%
STANDARD	**Učinkovitost (%)**	**Gorivo (€/kWh)**	**CO_2**
Plinski agregat	45,5	0,065072663	397,8340788
Goriva ćelija	54,0	0,054829744	335,6312005

Tablica 7.11: Učinkovitost plinskih agregata i gorivih ćelija pri 100% opterećenja u konfiguraciji sa 1MW SE

	100%	100%	100%
1MW SUNČEVA EL.	**Učinkovitost (%)**	**Gorivo (€/kWh)**	**CO_2**
Plinski agregat	44,80469041	0,066082504	404,007938
Goriva ćelija	54,38913645	0,054437455	333,2298692

Tablica 7.12: Učinkovitost plinskih agregata i gorivih ćelija pri 100% opterećenja u konfiguraciji sa 1 MW VE

	100%	100%	100%
1MW VJETRO EL.	**Učinkovitost (%)**	**Gorivo (€/kWh)**	**CO_2**
Plinski agregat	44,12738578	0,067096795	410,2089953
Goriva ćelija	54,06447721	0,054764354	335,2309272

Tablica 7.13: Učinkovitost plinskih agregata i gorivih ćelija pri 50% opterećenja u standardnoj konfiguraciji

	50%	50%	50%
STANDARD	**Učinkovitost (%)**	**Gorivo (€/kWh)**	**CO_2**
Plinski agregat	42	0,07049538	430,9869187
Goriva ćelija	55	0,05383284	329,528815

Tablica 7.14: Učinkovitost plinskih agregata i gorivih ćelija pri 50% opterećenja u konfiguraciji sa 1MW SE

	50%	50%	50%
1 MW SUNČEVA EL.	**Učinkovitost (%)**	**Gorivo (€/kWh)**	**CO_2**
Plinski agregat	40,21707892	0,07362062	450,0936187
Goriva ćelija	53,87402205	0,05495796	336,4160338

Tablica 7.15: Učinkovitost plinskih agregata i gorivih ćelija pri 50% opterećenja u konfiguraciji sa 1MW VE

	50%	50%	50%
1 MW VJETRO EL.	**Učinkovitost (%)**	**Gorivo (€/kWh)**	**CO_2**
Plinski agregat	39,40071389	0,07514600	459,4193556
Goriva ćelija	52,86021275	0,05601200	342,8681779

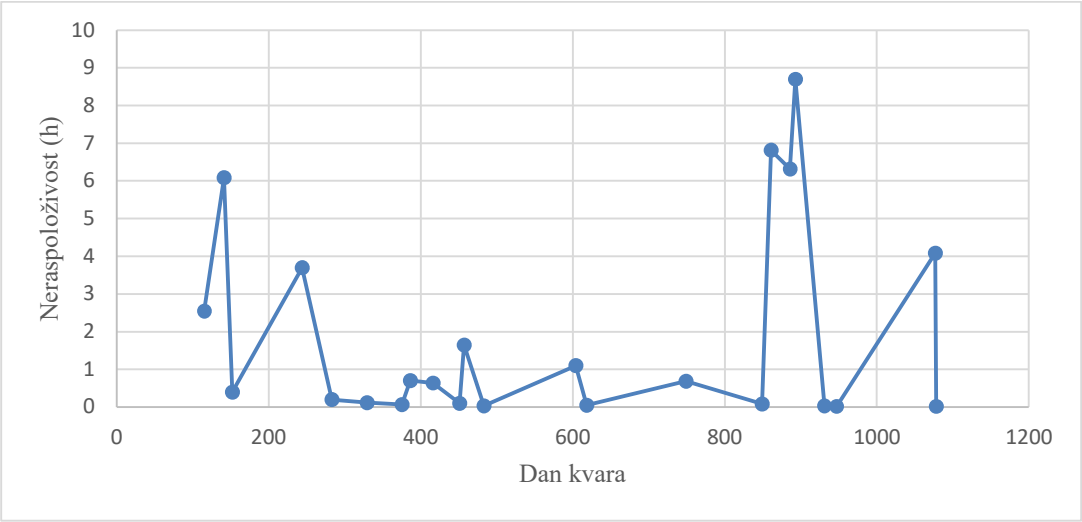
7.7. Emerson podatkovni centar – referentni validacijski model

U tablici 7.16 su prikazana vremena nastanka kvarova na komercijalnoj mreži kao i njihovo trajanje (neraspoloživost mreže) u periodu od tri godine, od 2013. do 2015. na lokaciji St. Louis, Missoury, SAD. Sve podatke je o postrojenju su ustupljeni od strane Emerson Electric a u svrhu izrade predmetne disertacije.

Tablica 7.16: Podaci o nestanku napajanja iz pojne mreže u Emerson podatkovnom postrojenju

Dan kvara	Neraspoloživost (min)	Neraspoloživost (h)	Broj dana između kvarova	Broj sati između kvarova
115	153	2,55	115	2760
141	365	6,08	26	624
152	24	0,40	11	264
244	222	3,70	92	2208
283	12	0,20	39	936
329	7	0,12	46	1104
375	4	0,07	46	1104
386	42	0,70	11	264
416	38	0,63	30	720
451	6	0,10	35	840
457	99	1,65	6	144
483	2	0,03	26	624
604	66	1,10	121	2904
618	3	0,05	14	336
749	41	0,68	131	3144
849	5	0,08	100	2400
861	409	6,82	12	288
886	379	6,32	25	600
893	522	8,70	7	168
931	2	0,03	38	912
947	1	0,02	16	384
1077	245	4,08	130	3120
1078	1	0,017	1	24

Na slici 7.27 prikazana je empirijska krivulja neraspoloživosti pojne mreže izražena u satima na pojedine dane pogona na lokaciji Emersonovog podatkovnog centra u St. Louisu, temeljem podataka iz tablice 7.16.



Slika 7.27: Neraspoloživost pojne mreže u Emerson podatkovnom centru na lokaciji St. Louis

Temeljem dostupnih podataka, može se uočiti da je pojavnost kvarova na mreži nepravilna, obzirom da je glavnina prekida uzrokovana korektivnim održavanjem. Može se također uočiti da je u promatranom periodu bilo sedam ispada duljih od dva sata a do kojih je došlo uslijed vremenskih neprilika (uragana), a među kojima u jednom slučaju (8,7 h) uslijed prometne nesreće u kojoj je uništen segment voda distributivne mreže. Prosječna raspoloživost napajanja iz mreže je 99,832%.

Emerson podatkovni centar ima do 100 kW ugrađenu SE sa parametrima sukladno tablici 7.17. Od puštanja u pogon (2011. godine) do trenutka izrade ove disertacije nije zabilježen gubitak tereta, odnosno podatkovni centar je u potpunosti ispunio sva očekivanja.

Tablica 7.17: Osnovni podaci o tehničkim svojstvima SE u Emerson podatkovnom postrojenju

Grad	St. Louis
Država	Missouri
Geografska širina	38.78°N
Geografska dužina	90.38°W
Uzvisina	172 m
Pn (DC strana)	96,2 kW
Tip sustava	Fiksne ploče
Nagib sustava	10,0°
Azimut sustava	180,0°
Predviđeni trošak el.en.	7,0 centi/kWh

Emersonov podatkovni centar ima infrastrukturu za 100 kW tereta i ispunjava zahtjeve Razine 4 raspoloživosti, odnosno ima u potpunosti dva odvojena distributivna polja unutar infrastrukture a svako pojno polje ima dva izvora energije, jedan aktivan (pojna mreža) a drugi u stanju pripravnosti (paralelni dizel agregat).

U tablici 7.18 prikazane su srednje vrijednosti stvarnih mjerenja generirane električne energije iz SE od 2011. do 2015. godine.

U svrhu evaluacije arhitektura za validacijski model, odabrane su arhitekture koje ne uključuju hibridne sustave i vjetroagregate budući da uporaba istih nije moguća na mikrolokaciji obzirom da je krajolik šumovit i uporaba vjetroagregata na toj mikrolokaciji bi bila tehnički zahtjevna a u financijskom smislu nepovoljna. Obzirom da je infrastruktura dimenzionirana za 100 kW tereta, uporaba plinskih turbina velike snage nema smisla. Također, obzirom da se o arhitekturi odlučivalo prije više od deset godina, mora se uzeti u obzira da je u to vrijeme učinkovitost plinskih agregata bila niža nego što je to danas, cijene gorivih ćelija su bile razmjerno visoke, te jedina opcija koja ima smisla za razmatranje u pogledu plinskih tehnologija je plinska mikroturbina(e). U tablici 7.19 izlistane su smislene arhitekture za evaluaciju.

Tablica 7.18: Podaci o prosječnoj sunčevoj radijaciji i proizvodnji električne energije

Mjesec	**Sunčeva radijacija (kWh/m^2/dan)**	**AC energija (kWh)**
1	2,64	6 093
2	3,42	7 113
3	4,54	10 132
4	5,35	11 210
5	6,09	12 819
6	6,51	12 977
7	6,46	13 154
8	5,63	11 436
9	4,90	9 873
10	3,95	8 506
11	2,71	5 759
12	2,21	4 975
	4,534166667	**114 047**

Tablica 7.19: Razmatrane arhitekture za validacijski model

	Izvor 1	**Izvor 2**	**Izvor 3**	**Izvor 4**
Arhitektura 1	Mreža	Dizel	Mreža	Dizel
Arhitektura 2	Plinske mikroturbine	Dizel	Plinske mikroturbine	Dizel
Arhitektura 3	Plinske mikroturbine	Mreža	Plinske mikroturbine	Mreža
Arhitektura 4	Mreža	Plinske mikroturbine	Mreža	Plinske mikroturbine
Arhitektura 14	Mreža + sunčeva el.	Dizel	Mreža + sunčeva el.	Dizel
Arhitektura 17	Mreža + sunčeva el.	Plinske mikroturbine	Mreža + sunčeva el.	Plinske mikroturbine
Arhitektura 26	Mreža	Dizel	Mreža	Dizel
Arhitektura 27	Plinske mikroturbine	Dizel	Plinske mikroturbine	Dizel
Arhitektura 28	Plinske mikroturbine	Mreža	Plinske mikroturbine	Mreža
Arhitektura 29	Mreža	Plinske mikroturbine	Mreža	Plinske mikroturbine

8. REZULTATI ISTRAŽIVANJA

Rezultati istraživanja su podijeljeni u dva dijela. Prvi dio je vezan za validacijski model, te stoga rezultate treba usporediti sa postojećim stanjem i u slučaju podudaranja, nužni zaključak treba biti da je model postavljen ispravno. Drugi dio rezultata se tiče primjene modela na evaluaciju moguće izgradnje podatkovnog postrojenja u Republici Hrvatskoj temeljem važećih parametara, kao što su trenutne cijene energenata, njihova dobavljivost, cijena opreme i održavanja.

8.1. Rezultati validacijskog modela

Rezultati evaluacije neizrazite Delphi metode, provedene na jednom ispitaniku, su prikazani u tablicama 8.1-8.6. Obzirom da se lokacija nalazi u SAD-u, koji ima mogućnost zadovoljavanja vlastitih energetskih potreba iz vlastitih resursa i rezervi, općenito za gotovo svu infrastrukturu, sustave dobave kao i otpornost na vanjske utjecaje se može tvrditi da su gotovo svi ponuđeni izvori energije podložni niskom riziku. Kao jedini ponuđeni izvor podložan rizicima je infrastrukturni dio pojne mreže kao i njezina otpornost na vanjske utjecaje. Hodogram evaluacije je opisan u poglavlju 5.10.3.

Tablica 8.1: Združena matrica odlučivanja za validacijski model

	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Težine	**Srednja**			**Srednja**			**Srednja**		
Nafta	7	9	9	7	9	9	7	9	9
Plin	7	9	9	7	9	9	7	9	9
El.en.	5	7	9	7	9	9	5	7	9
OIE	7	9	9	7	9	9	7	9	9

Tablica 8.2: Normirana neizrazita matrica odlučivanja za validacijski model

Težine	3	5	7	3	5	7	3	5	7
	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Nafta	0,778	1,000	1	0,778	1,000	1	0,778	1,000	1,000
Plin	0,778	1,000	1	0,778	1,000	1	0,778	1,000	1,000
El.en.	0,556	0,778	1	0,778	1,000	1,000	0,556	0,778	1,000
OIE	0,778	1,000	1,000	0,778	1,000	1,000	0,778	1,000	1,000

Tablica 8.3: Težinska normirana neizražena matrica odlučivanja za validacijski model

Težine	3	5	7	3	5	7	3	5	7
	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Nafta	2,333	5,000	7,000	2,333	5,000	7,000	2,333	5,000	7,000
Plin	2,333	5,000	7,000	2,333	5,000	7,000	2,333	5,000	7,000
El.en.	1,667	3,889	7,000	2,333	5,000	7,000	1,667	3,889	7,000
OIE	2,333	5,000	7,000	2,333	5,000	7,000	2,333	5,000	7,000
$\mathbf{A^+}$	**2,333**	**5,000**	**7,000**	**2,333**	**5,000**	**7,000**	**2,333**	**5,000**	**7,000**
$\mathbf{A^-}$	**1,667**	**3,889**	**7,000**	**2,333**	**5,000**	**7,000**	**1,667**	**3,889**	**7,000**

Tablica 8.4: Udaljenost od najboljeg rješenja za validacijski model

	Infrastruktura	**Dobava**	**Otpornost na vanjske utjecaje**	$\mathbf{S_i^+}$
Nafta	0,000	0,000	0,000	0,000
Plin	0,000	0,000	0,000	0,000
El.en.	0,748	0,000	0,748	1,496
OIE	0,000	0,000	0,000	0,000

Tablica 8.5: Udaljenost od najlošijeg rješenja za validacijski model

	Infrastruktura	**Dobava**	**Otpornost na vanjske utjecaje**	$\mathbf{S_i^-}$
Nafta	0,748	0,000	0,748	1,496
Plin	0,748	0,000	0,748	1,496
El.en.	0,000	0,000	0,000	0,000
OIE	0,748	0,000	0,748	1,496

Tablica 8.6: Rangiranje za validacijski model

$\mathbf{P_i}$	**Dodijeljeni bodovi**	
1	2	Nafta
1	2	Plin
0	1	El.en.
1	2	OIE

Rezultati u tablicama 8.7-8.11 prikazuju ishode provedene TOPSIS analize na validacijskom modelu. Prvorangirana arhitektura je zasnovana na primarnom napajanju iz pojne mreže sa dvije strane a distribuirani izvori energije na samoj lokaciji u funkciji paralelnih sustava su dizel agregati.

Uz navedenu konfiguraciju izvora električne energije arhitektura također sadrži i sunčevu elektranu instalirane snage jednake kao što je i snaga tereta.

Tablica 8.7: TOPSIS ulazna matrica za validacijski model

	KATEGORIJA TROŠKA	**KATEGORIJA TROŠKA**	**KATEGORIJA TROŠKA**	**KATEGORIJA BENEFICIJA**
TEŽINA	0.4	0.3	0.2	0.1
	Kapitalna ulaganja ($)	**Operativni tr. sa gorivom ($)**	**CO_2 (t)**	**Stupanj kvalitete opskrbe**
ARHITEKTURA 1	260 000,00	768 984,83	1 589 769,115	6
ARHITEKTURA 2	997 200,00	1 802 691,45	1 569 379,996	8
ARHITEKTURA 3	937 200,00	1 745 587,18	1 569 369,913	6
ARHITEKTURA 4	937 200,00	789 305,92	1 589 768,539	6
ARHITEKTURA 14	3 152 000,00	292 953,24	11,76562812	6
ARHITEKTURA 17	3 829 200,00	313 271,15	6,282799658	6
ARHITEKTURA 26	560 000,00	718 920,09	1 382 797,589	6
ARHITEKTURA 27	1 297 200,00	1 646 368,53	1 590 267,754	8
ARHITEKTURA 28	1 237 200,00	1 588 932,04	1 590 254,379	6
ARHITEKTURA 29	1 237 200,00	738 865,19	1 382 796,458	6

Tablica 8.8: TOPSIS normirana matrica za validacijski model

	Kapitalna ulaganja ($)	**Operativni tr. sa gorivom ($)**	**CO_2 (t)**	**Stupanj kvalitete opskrbe**
ARHITEKTURA 1	0,045625111	0,205570687	0,366042813	0,294174203
ARHITEKTURA 2	0,174989848	0,481908752	0,361348238	0,39223227
ARHITEKTURA 3	0,164460976	0,466643219	0,361345916	0,294174203
ARHITEKTURA 4	0,164460976	0,21100307	0,36604268	0,294174203
ARHITEKTURA 14	0,553116728	0,078314416	2,71E-01	0,294174203
ARHITEKTURA 17	0,671952594	0,08374595	1,45E-01	0,294174203
ARHITEKTURA 26	0,098269469	0,192187013	0,318387818	0,294174203
ARHITEKTURA 27	0,227634207	0,44011936	0,366157624	0,39223227
ARHITEKTURA 28	0,217105335	0,424765015	0,366154545	0,294174203
ARHITEKTURA 29	0,217105335	0,197518883	0,318387557	0,294174203

Tablica 8.9: TOPSIS normirana težinska matrica za validacijski model

	Kapitalna ulaganja ($)	**Operativni tr. sa gorivom ($)**	**CO_2 (t)**	**Stupanj kvalitete opskrbe**
ARHITEKTURA 1	0,018250044	0,061671206	0,073208563	0,02941742
ARHITEKTURA 2	0,069995939	0,144572626	0,072269648	0,039223227
ARHITEKTURA 3	0,065784391	0,139992966	0,072269183	0,02941742
ARHITEKTURA 4	0,065784391	0,063300921	0,073208536	0,02941742
ARHITEKTURA 14	0,221246691	0,023494325	5,42E-02	0,02941742
ARHITEKTURA 17	0,268781037	0,025123785	2,89E-02	0,02941742
ARHITEKTURA 26	0,039307788	0,057656104	0,063677564	0,02941742
ARHITEKTURA 27	0,091053683	0,132035808	0,073231525	0,039223227
ARHITEKTURA 28	0,086842134	0,127429504	0,073230909	0,02941742
ARHITEKTURA 29	0,086842134	0,059255665	0,063677511	0,02941742
A^+	**0,018250044**	**0,023494325**	**2,89E-02**	**0,039223227**
A^-	**0,268781037**	**0,144572626**	**0,073231525**	**0,02941742**

Tablica 8.10: TOPSIS udaljenosti za validacijski model

	S_i^+	S_i^-	P_i
ARHITEKTURA 1	0,08314493	0,263890933	0,760414012
ARHITEKTURA 2	0,150201374	0,199029129	0,569907633
ARHITEKTURA 3	0,145431751	0,20305058	0,582671091
ARHITEKTURA 4	0,096434851	0,21866122	0,693950958
ARHITEKTURA 14	0,203233345	0,149272388	0,42346088
ARHITEKTURA 17	0,250728115	0,140110097	0,358486179
ARHITEKTURA 26	0,075903918	0,245568183	0,763886452
ARHITEKTURA 27	0,149814676	0,178438612	0,54360038
ARHITEKTURA 28	0,144797354	0,182744771	0,557927536
ARHITEKTURA 29	0,100671201	0,201176608	0,666483579

Tablica 8.11: TOPSIS rangiranje za validacijski model

Rang	Arhitektura	Izvor 1	Izvor 2	Izvor 3	Izvor 4	Dodatni sustav
1	**Arhitektura 26**	Mreža	Dizel	Mreža	Dizel	100 kW SS
2	**Arhitektura 1**	Mreža	Dizel	Mreža	Dizel	
3	**Arhitektura 4**	Mreža	Plinski generator	Mreža	Plinski generator	
4	**Arhitektura 29**	Mreža	Plinski generator	Mreža	Plinski generator	100 kW SS
5	**Arhitektura 3**	Plinski generator	Mreža	Plinski generator	Mreža	
6	**Arhitektura 2**	Plinski generator	Dizel	Plinski generator	Dizel	
7	**Arhitektura 28**	Plinski generator	Mreža	Plinski generator	Mreža	100 kW SS
8	**Arhitektura 27**	Plinski generator	Dizel	Plinski generator	Dizel	100 kW SS
9	**Arhitektura 14**	Mreža + sunčeva el.	Dizel	Mreža + sunčeva el.	Dizel	
10	**Arhitektura 17**	Mreža + sunčeva el.	Plinski generator	Mreža + sunčeva el.	Plinski generator	

Provedbom detaljne analize troškova i dobrobiti uspostavljeni su temelji za formiranje četiri glavna kriterija: kapitalnim ulaganjima, operativnim troškovima, emisiji CO_2 i rizicima opskrbe. Težinski faktori aplicirani na kategorije su slijedeći: 40% na kapitalna ulaganja, 30% na operativne troškove, 20% na emisiju CO_2 i 10% na rizike opskrbom energentima. U svrhu simulacije korišten je formirani sinergijski model raspoloživosti, čiji rezultati su u konačnici bili od presudne važnosti za razumijevanje dinamike postrojenja i utjecaja na operativne troškove kao i emisiju CO_2.

Rezultati dobiveni provedenom metodom se podudaraju sa stvarnim stanjem, odnosno sa odabirom izvora energije na lokaciji. Predmetno podatkovno postrojenje je u stvarnosti i klasificirano kao *zeleno* podatkovno postrojenje za što je i izdan certifikat.

Važnost dobivenih rezultata se očituje u činjenici da je ponuđene metoda, zajedno sa ponuđenim modelima i podmodelima točna, primjenjiva i obnovljiva. U sljedećem poglavlju ista metoda, dokazana na konkretnom primjeru, odnosno živom podatkovnom postrojenju, biti će primijenjena na generalnom modelu sa mogućom implementacijom u R.H. Nužno je još jednom napomenuti kako su ulazni podaci o količinama snage proizvedene iz VE i SE prosječne za cijelu R.H. te stoga rezultate modeliranja (prije svega hibridnih rješenja) treba uzeti isključivo kao smjernicu.

8.2. Rezultati modeliranja za R.H.

U ovom dijelu predočeni su rezultati istraživanja, a odnose se na primjenu modela za evaluaciju moguće izgradnje podatkovnog postrojenja u Republici Hrvatskoj temeljem važećih parametara kao što su cijene energenata, njihova dobavljivost, cijena opreme i troškovi održavanja. Od energenata razmatraju se nafta i plin, zatim električna energija i obnovljivi izvori električne energije. S obzirom na infrastrukturu, dobavljivost i otpornost na vanjske utjecaje utvrđeni su stupnjevi visoko, vrlo visoko, srednje, nisko i vrlo nisko.

Dobiveni rezultati uočljivi su u tablicama 8.12 – 8.22, te na slikama 8.1 – 8.12. U tablicama 8.12 – 8.15 prikazane su ulazne matrice odlučivanja za rizike opskrbe temeljene na neizrazitoj logici. Hodogram evaluacije je opisan u poglavlju 5.10.3.

Tablica 8.12: Združena matrica odlučivanja

Težine	**Srednja**			**Srednja**			**Srednja**		
Nafta	3	6,3333333	9	3	5,666667	9	3	6,3333333	9
Plin	3	5	7	1	4,333333	7	3	6,3333333	9
El.en.	3	5,6666667	9	3	5,666667	9	5	7	9
OIE	7	9	9	7	9	9	3	5,6666667	9

Tablica 8.13: Združena matrica odlučivanja

Težine	3	5	7	3	5	7	3	5	7
	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Nafta	3	6,3333333	9	3	5,666667	9	3	6,3333333	9
Plin	3	5	7	1	4,333333	7	3	6,3333333	9
El.en.	3	5,6666667	9	3	5,666667	9	5	7	9
OIE	7	9	9	7	9	9	3	5,6666667	9

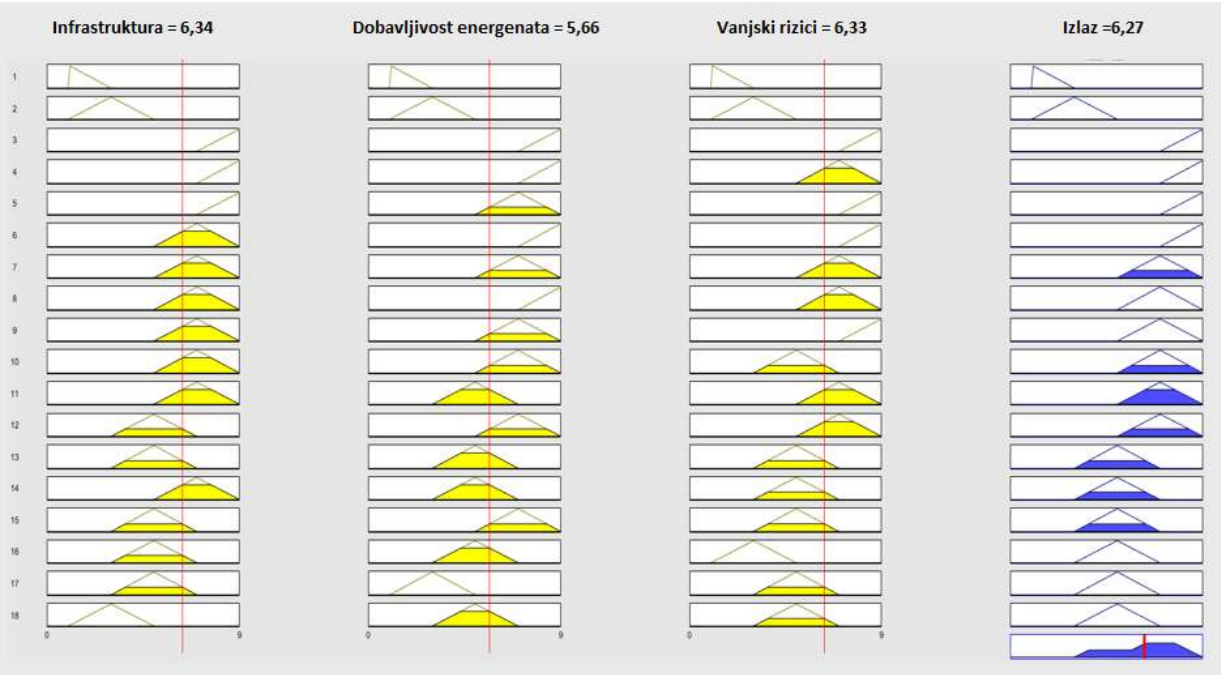
Tablica 8.14: Normirana neizrazita matrica odlučivanja

Težine	3	5	7	3	5	7	3	5	7
	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Nafta	0,333	0,704	1	0,333	0,630	1	0,333	0,704	1,000
Plin	0,333	0,556	0,777778	0,111	0,481	0,777778	0,333	0,704	1,000
El.en.	0,333	0,630	1	0,333	0,630	1,000	0,556	0,778	1,000
OIE	0,778	1,000	1,000	0,778	1,000	1,000	0,333	0,630	1,000

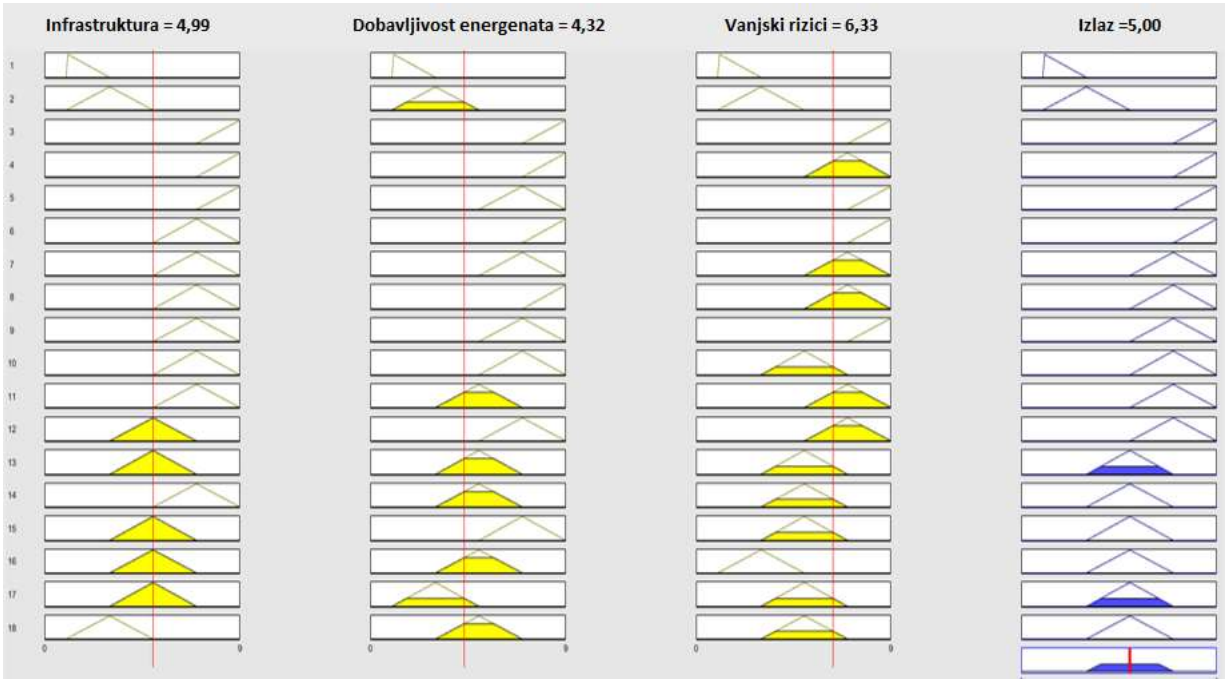
Tablica 8.15: Težinska normirana neizrazita matrica odlučivanja

Težine	3	5	7	3	5	7	3	5	7
	Infrastruktura			**Dobava**			**Otpornost na vanjske utjecaje**		
Nafta	1,000	3,519	7,000	1,000	3,148	7,000	1,000	3,519	7,000
Plin	1,000	2,778	5,444	0,333	2,407	5,444	1,000	3,519	7,000
El.en.	1,000	3,148	7,000	1,000	3,148	7,000	1,667	3,889	7,000
OIE	2,333	5,000	7,000	2,333	5,000	7,000	1,000	3,148	7,000
A^+	2,333	5,000	7,000	2,333	5,000	7,000	1,667	3,889	7,000
A^-	1,000	2,778	5,444	0,333	2,407	5,444	1,000	3,148	7,000

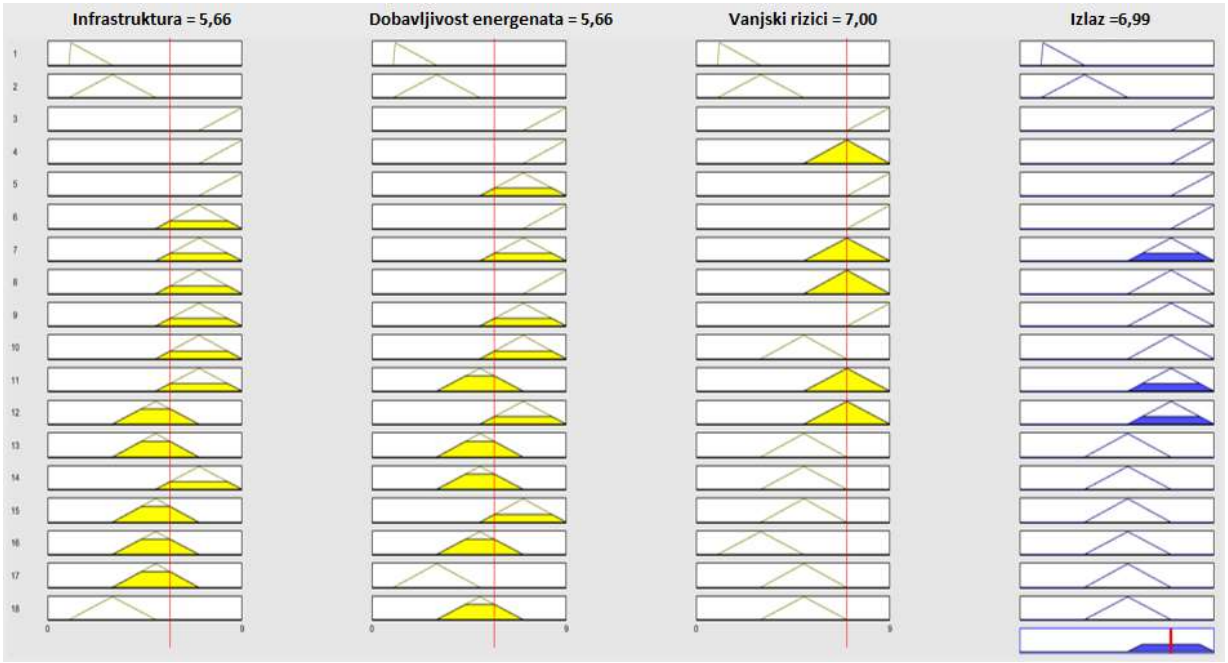
Na slikama 8.1 – 8.4 prikazane su funkcije pridruživanja odnosno neizrazite funkcije za rizike opskrbe naftom, plinom, električnom energijom i obnovljivom izvorima energije u R.H. Na svakoj od četiri slike su četiri stupca od kojih prva tri ukazuju na ulazne parametre: infrastrukturu, dobavljivost energenata i vanjske rizike. Obzirom da je sustav postavljen kao funkcija (pridruživanja) u prikazanom sučelju proizašlom iz Matlab 2018b softwareskog paketa, crvena linija označava trenutno odabranu točku, koja je u ovom slučaju rezultat združene matrice odlučivanja prikazane u tablicama 8.12 – 8.15. U četvrtom stupcu je izlazna funkcija sa pridruženom vrijednosti koja izravno ovisi o trima ulaznim vrijednostima ulaznih funkcija.



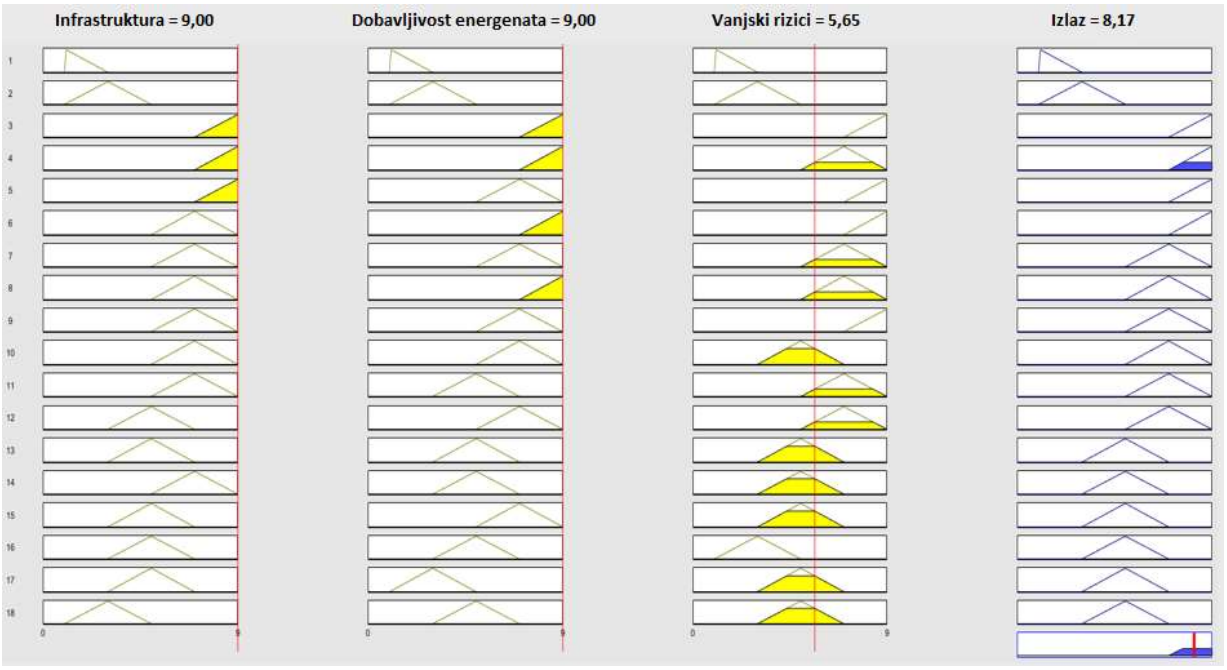
Slika 8.1: Prikaz rizika opskrbe naftom neizraženom logikom za R.H.



Slika 8.2: Prikaz rizika opskrbe plinom neizraženom logikom za R.H.



Slika 8.3: Prikaz rizika opskrbe električne energijom neizraženom logikom za R.H.



Slika 8.4: Prikaz rizika opskrbe OIE neizraženom logikom za R.H.

Tablica 8.16: Udaljenost od najboljeg rješenja za model R.H.

	Infrastruktura	**Dobava**	**Otpornost na vanjske utjecaje**	$\mathbf{S_i^+}$
Nafta	1,151	1,317	0,440	2,909
Plin	1,745	2,093	0,440	4,278
El.en.	1,317	1,317	0,000	2,635
OIE	0,000	0,000	0,575	0,575

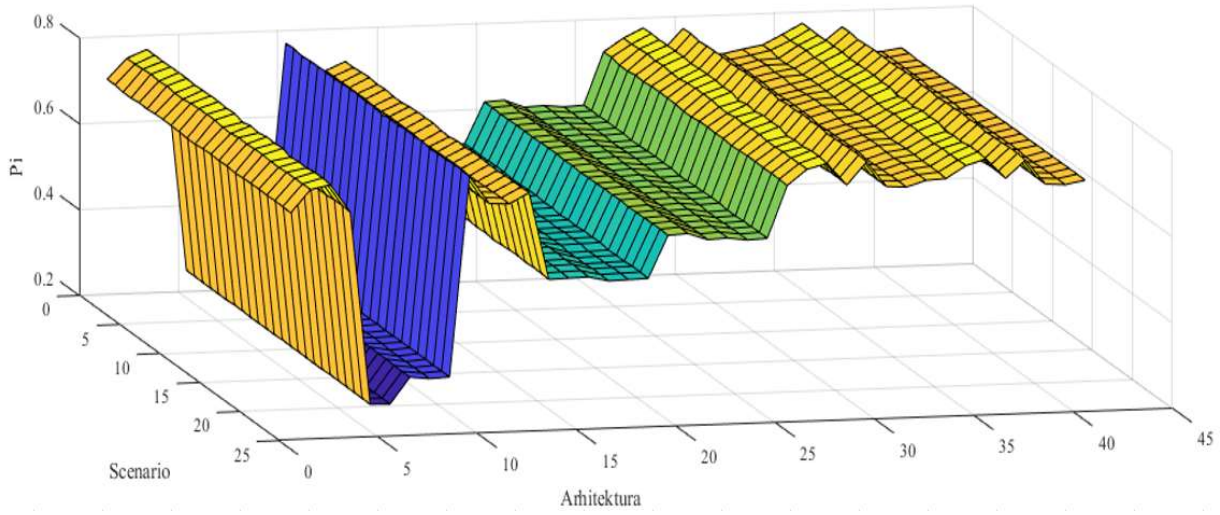
Tablica 8.17: Udaljenost od najlošijeg rješenja za model R.H.

	Infrastruktura	**Dobava**	**Otpornost na vanjske utjecaje**	$\mathbf{S_i^-}$
Nafta	0,995	1,067	0,214	2,275
Plin	0,000	0,000	0,214	0,214
El.en.	0,923	1,067	0,575	2,565
OIE	1,745	2,093	0,000	3,838

Tablica 8.18: Rangiranje za model R.H.

P_i	Dodijeljeni bodovi	
0,438909	2	Nafta
0,047601	1	Plin
0,493293	3	El.en.
0,869631	4	OIE

Na slici 8.5 prikazan je graf sa rezultatima analize osjetljivosti i utjecaja varijabilnosti rizika opskrbe na ishođenje optimalne arhitekture u razmatranom slučaju. U tu svrhu razvijena su 24 scenarija obzirom da je toliko mogućih permutacija među bodovima dodijeljenim pojedinom izvoru ili energentu. Što je dodijeljeni broj dodijeljenih bodova veći to je izvor odnosno energent povoljniji. Rezultati ukazuju u većini scenarija da je arhitektura 28 optimalna dok u scenarijima 15, 19, 20, 21, 23 i 24 ukazuju na arhitekturu 30 kao optimalnu.



Slika 8.5: Analiza osjetljivosti s obzirom na rizike

U tablicama 8.19A – 8.19D se nalaze konfiguracije za predložena 24 scenarija razvijena za analizu osjetljivosti.

Tablica 8.19A: Analiza osjetljivosti s obzirom na rizike u opskrbi

Scenarij	1	2	3	4	5	6
Nafta	1	1	1	1	1	1
Plin	2	2	3	4	3	4
El.en.	3	4	2	2	4	3
OIE	4	3	4	3	2	2
Opt. Arh.	**28**	**28**	**28**	**28**	**28**	**28**

Tablica 8.19B: Analiza osjetljivosti s obzirom na rizike u opskrbi

Scenarij	7	8	9	10	11	12
Nafta	2	2	2	2	2	2
Plin	1	1	3	4	3	4
El.en.	3	4	4	3	1	1
OIE	4	3	1	1	4	3
Opt. Arh.	**28**	**28**	**28**	**28**	**28**	**28**

Tablica 8.19C: Analiza osjetljivosti s obzirom na rizike u opskrbi

Scenarij	13	14	15	16	17	18
Nafta	3	3	3	3	3	3
Plin	1	1	2	2	4	4
El.en.	2	4	1	4	1	2
OIE	4	2	4	1	2	1
Opt. Arh.	**28**	**28**	**30**	**28**	**28**	**28**

Tablica 8.19D: Analiza osjetljivosti s obzirom na rizike u opskrbi

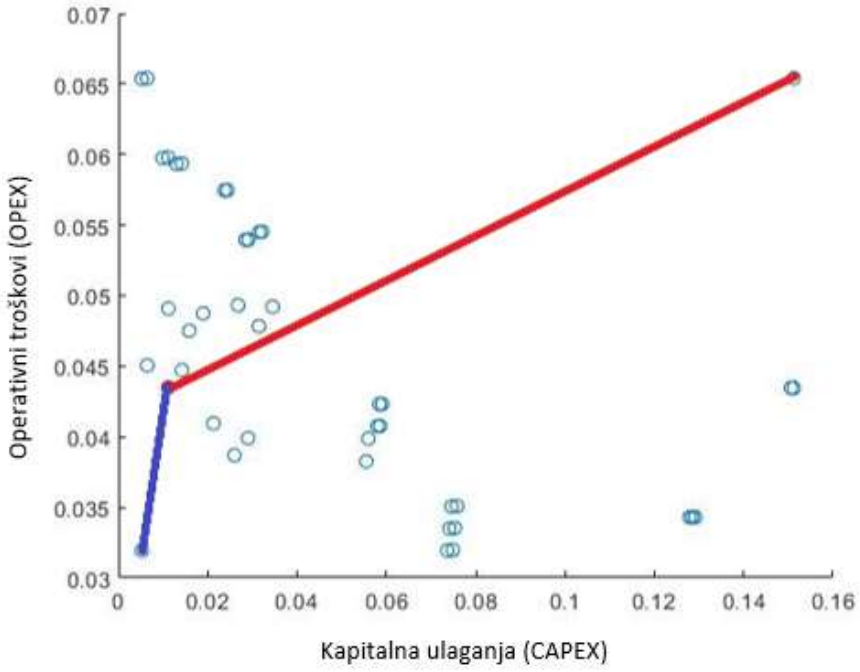
Scenarij	19	20	21	22	23	24
Nafta	4	4	4	4	4	4
Plin	1	1	2	2	3	3
El.en.	2	3	1	3	2	1
OIE	3	2	3	1	1	2
Opt. Arh.	**30**	**30**	**30**	**28**	**30**	**30**

Tablica 8.20: TOPSIS ulazna matrica za model R.H.

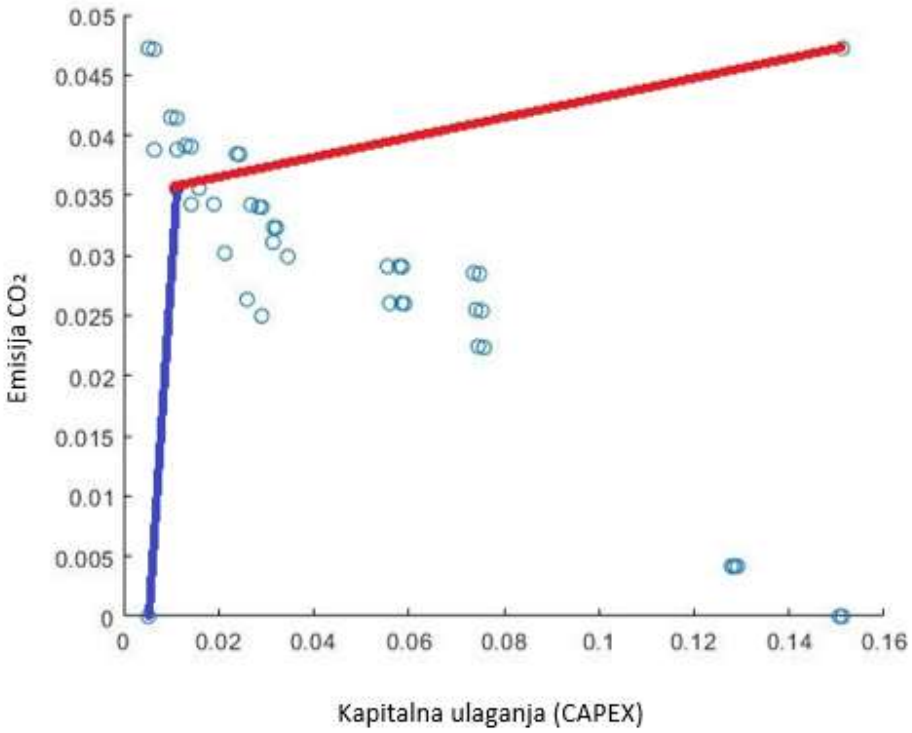
	KATEGORIJA TROŠKA	**KATEGORIJA TROŠKA**	**KATEGORIJA TROŠKA**	**KATEGORIJA BENEFICIJA**
TEŽINA	0.4	0.3	0.2	0.1
	Kapitalna ulaganja (€)	**Operativni tr. sa gorivom (€)**	**CO_2 (t)**	**Stupanj kvalitete opskrbe**
ARHITEKTURA 1	1 506 484,92	9 973 320,99	45 976	10
ARHITEKTURA 2	3 232 091,07	7 488 953,05	37 773	6
ARHITEKTURA 3	1 865 606,15	6 875 550,20	37 756	8
ARHITEKTURA 4	1 865 606,15	9 979 852,87	45 893	8
ARHITEKTURA 5	43 400 920,46	6 630 300,55	6	9
ARHITEKTURA 6	43 580 481,07	6 630 299,36	6	8
ARHITEKTURA 7	36 860 212,92	5 233 789,38	4 057	11
ARHITEKTURA 8	37 219 334,15	5 234 208,37	4 049	9
ARHITEKTURA 9	37 039 773,53	5 233 494,93	4 054	10
ARHITEKTURA 10	6 140 060,92	6 247 124,72	29 401	6
ARHITEKTURA 11	6 858 303,38	8 767 641,49	37 421	8
ARHITEKTURA 12	7 037 863,99	8 770 910,25	37 380	7
ARHITEKTURA 13	7 721 106,45	7 525 456,66	33 320	6
ARHITEKTURA 14	21 224 484,92	4 873 636,84	27 800	10
ARHITEKTURA 15	21 360 484,92	5 110 222,63	24 818	10
ARHITEKTURA 16	21 496 484,92	5 346 808,45	21 837	10
ARHITEKTURA 17	21 583 606,15	4 880 223,11	27 716	8
ARHITEKTURA 18	21 719 606,15	5 116 808,95	24 735	8
ARHITEKTURA 19	21 855 606,15	5 353 394,84	21 754	8
ARHITEKTURA 20	15 999 060,92	5 836 597,34	28 333	6
ARHITEKTURA 21	16 135 060,92	6 082 668,53	25 352	6
ARHITEKTURA 22	16 717 303,38	6 217 819,21	28 333	8
ARHITEKTURA 23	16 853 303,38	6 454 405,06	25 352	8
ARHITEKTURA 24	16 896 863,99	6 221 092,54	28 302	7
ARHITEKTURA 25	17 032 863,99	6 457 678,40	25 321	7
ARHITEKTURA 26	2 857 284,92	9 116 653,21	40 390	10
ARHITEKTURA 27	4 582 891,07	7 249 393,19	34 653	6
ARHITEKTURA 28	3 216 406,15	6 635 718,26	34 639	8

ARHITEKTURA 29	3 216 406,15	9 122 665,96	40 318	8
ARHITEKTURA 30	7 490 860,92	5 903 499,58	25 644	6
ARHITEKTURA 31	8 209 103,38	8 231 180,57	33 140	8
ARHITEKTURA 32	8 388 663,99	8 234 196,67	33 104	7
ARHITEKTURA 33	9 071 906,45	7 297 558,03	30 271	6
ARHITEKTURA 34	3 742 484,92	9 052 145,25	38 084	10
ARHITEKTURA 35	5 468 091,07	7 437 301,42	33 351	6
ARHITEKTURA 36	4 101 606,15	6 823 513,01	33 338	8
ARHITEKTURA 37	4 101 606,15	9 057 941,05	38 017	8
ARHITEKTURA 38	8 376 060,92	6 088 678,51	24 325	6
ARHITEKTURA 39	9 094 303,38	8 316 755,28	31 482	8
ARHITEKTURA 40	9 273 863,99	8 319 662,24	31 449	7
ARHITEKTURA 41	9 957 106,45	7 509 340,30	29 115	6

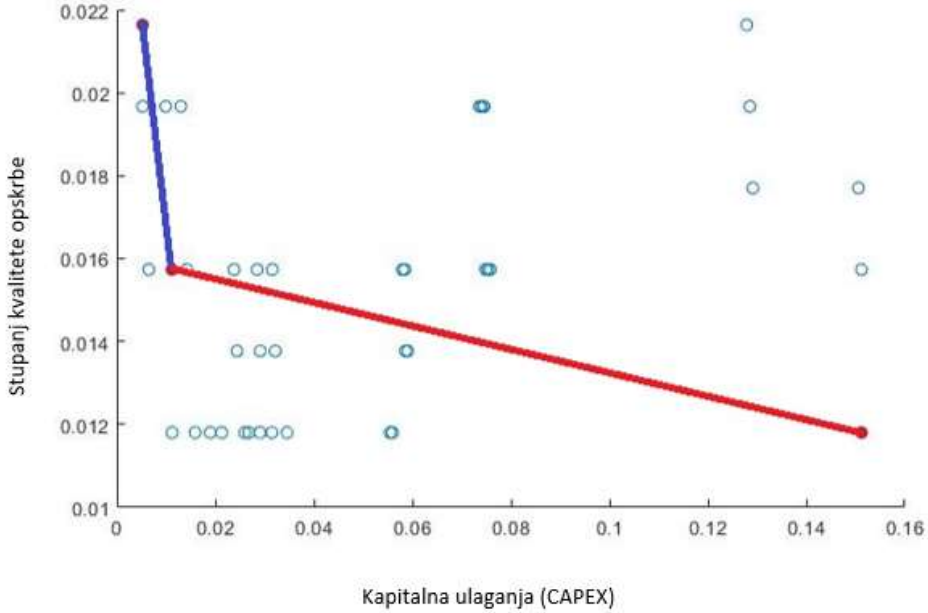
Na slikama 8.6 - 8.11 prikazani su rezultati svih arhitektura gdje središnja točka između plave i crvene linije označava globalno najbolje rješenje. Crvena boja označava udaljenost od najlošijeg rješenja, a plava boja udaljenost od najboljeg rješenja za pojedinačni slučaj.



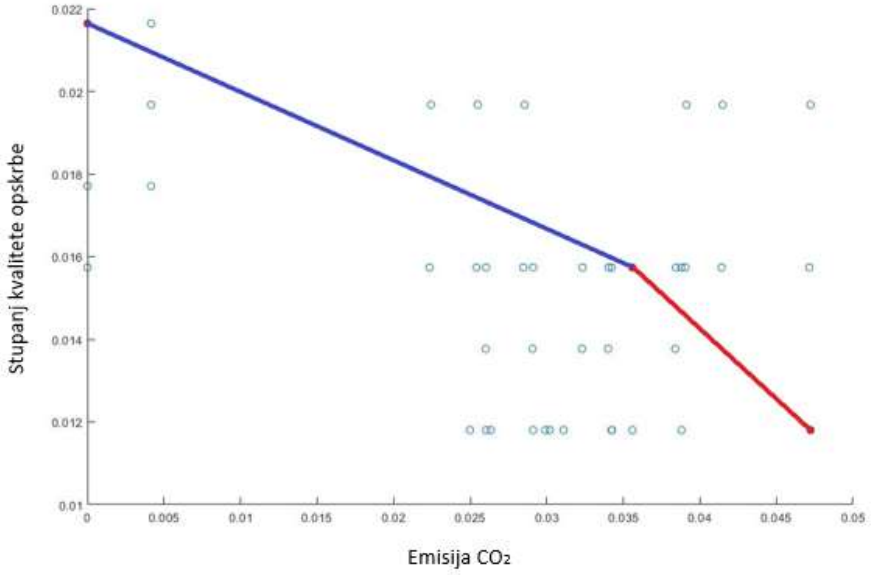
Slika 8.6: Kapitalna ulaganja i operativni troškovi



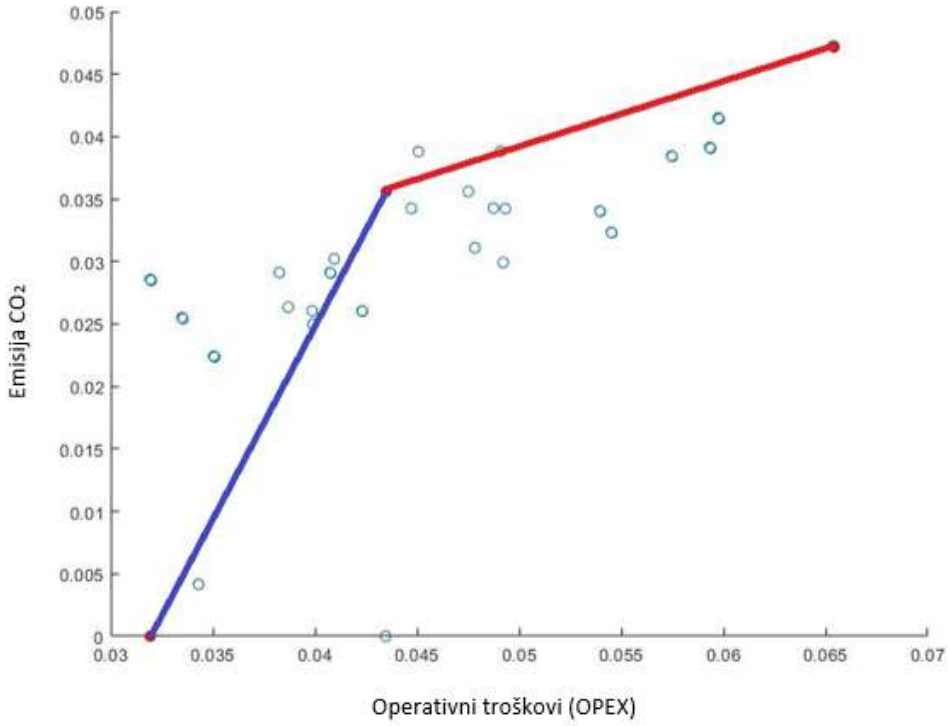
Slika 8.7: Kapitalna ulaganja i CO_2 emisije



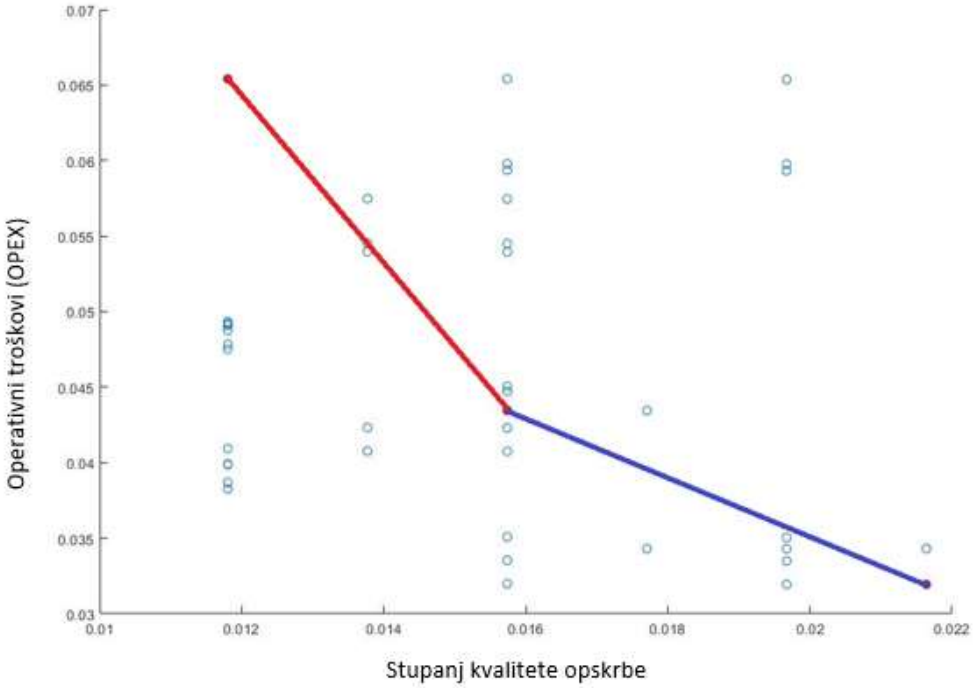
Slika 8.8: Kapitalna ulaganja i kvaliteta opskrbe



Slika 8.9: CO_2 emisije i kvaliteta opskrbe



Slika 8.10: Operativni troškovi i CO_2 emisije



Slika 8.11: Kvaliteta opskrbe i operativni troškovi

Tablica 8.21: TOPSIS rangiranje za model R.H.

	S_i^+	S_i^-	P_i	RANG
ARHITEKTURA 1	0,05788546	0,146178774	0,716337064	21
ARHITEKTURA 2	0,043946806	0,141180681	0,762613283	8
ARHITEKTURA 3	0,041377876	0,146440682	0,779692291	5
ARHITEKTURA 4	0,05812052	0,144774423	0,713543772	23
ARHITEKTURA 5	0,145852245	0,052410605	0,264349095	40
ARHITEKTURA 6	0,146539067	0,052221996	0,262737555	41
ARHITEKTURA 7	0,122745531	0,058838508	0,324029073	37
ARHITEKTURA 8	0,124052697	0,057827209	0,317941712	39
ARHITEKTURA 9	0,123383555	0,058299715	0,320886536	38
ARHITEKTURA 10	0,036713376	0,133267496	0,784014662	4
ARHITEKTURA 11	0,050079638	0,128009895	0,718795162	19

ARHITEKTURA 12	0,050560638	0,127345988	0,715802389	22
ARHITEKTURA 13	0,045106841	0,126114084	0,736557661	13
ARHITEKTURA 14	0,074151957	0,086867554	0,539484647	33
ARHITEKTURA 15	0,073486128	0,08657572	0,540889169	32
ARHITEKTURA 16	0,072978905	0,086421922	0,542167337	31
ARHITEKTURA 17	0,075475787	0,085487689	0,531099917	36
ARHITEKTURA 18	0,074834009	0,085201889	0,532392358	35
ARHITEKTURA 19	0,074348331	0,085056383	0,533587624	34
ARHITEKTURA 20	0,059255422	0,101103928	0,630483522	26
ARHITEKTURA 21	0,05842085	0,100833113	0,63315921	25
ARHITEKTURA 22	0,061186977	0,098170104	0,616038542	28
ARHITEKTURA 23	0,060454575	0,097958975	0,618374975	27
ARHITEKTURA 24	0,061932214	0,097519902	0,611593652	30
ARHITEKTURA 25	0,061215668	0,097311725	0,613848014	29
ARHITEKTURA 26	0,050198478	0,141728743	0,738450451	11
ARHITEKTURA 27	0,041469042	0,136967028	0,7675972	7
ARHITEKTURA 28	0,03832619	0,142271521	0,78778142	1
ARHITEKTURA 29	0,050598091	0,140322892	0,734978888	14
ARHITEKTURA 30	0,035593032	0,12971638	0,784688415	3
ARHITEKTURA 31	0,04709686	0,124013305	0,724757087	16
ARHITEKTURA 32	0,047675264	0,12335197	0,721241684	17
ARHITEKTURA 33	0,044771338	0,122074648	0,731660683	15
ARHITEKTURA 34	0,048413456	0,138803735	0,741404857	10
ARHITEKTURA 35	0,041726908	0,133898299	0,762409345	9
ARHITEKTURA 36	0,038097314	0,139179731	0,785097309	2
ARHITEKTURA 37	0,048912395	0,137396716	0,737466435	12
ARHITEKTURA 38	0,036771608	0,126735167	0,775106519	6
ARHITEKTURA 39	0,047773881	0,12112098	0,717138336	20
ARHITEKTURA 40	0,048386598	0,120460015	0,713428673	24
ARHITEKTURA 41	0,046354332	0,119034318	0,719724829	18

Provedenom TOPSIS analizom situacije u Republici Hrvatskoj a zasnovano na sinergijskom modelu, utvrđuje se da plinske tehnologije treba uzeti u obzir kao primarne izvore energije u podatkovnom postrojenju. Najbolje rješenje izniklo analizom je zasnovano na plinskim agregatima

kao primarnim izvorima energije a pojna mreža treba biti uzeta kao rezervno napajanje. Uz navedene izvore energije najbolje rangirana arhitektura također sadrži i sunčevu elektranu sa instaliranom snagom koja je jednaka snazi tereta.

Provedena je analiza osjetljivosti težinskih faktora ulazne matrice za TOPSIS metodu. Razvijena su 34 različita scenarija, kao što je prikazano u tablicama 8.22A – 8.22E. U svakom scenariju je iznađena optimalna arhitektura.

Tablica 8.22A: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice

Scenarij	**1**	**2**	**3**	**4**	**5**	**6**	**7**
Kapitalna ulaganja	100%	0%	0%	0%	65%	35%	50%
Operativni troškovi	0%	100%	0%	0%	35%	65%	50%
CO2	0%	0%	100%	0%	0%	0%	0%
Opskrba	0%	0%	0%	100%	0%	0%	0%
Optimalna Arhitektura	1	14	6	7	3	30	28

Tablica 8.22B: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice

Scenarij	**8**	**9**	**10**	**11**	**12**	**13**	**14**
Kapitalna ulaganja	33%	30%	10%	10%	10%	10%	10%
Operativni troškovi	33%	30%	20%	20%	30%	40%	30%
CO2	33%	30%	30%	40%	20%	20%	40%
Opskrba	0%	10%	40%	30%	40%	30%	20%
Optimalna Arhitektura	30	30	7	7	7	7	7

Tablica 8.22C: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice

Scenarij	**15**	**16**	**17**	**18**	**19**	**20**	**21**
Kapitalna ulaganja	10%	20%	20%	20%	20%	20%	20%
Operativni troškovi	40%	10%	10%	30%	40%	30%	40%
CO2	30%	30%	40%	40%	30%	10%	10%
Opskrba	20%	40%	30%	10%	10%	40%	30%
Optimalna Arhitektura	7	36	7	38	38	28	28

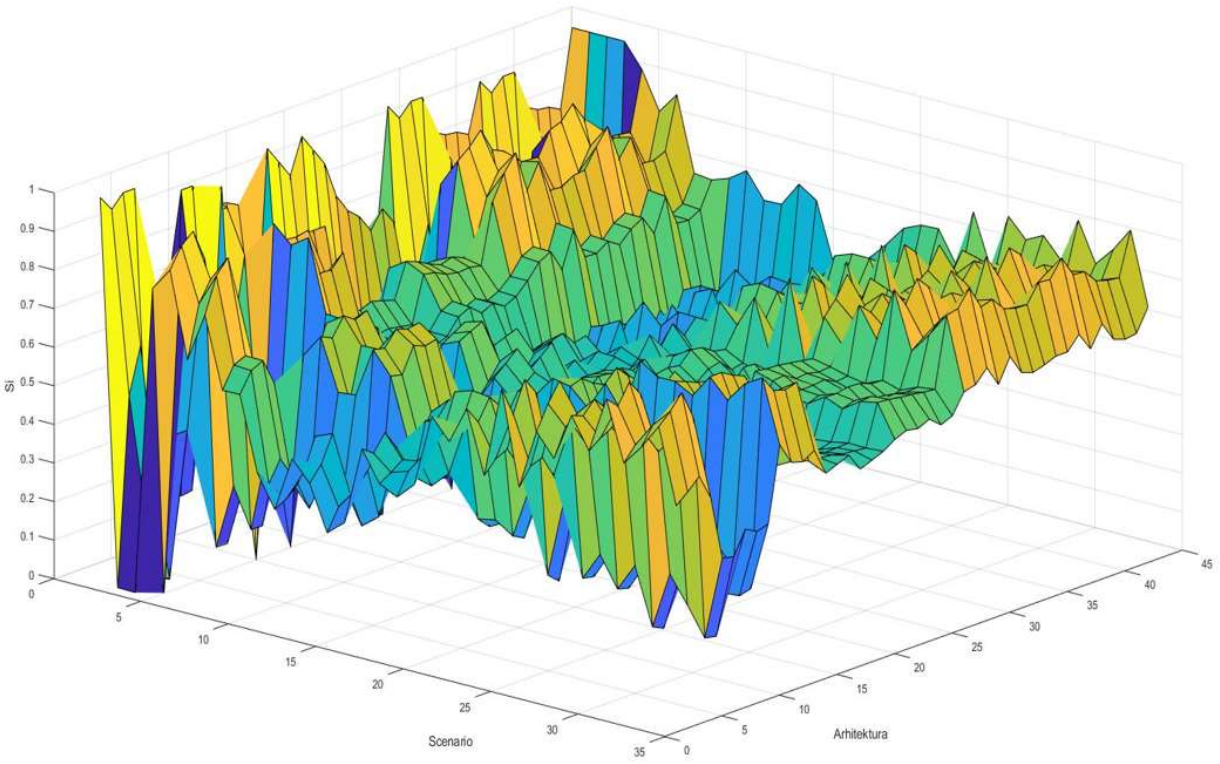
Tablica 8.22D: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice

Scenarij	**22**	**23**	**24**	**25**	**26**	**27**	**28**
Kapitalna ulaganja	30%	30%	30%	30%	30%	30%	40%
Operativni troškovi	10%	10%	20%	20%	40%	40%	10%
CO2	20%	40%	10%	40%	10%	20%	20%
Opskrba	40%	20%	40%	10%	20%	10%	30%
Optimalna Arhitektura	34	38	34	38	28	30	28

Tablica 8.22E: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice

Scenarij	**29**	**30**	**31**	**32**	**33**	**34**	
Kapitalna ulaganja	40%	40%	40%	40%	40%	25%	
Operativni troškovi	10%	20%	20%	30%	30%	25%	
CO2	30%	10%	30%	20%	10%	25%	
Opskrba	20%	30%	10%	10%	20%	25%	
Optimalna Arhitektura	30	3	30	28	28	30	

Analizom osjetljivosti, sukladno ulaznim parametrima utvrđeno je da od ponuđenih četrdeset i jedne arhitekture, njih devet mogu biti optimalne pod različitim okolnostima uvjetovanim različitom važnosti s obzirom na ulazne faktore (kapitalna ulaganja, operativne troškove, emisiju CO_2 i faktore rizika opremljena energentima), sukladno prikazu na slici 8.12.



Slika 8.12: Analiza osjetljivosti arhitektura na promjene težinskih faktora

U scenarijima 1-4 razmotrena je varijanta iznalaženja optimalnog rješenja na način da je samo jedna od četiri kategorije proglašena dominantnom odnosno važnom, modelirajući ju pri tome sa 100% važnosti što dovodi do anuliranja ostalih kategorija. U scenariju 1 kapitalna ulaganja su u fokusu te se u tom slučaju kao optimalna pokazuje Arhitektura 1. U slučaju razmatranja samo operativnih troškova optimalna je arhitektura 14. Optimalna arhitektura samo s obzirom za emisiju CO_2 je arhitektura 6. Najrobusnija je arhitektura 7.

U predmetnoj disertaciji razmatran je model u kojem se koristi 40% težine alocirane na kapitalna ulaganja (troškovi nabave opreme, instalacije u puštanja u pogon), 30% na operativne troškove (preventivno i korektivno održavanje, troškovi energenata), 20% na emisiju CO_2 i faktore rizika opskrbljena energentima 10%, sukladno scenariju 32.

9. ZAKLJUČNA RAZMATRANJA

Podatkovna i telekomunikacijska (TK) postrojenja omogućuju kvalitetu života i poslovanja diljem planeta Zemlje, no upravo zbog naglog skoka u uporabi takovih infrastruktura nameće se i potreba za podizanjem učinkovitosti iste kao i razmatranje novih načina napajanja. Glavni izazov pri dimenzioniranju i konstruiranju podatkovnog i TK postrojenja je održavanje visoke razine raspoloživosti istih, a pogotovo u sustavima najviše razine raspoloživosti, odnosno Razine 4. Postrojenja Razine 4 moraju biti konstruirana na način da imaju redundantne distributivne trase unutar samog postrojenja ali također moraju imati čak četiri izvora energije, od kojih su dva primarna a druga dva sekundarna. Spajanje na raspoloživu pojnu mrežu i uporaba paralelnih dizel agregata je metoda koja je duboko ukorijenjena danas, no ista je također izazvana obzirom da neke pojne mreže na svijetu mogu imati znatne probleme sa kapacitetom, kao što je primjer u Irskoj gdje nova podatkovna postrojenja moraju razmatrati nove tehnologije distribuirane proizvodnje električne energije na samoj lokaciji. Uz navedene izazove, a u svrhu očuvanja planeta, nužno je razmotriti povećanje učinkovitosti i smanjenje emisije stakleničkih plinova koji su posljedica napajanja istih infrastruktura.

Predmetna disertacija se bavi problematikom odlučivanja i iznalaženja optimuma u pogledu odabira prikladnih tehnologija distribuirane proizvodnje, a u svrhu minimiziranja kapitalnih i operativnih troškova, smanjenja emisije CO_2 i razmatranja rizika vezanih za opskrbu energenata. U svrhu stvaranja modela koji je primjenjiv diljem planeta te stoga univerzalan, predmetna disertacija nudi set modela koje je potrebno razmotriti u svrhu iznalaženja optimalnog rješenja sukladno navedenim kriterijima a uz zadržavanje osnovnog kriterija a to je visoka razina raspoloživosti.

Razmotrene su tehnologije napajanja iz pojne mreže, plinske tehnologije (plinske turbine, plinske mikroturbine, plinski agregati i gorive ćelije), dizel agregati i tehnologije obnovljivih izvora (sunčeve i vjetro elektrane) sa i bez uporabe spremnika energije. Za razumijevanje napajanja podatkovne i TK infrastrukture nije dovoljno se zaustaviti na razmatranju samih izvora već je nužno razumijevanje njihove interakcije i međuovisnosti. U tu svrhu, ponuđene su arhitekture koje su individualno podvrgnute evaluaciji.

Interakcija pojedinih izvora električne energije u svim ponuđenim arhitekturama je simulirana grubom Monte Carlo metodom uz uporabu uniformne razdiobe koja je korištena kao razdioba sa najvećom entropijom, što se pokazalo nužnim zbog nedostataka informacija. Tijekom simulacije razmotreni su i utjecaji na trenutnu učinkovitost pojedinog izvora što rezultira promjenjivom potrošnjom primarnih energenata ako i promjenjivom emisijom CO_2. Utjecaji takove dinamike su evidentni, no utjecaj na sveukupnu potrošnju primarnih energenata kao i emisiju CO_2 je neznatan.

Sami sustavi distribucije unutar podatkovnog postrojenja koja mogu biti zasnovana na dva razvoda: istosmjernom i izmjeničnom. Izmjenični razvod je predominantan u tehnologijama današnjice, no rezultati istraživanja ukazuju na dobrobiti uporabe istosmjernih tehnologija u pogledu razine raspoloživosti, obzirom da je nužno postojanje sustava za besprekidna napajanja u predmetnoj infrastrukturi. Evaluacija raspoloživosti sustava razvoda postignuta je uporabom metode dinamičkog stabla kvara, koja se pokazala izuzetno učinkovitom i dovoljno dobrom za uspostavu diferenciranja pojedinih arhitektura.

U predmetnoj disertaciji posebna pozornost je posvećena detaljnoj analizi hibridnih sustava sa spremnicima energije zasnovanim na baterijama. Rezultati istraživanja ukazuju na nužnost optimizacije prilikom dimenzioniranja sustava sunčeve elektrane, vjetroelektrane i spremnika energije, a uvažavajući ne samo trenutne kapacitete sunčeve energije i energije iz vjetra već i prijašnja stanja spremnika energije. Generiranje električne energije iz SE i VE je podložno stohastičkim procesima, a uvažavajući nužne kriterije o visokom stupnju raspoloživost nužno je predimenzioniranje spremnika energije što za posljedicu ima znatna kapitalna ulaganja u takov sustav. Kao dobrobit implementacije takvog sustava pokazuje se značajna redukcija emisije CO_2, no imajuću u vidu da kapitalna ulaganja kao i operativni troškovi imaju znatno veći težinski faktor u procesu odlučivanja, takov sustav se pokazuje nerentabilnim obzirom da su kapitalna ulaganja u takov sustav višestruko veće u odnosu na druge dostupne tehnologije. Unatoč tome što primjena takovog sustava evidentno nije dovoljno dobra u podatkovnoj industriji, i dalje se njezinu uporabu treba razmotriti u primjenama na postrojenjima male snage u telekomunikacijama na pristupnim točkama mobilne telefonije, a pogotovo na lokacijama s neraspoloživom gradskom mrežom kao što su npr. otoci i planinski krajolici. Nužno je za napomenuti, također, da u današnjem modelu gradska mreža se može koristiti kao spremnik energije dobivene iz obnovljivih izvora, a ukoliko to ikada prestane biti slučaj, biti će nužno ponovno razmotriti predložene modele a poštujući

novonastale kriterije, što bi u budućnosti moglo otvoriti put prema uporabi predimenzioniranih spremnika energije kao rentabilnom rješenju.

Tijekom istraživanja isprobano je nekoliko različitih metoda predviđanja vremenskih nizova gdje se smatralo da bi Holt – Winter algoritam, kao najnapredniji algoritam iz svoje porodice trebao omogućiti kvalitetno rješenje. Obzirom da su razmatrani vremenski nizovi znatno dugački, odnosno da je nužno sagledati period od deset godina sa razlučivosti od jednog sata, ispostavilo se da Holt-Winter algoritam ne omogućuje dovoljno kvalitetne rezultate u pogledu raspršenje. Nužno je bilo pronaći alternativna rješenja a kao najbolje se pokazalo uporaba neuronskih mreža.

Tijekom istraživanja, a pogotovo pri analizi raspoloživosti elektroenergetskog sustava postalo je očito kako je nužno obuhvatiti i na nekakav način kvantificirati (kvalificirati) i kriterije vezane sa opskrbu energentima. Obzirom da je glavnina istraživanja provedena za teritorij Republike Hrvatske, nužno je bilo sagledati i proizvodne kapacitete električne energije kao i emisije CO_2 alocirane na iste. Osim proizvodnje električne energije, bilance uvoza i izvoza iste, sagledani su rizici vezani za opskrbu i skladištenje rezervi drugih energenata kao što su prirodni plin i sirova nafta te njezin derivat dizelsko gorivo. Kvantificiranje takvih rizika je zahtjevno te je u tu svrhu ponuđena metoda temeljena na neizrazitoj logici. Primjena neizrazite logike se očituje u uporabi neizrazite Delphi metode. Ulazne podatke za uporabu spomenute metode generirali su temeljem svog iskustva trojica stručnjaka u danom području.

U pogledu pronalaženja najbolje metode za višekriterijsku evaluaciju pokazuje se TOPSIS metoda, obzirom da omogućuje višedimenzionalnu analizu uz uporabu težinskih faktora. Uporaba metode se pokazuje uspješnom što je potvrdila i validacija na postojećem podatkovnom postrojenju na lokaciji St. Louis u saveznoj državi Missouri u SAD-u.

Rezultati istraživanja provedenih za Republiku Hrvatsku ukazuju na veliki potencijal uporabe plinskih tehnologija a ponajviše plinskih agregata kao primarnih izvora električne energije za podatkovnu infrastrukturu Razine 4 raspoloživosti. Kao sekundarni izvor najboljom opcijom se pokazuje spajanje na pojnu mrežu a također u svrhu smanjenja emisije CO_2 kao i smanjenje operativnih troškova u pogledu kupovine energenata pokazuje se i uporaba SE instaliranog kapaciteta ne većeg od tereta.

U budućim istraživanjima, kao nadogradnja pa predmetnu disertaciju, bilo bi od velike važnosti razmotriti mogućnosti veće dinamike i interakcije podatkovne i TK infrastrukture sa pojnom mrežom u svrhu pomaganja pojnoj preži pri vršnim opterećenjima ili regulaciji frekvencije, što bi za ishod imalo i financijsku interakciju između operatera distributivnog sustava i vlasnika spomenute infrastrukture.

10. POSTIGNUTI ZNANSTVENI DOPRINOSI

Istraživanjem problema koji je postavljen u disertaciji postignuti su slijedeći izvorni znanstveni doprinosi:

1. Provedena je detaljna analiza troškova i koristi distribuiranih izvora proizvodnje električne energije sa primjenom u podatkovnim ili telekomunikacijskim postrojenjima. Analiza je zasnovana na TOPSIS metodi koja u ovom slučaju objedinjuje kapitalne i operativne troškove, emisiju CO_2 i rizike vezane za opskrbu nužnim energentima. Uspostavljen je dinamički model izvora energije koji ima izravan utjecaj na učinkovitost odnosno operativne troškove i emisiju CO_2.
2. Zasnovan je sinergijski model raspoloživosti distribuiranih izvora energije i podatkovnog ili telekomunikacijskog postrojenja. Predloženi model je robustan i sastoji se od podmodela kojima su modelirani individualni izvori ovisno s obzirom na svojstva pogona i dinamike a koji se u konačnici ugrađuju u model više hijerarhijske razine. Električne arhitekture su u cijelosti modelirane dinamičkim stablom kvara.
3. Zasnovani sinergijski model je verificiran na konkretnom postrojenju. Prikupljen je jedinstven set podataka sa detaljnim uvidom u raspoloživost napajanja podatkovnog centra Emerson u St. Louisu u saveznoj državi Missouri, SAD. Prikupljeni podaci su korišteni u predloženom modelu, te u konačnici jednoznačno verificirali model, na način da je modelirani ishod isti kao i stvarni a prije svega u tehničkoj konfiguraciji različitih izvora energije, njihovim kapitalnim ulaganjima, operativnim troškovima, emisiji CO_2 i rizicima vezanima za opskrbu energentima.

11. POPIS SLIKA

Slika 2.1: Karakteristika učinkovitosti dizel i plinskog agregata u ovisnosti o postotnom opterećenju 6
Slika 2.2: Karakteristika učinkovitosti plinske turbine u ovisnosti o postotnom opterećenju 7
Slika 2.3: Karakteristika izlazne električne snage iz vjetroagregata u ovisnosti o brzini vjetra 9
Slika 2.4: Primjer karakteristike izlazne snage iz grupe vjetroagregata tijekom perioda od 10 sati u zapadnoj Australiji, projekt kompanije ABB Ltd. 10
Slika 2.5: Prosječne cijene instaliranog kW vjetroagregata globalno na kopnu u 2016, izraženo u USD [24] 11
Slika 2.6: Prosječne cijene instaliranog kW vjetroagregata na kopnu 2010. - 2016. izražene u USD [24] 11
Slika 2.7: Prosječne cijene instaliranog kW sunčeve elektrane (fotonaponski tip) globalno na kopnu u 2016, izraženo u USD [24] 12
Slika 2.8: Prosječne cijene instaliranog kW sunčeve elektrane (fotonaponski tip) na kopnu 2010. - 2016. izražene u USD [24] 13
Slika 2.9: Karakteristika učinkovitosti plinske mikro turbine u ovisnosti o postotnom opterećenju [31] 15
Slika 2.10: Karakteristika učinkovitosti gorive ćelije u ovisnosti o postotnom opterećenju 18
Slika 2.11: Klasifikacija spremnika energije [49] 22
Slika 2.12: Klasifikacija stacionarnih baterija [10] 24
Slika 2.13: Karakteristika degradacije ciklusa PowerSafe SBS EON, VRLA tipa stacionarne baterije kompanije Enersys za primjenu u hibridnom sustavu u ovisnosti o dubini pražnjenja (%) 25
Slika 2.14: Klasifikacija hibridnih sustava 27
Slika 2.15: Model hibridnog sustava 27
Slika 2.16: Dinamika punjenja i pražnjenja spremnika energije 28
Slika 2.17: primjer dinamike proizvodnje energije iz VE i SE i utjecaj na dinamiku kapaciteta spremnika energije 29
Slika 2.18: metodologija dimenzioniranja kapaciteta spremnika energije 30

Slika 3.1: Financijska šteta uzrokovana kvarom opskrbe tereta u podatkovnoj infrastrukturi [63] 32
Slika 3.2: Uzroci neplaniranih kvarova opskrbe tereta u podatkovnoj infrastrukturi [63] 32
Slika 3.3: Ukupni troškovi za svaku minutu neplaniranog gubitka opskrbe tereta [63] 33
Slika 3.4: Tipična AC distribucijska arhitektura (iscrtkani blokovi su opcijski) [64] 33
Slika 3.5: Tipična DC distribucijska arhitektura (iscrtkani blokovi su opcijski) [64] 34
Slika 3.6 DC distribucijska arhitektura sa međusabirnicom (iscrtkani blokovi su opcijski) [64]..34
Slika 3.7: primjer dnevnog opterećenja serverskog niza.....36
Slika 3.8: Prikaz napajanja poslužitelja.....37
Slika 3.9: Istosmjerni sustav.....38
Slika 3.10: UPS sa dvojnom konverzijom 38
Slika 3.11: UPS sa dvojnom konverzijom i statičkom sklopkom.....39
Slika 3.12: UPS sa jednostrukom konverzijom.....39
Slika 3.13: Grupa UPS uređaja sa dvojnom konverzijom u paraleli.....40
Slika 4.1: Električka arhitektura Razine 1.....41
Slika 4.2: Električka arhitektura Razine 2.....42
Slika 4.3: Električka arhitektura Razine 3.....43
Slika 4.4: Električka arhitektura Razine 4.....44
Slika 5.1: Krivulja kade.....46
Slika 5.2: Raspoloživost komponente 48
Slika 5.3: Vrijeme oporavka i vrijeme popravka [67].....49
Slika 5.4: eksponencijalna razdioba 50
Slika 5.5: konstantna učestalost kvarova.....51
Slika 5.6: Prikaz Weibullove razdiobe u ovisnosti o faktoru β.....53
Slika 5.7: Funkcija gustoće vjerojatnosti uniformne razdiobe.....54
Slika 5.8: Markovljev model I logičkih vrata 56
Slika 5.9: Markovljev model ILI logičkih vrata.....57
Slika 5.10: Podjela modela vremenskih nizova [76].....63
Slika 5.11: Prikaz komponenti Holt-Winter metode [76] 64
Slika 5.12: NAR tip UNM [85].....67
Slika 5.13: NARX tip UNM [85].....68

Slika 5.14: NIO tip UNM [87] 68
Slika 5.15: Prikaz neizrazitog broja u trokutastoj funkciji pridruživanja [90] 70
Slika 5.16: Kategorije sa trokutastom funkcijom pridruživanja [88] 70
Slika 5.17: TOPSIS procedura [96] 71
Slika 6.1: Predloženi model raspoloživosti dizel agregata zasnovan na Markovljevom modelu ..76
Slika 6.2: Broj prekida opskrbe u zemljama EU-28 [102] 78
Slika 6.3: Neraspoloživost pojne mreže u izraženo u minutama godišnje u zemljama EU-28 [102] 78
Slika 6.4: DFTA segmenta proizvodnje električne energije za izmjenično zasnovanu električku arhitekturu [9] 80
Slika 6.5: Segment DFTA za distributivni dio arhitekture [9] 80
Slika 6.6: DFTA za cijelu arhitekturu [9] 81
Slika 6.7: Neraspoloživost predloženih AC i DC arhitektura izražena u milisekundama godišnje [9] 82
Slika 6.8: DFTA za model 1 83
Slika 6.9: DFTA za model 2 83
Slika 6.10: DFTA za model 3 84
Slika 6.11: Model distribuiranih izvora za Monte Carlo simulaciju dinamičkih performansi 85
Slika 6.12: Korištena uniformna razdioba za Monte Carlo simulaciju 85
Slika 6.13: Model za arhitekture 1-13 88
Slika 6.14: Model arhitekture 14-25 sa sunčevim elektranama 89
Slika 6.15: Model arhitekture 14-25 sa vjetroelektranama 89
Slika 6.16: Model arhitekture 26-33 90
Slika 6.17: Model arhitekture 34-41 90
Slika 7.1: Cijene kWh električne energije u Missouri-u tijekom godina 94
Slika 7.2: Estimirana karakteristika troškova instalirane snage vjetroelektrane u ovisnosti o veličini vjetroelektrane 97
Slika 7.3: Statistička distribucija generirane električne snage iz vjetra u Republici Hrvatskoj 98
Slika 7.4: Validacija performansi neuronske mreže 99
Slika 7.5: Prikaz odstupanja generiranih podataka u odnosu na ulazne 100
Slika 7.6: Prikaz treniranja neuronske mreže 101

Slika 7.7: Prikaz greške autokoorelacije 101
Slika 7.8: Histogram grešaka na izlazu 102
Slika 7.9: Statistička distribucija generirane električne snage iz sunca u Republici Hrvatskoj ... 103
Slika 7.10: Validacija performansi neuronske mreže 103
Slika 7.11: Prikaz odstupanja generiranih podataka u odnosu na ulazne 104
Slika 7.12: Prikaz treniranja neuronske mreže 105
Slika 7.13: Histogram grešaka na izlazu 106
Slika 7.14: Prostor mogućih rješenja za hibridni sustav – ovisnost dimenzije spremnika energije o instaliranim snagama SS i VS – najniža točka označava optimum 108
Slika 7.15: Broj baterijskih ćelija za hibridne sustave 108
Slika 7.16: Dinamika spremnika tijekom 1. simulirane godine 109
Slika 7.17: Dinamika spremnika tijekom 2. simulirane godine 110
Slika 7.18: Dinamika spremnika tijekom 3. simulirane godine 110
Slika 7.19: Dinamika spremnika tijekom 4. simulirane godine 110
Slika 7.20: Dinamika spremnika tijekom 5. simulirane godine 111
Slika 7.21: Dinamika spremnika tijekom 6. simulirane godine 111
Slika 7.22: Dinamika spremnika tijekom 7. simulirane godine 111
Slika 7.23: Dinamika spremnika tijekom 8. simulirane godine 112
Slika 7.24: Dinamika spremnika tijekom 9. simulirane godine 112
Slika 7.25: Dinamika spremnika tijekom 10. simulirane godine 112
Slika 7.26: Prikaz neizrazite (fuzzy) funkcije 115
Slika 7.27: Neraspoloživost pojne mreže u Emerson podatkovnom centru na lokaciji St. Louis 118
Slika 8.1: Prikaz rizika opskrbe naftom neizraženom logikom za R.H. 127
Slika 8.2: Prikaz rizika opskrbe plinom neizraženom logikom za R.H. 128
Slika 8.3: Prikaz rizika opskrbe električne energijom neizraženom logikom za R.H. 128
Slika 8.4: Prikaz rizika opskrbe OIE neizraženom logikom za R.H. 129
Slika 8.5: Analiza osjetljivosti s obzirom na rizike 130
Slika 8.6: Kapitalna ulaganja i operativni troškovi 133
Slika 8.7: Kapitalna ulaganja i CO_2 emisije 134
Slika 8.8: Kapitalna ulaganja i kvaliteta opskrbe 134
Slika 8.9: CO_2 emisije i kvaliteta opskrbe 135

Slika 8.10: Operativni troškovi i CO_2 emisije.....135
Slika 8.11: Kvaliteta opskrbe i operativni troškovi.....136
Slika 8.12: Analiza osjetljivosti arhitektura na promjene težinskih faktora 140

12. POPIS TABLICA

Tablica 2.1: Usporedba različitih plinskih turbina iz proizvodnog portfelja jednog od proizvođača [20] 8
Tablica 2.2: Raspoloživost elemenata vjetroturbine i udio u ukupnom trošku 10
Tablica 2.3: Pregled tehnologija fotonaponskih ćelija sa pripadajućim stupnjem djelovanja [27] 14
Tablica 2.4: Podaci mikroturbina kompanije Capstone [33] 15
Tablica 2.5: Pregled tehnologija gorivih ćelija [38] 17
Tablica 3.1: Pregled razina raspoloživosti podatkovne infrastrukture [62] 31
Tablica 3.2: Usporedba aspekata pouzdanosti, učinkovitosti i mogućnosti za spajanje tehnologija u usponu radi potpore stvaranju električne energije na lokaciji i pohrani električne energije, između AC i DC energetskih distribucija [64] 35
Tablica 5.1: Matematički odnosi između kvarova, pouzdanosti, funkcija gustoće i učestalosti kvara 45
Tablica 5.2: Broj *devetki* i korespondirajući vrijeme neraspoloživosti u jednoj godini 48
Tablica 5.3: Vrste razdioba 50
Tablica 6.1: Predložene konfiguracije fotonaponskih panela modelirane SE 74
Tablica 6.2: Prekapacitiranost grupe vjetroagregata u svrhu postizanja tražene razine raspoloživosti 75
Tablica 6.3: Indikatori raspoloživosti dizel agregata [101] 76
Tablica 6.4: Indikatori raspoloživosti plinskih agregata [101] 77
Tablica 6.5: Predložene arhitekture 86
Tablica 7.1: Cijene električne energije izražene u EUR / kWh za industrijske korisnike [103] 93
Tablica 7.2: Kretanje cijena plina u Missouri-u izražena u USD za m^3 [107] 95
Tablica 7.3: Faktori pretvorbe iz EUR u USD [109] 96
Tablica 7.4: Cijena instaliranog kW vjetroagregata pretvoreno iz USD u EUR 96
Tablica 7.5: Moguća rješenja hibridnog sustava 107
Tablica 7.6: Prikaz godišnje proizvodnje električne energije iz optimiziranog hibridnog rješenja 109
Tablica 7.7: Ulazni podaci 1, neizrazita Delphi ulazna matrica 114
Tablica 7.8: Ulazni podaci 2, neizrazita Delphi ulazna matrica 114

Tablica 7.9: Ulazni podaci 3, neizrazita Delphi ulazna matrica.....114
Tablica 7.10: Učinkovitost plinskih agregata i gorivih ćelija pri 100% opterećenja u standardnoj konfiguraciji 116
Tablica 7.11: Učinkovitost plinskih agregata i gorivih ćelija pri 100% opterećenja u konfiguraciji sa 1MW SE.....116
Tablica 7.12: Učinkovitost plinskih agregata i gorivih ćelija pri 100% opterećenja u konfiguraciji sa 1 MW VE.....116
Tablica 7.13: Učinkovitost plinskih agregata i gorivih ćelija pri 50% opterećenja u standardnoj konfiguraciji 116
Tablica 7.14: Učinkovitost plinskih agregata i gorivih ćelija pri 50% opterećenja u konfiguraciji sa 1MW SE.....116
Tablica 7.15: Učinkovitost plinskih agregata i gorivih ćelija pri 50% opterećenja u konfiguraciji sa 1MW VE.....116
Tablica 7.16: Podaci o nestanku napajanja iz pojne mreže u Emerson podatkovnom postrojenju 117
Tablica 7.17: Osnovni podaci o tehničkim svojstvima SE u Emerson podatkovnom postrojenju 118
Tablica 7.18: Podaci o prosječnoj sunčevoj radijaciji i proizvodnji električne energije.....119
Tablica 7.19: Razmatrane arhitekture za validacijski model 120
Tablica 8.1: Združena matrica odlučivanja za validacijski model 121
Tablica 8.2: Normirana neizrazita matrica odlučivanja za validacijski model 121
Tablica 8.3: Težinska normirana neizražena matrica odlučivanja za validacijski model 122
Tablica 8.4: Udaljenost od najboljeg rješenja za validacijski model 122
Tablica 8.5: Udaljenost od najlošijeg rješenja za validacijski model 122
Tablica 8.6: Rangiranje za validacijski model 122
Tablica 8.7: TOPSIS ulazna matrica za validacijski model 123
Tablica 8.8: TOPSIS normirana matrica za validacijski model 123
Tablica 8.9: TOPSIS normirana težinska matrica za validacijski model 124
Tablica 8.10: TOPSIS udaljenosti za validacijski model 124
Tablica 8.11: TOPSIS rangiranje za validacijski model 125
Tablica 8.12: Združena matrica odlučivanja 126

Tablica 8.13: Združena matrica odlučivanja 126
Tablica 8.14: Normirana neizrazita matrica odlučivanja 126
Tablica 8.15: Težinska normirana neizrazita matrica odlučivanja 127
Tablica 8.16: Udaljenost od najboljeg rješenja za model R.H. 129
Tablica 8.17: Udaljenost od najlošijeg rješenja za model R.H. 129
Tablica 8.18: Rangiranje za model R.H. 130
Tablica 8.19A: Analiza osjetljivosti s obzirom na rizike u opskrbi 131
Tablica 8.19B: Analiza osjetljivosti s obzirom na rizike u opskrbi 131
Tablica 8.19C: Analiza osjetljivosti s obzirom na rizike u opskrbi 131
Tablica 8.19D: Analiza osjetljivosti s obzirom na rizike u opskrbi 131
Tablica 8.20: TOPSIS ulazna matrica za model R.H. 132
Tablica 8.21: TOPSIS rangiranje za model R.H. 136
Tablica 8.22A: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice 138
Tablica 8.22B: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice 138
Tablica 8.22C: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice 139
Tablica 8.22D: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice 139
Tablica 8.22E: Analiza osjetljivosti pronalaska optimalne arhitekture promjenom težinskih faktora TOPSIS ulazne matrice 139

13. POPIS LITERATURE

[1] L. Dittmar, M. Schaefer, “Electricity demand modeling of German data centers: dealing with uncertainties,” Schriftenreihe Innovationszentrum Energie, no. Band 1, Technische Universität Berlin Innovationszentrum Energie, 2009.

[2] M. Steen, Greenhouse Gas Emissions from Fossil Fuel Fired Power Generation Systems, European Commission Joint Research Centre (DG JRC) Institute for Advanced Materials, 2017

[3] S.U. Khan and C. Ardil, “On the joint optimization of performance and power consumption in data centers,” *World Acad. Sci. Eng. Technol.*, vol. 56, no. 3, pp. 660–666, 2009.

[4] G. Poncelin, J. Derain, A. Cauvin and D. Dufrene, "Development of a design-for-reliability method for complex systems," *2008 Annual Reliability and Maintainability Symposium*, Las Vegas, NV, 2008, pp. 175-180.

[5] D. Talapko, “Telecom datacenter power infrastructure availability comparison of DC and AC UPS,” *INTELEC, Int. Telecommun. Energy Conf.*, pp. 0–4, 2012.

[6] D. Talapko, S. Tesnjak, “Influence of solar and wind power generation sources on power supply availability in telecom infrastructure,” *INTELEC, Int. Telecommun. Energy Conf.*, vol. 2014-January, no. January, 2014.

[7] D. Talapko, S. Tesnjak, “Influence of distributed power generation sources on improvement of power supply availability in telecom infrastructure,” *12th IET Int. Conf. Dev. Power Syst. Prot. DPSP 2014*, pp. 1–5, 2014.

[8] D. Talapko, S. Tesnjak, “Influence of availability on the cost analysis of solar powered data centers with AC and DC architecture and mirroring functionality,” *INTELEC, Int. Telecommun. Energy Conf.*, vol. 2016-September, 2016.

[9] D. Talapko, S. Tesnjak, and H. Glavas, “Comparison of Electrical Architectures for Support of the Software Defined Data Centers,” *Proc. Int. Conf. Smart Syst. Technol. 2018, SST 2018*, no. 6, pp. 179–184, 2018.

[10] D. Talapko, S. Tesnjak, H. Glavas, “Impact of Maintenance on Solar and Wind Powered Internet Data Center Electrical Infrastructure Availability,” *27th Int. Sci. Prof. Conf. "Organization Maint. Technol.*, pp. 87–95, 2018.

[11] S. Ericson and D. Olis, “A Comparison of Fuel Choice for Backup Generators,” *Natl. Renew. Energy Lab. Tech. Rep. NREL/TP-6A50-72509*, no. March, p. 59, 2019.

[12] K. Darrow and B. Hedman, „*Opportunities for Combined Heat and Power in Data Centers“*, ICF International, Report for Oak Ridge National Laboratory Subcontract Number: 4000021512, September. 2009.

[13] T. Loehlein: “Maintenance is one key to diesel generator set reliability” published on October 4, 2013 in Latest EPSS News, 2013 http://mgisys.com/maintenance-one-key-diesel-generator-set-reliability/

[14] R. Miller. “The Year in Downtime: Top 10 Outages of 2012”, Data Center Knowledge, web published, (3. srpanj 2013.), dostupno na: http://www.datacenterknowledge.com/archives/2012/12/17/the-year-in-downtime-top-10-outages-of-2012/

[15] Uptime Institute Professional Services, „Data Center Site Infrastructure Tier Standard: Topology“, Uptime Institute, LLC, 20 West 37th Street - 6th FloorNew York, NY 10018, 2012

[16] Y. M. A. Welaya, M. M. El Gohary, and N. R. Ammar, “A comparison between fuel cells and other alternatives for marine electric power generation,” *Int. J. Nav. Archit. Ocean Eng.*, vol. 3, no. 2, pp. 141–149, 2011.

[17] CAT plinski agregati, (3. listopad 2019.) dostupno na: https://www.cat.com/en_AU/news/engine-press-releases/cg132b-natural-gas-generator-set-delivers-highest-efficiency-in-output-category.html

[18] K. Ishida, „Small and Medium Size Gas Turbines“, Gas Turbine Technology in Japan, Bulletin of GTSJ 2003

[19] K.A.B. Pathirathna, „Gas Turbine Thermodynamic and Performance Analysis Methods Using Available Catalog Data“, Master's Thesis in Sustainable Energy Engineering, Faculty of Engineering and Sustainable Development, University of Galve, 2013

[20] U.S. Department of Energy, „Combined Heat and Power Technology Fact Sheet Series“, U.S. Department of Energy, DOE/EE-1330, July 2016

[21] P. Giorsetto and K. F. Utsurogi, "Development of a new procedure for reliability modeling of wind turbine generators", IEEE Transactions on Power Apparatus and Systems, Vol. PAS-102, No. 1, 1983, pp.134-143.

[22] Topić, D., Šljivac, D., Stojkov, M., „Availability of Different Wind Power Plant Configurations Based on Components Performance Statistics“, International Review of Electrical Engineering 10(3):414-420, June 2015

[23] Lee, J.K., Park, J.Y., Oh, K.Y., Ju, S., Lee, J.S., „Transformation algorithm of wind turbine blade moment signals for blade condition monitoring“, Renewable Energy, 79, 209-218. 10.1016/j.renene.2014.11.030, 2015

[24] IRENA, „Renewable Power Generation Costs in 2017“, International Renewable Energy Agency, Abu Dhabi, 2018

[25] Carroll J, May A, McDonald A, McMillan D., „Availability Improvements From Condition Monitoring Systems and Performance Based Maintenance Contracts“, Copenhagen. EWEA Offshore 2015

[26] A. Goetzberger, V.U. Hoffmann, "Photovoltaic Solar Energy Generation," Springer Series in Applied Science, 2005.

[27] Wengenmayr, R., Bührke, T., "Renewable Energy, Solar Cells – an Overview", WILEY-VCH Verlag GmbH & Co. KgaA, Weinheim, pp. 34-40, 2008

[28] J. C. Bruno, L. Massagués, and A. Coronas, “Power Quality and Air Emission Tests in a Micro Gas Turbine Cogeneration Plant,” *Renew. Energy Power Qual. J.*, vol. 1, no. 01, pp. 502–506, 2017.

[29] M.A.R. Do Nascimento, L.D.O. Rodrigues, E.E.B.G.E.C. Dos Santos, F.L.G. Dias, E.I.G. Velásques, and R.a M. Carrillo, „Micro Gas Turbine Engine: A Review, Progress in Gas Turbine Performance”, Ernesto Benini, IntechOpen, DOI: 10.5772/54444. Available from: https://www.intechopen.com/books/progress-in-gas-turbine-performance/micro-gas-turbine-engine-a-review, 2013.

[30] B. Peters, K. Dielmann, "Capstone Microturbines: Experiences with Different Gaseous and Liquid Fuels". Workshop on Energy Efficiency & Emissions Reduction with Micro Gas Turbines - Technology and Operating Experience, October, 22nd, Tarragona, 2002.

[31] Capstone: „Capstone C200 Microturbine Technical Reference“, 410066 Rev C, Capstone, 2009

[32] Shah, Y.T., „Thermal Energy – Sources, Recovery and Applications“, CRC Press, Taylor / Francis Group, Boca Ranton, Florida, USA, 2018

[33] K. Darrow, R. Tidball, J. Wang, A. Hampson: „Catalog of CHP Technologies, Section 5. Technology Characterization – Microturbines“, ICF International, U.S. Environmental Protection AgencyCombined Heat and Power Partnership, 2015

[34] F. Leccese, „Fuel Cells: Technologies and Applications“ The Open Fuel Cells Journal. 6. 1-20. 10.2174/1875932720130719001, 2013

[35] Y. Sahli, B. Zitouni, and H. Ben-moussa, “Solid Oxide Fuel Cell Thermodynamic Study,” Çankaya University Journal of Science and Engineering, vol. 14, no. 2, pp. 134–151, 2017.

[36] Y. M. A. Welaya, M. M. El Gohary, and N. R. Ammar, “A comparison between fuel cells and other alternatives for marine electric power generation,” *Int. J. Nav. Archit. Ocean Eng.*, vol. 3, no. 2, pp. 141–149, 2011.

[37] S. Curtin and J. Gangi, “The Business Case for Fuel Cells 2013: Reliability, Resiliency & Savings,” *Fuel Cells 2000 - Breakthr. Technol. Inst.*, 2013.

[38] Weidner, E.Ortiz Cebolla, R.Davies, J., „Global deployment of large capacity stationary fuel cells“, joint Research Centre (JRC), the European Commission’s science and knowledge service, doi:10.2760/372263

[39] M. Ajmal.A, N. N, and Y. R, “Bloom Box,” *Int. J. Eng. Trends Technol.*, vol. 67, no. 3, pp. 85–89, 2019.

[40] Leah, R., Bone, A., Lankin, M., Selcuk, A., Rahman, M., Clare, A., Rees, L., Phillip, S. Mukerjee, S., Selby, M.., „Ceres Power Steel Cell Technology: Rapid Progress Towards a Truly Commercially Viable SOFC“ ECS Transactions. 68. 95-107. 10.1149/06801.0095ecst., 2015

[41] G. Schiller, “Progress in Metal-Supported Solid Oxide Fuel Cells”, International Symposium on Energy Materials: Opportunities and Challenges (ISEM-2011), Kolkata, India, March 1-2, 2011

[42] International Energy Agency: “Renewable Energy Essentials: Hydropower”, web published 2010
http://www.iea.org/publications/freepublications/publication/Hydropower_Essentials.pdf

[43] M. Majumder, S. Ghosh: “Decision Making Algorithms for Hydro-Power”, Plant Location, SpringerBriefs in Energy, DOI: 10.1007/978-981-4451-63-5_2, 2013

[44] A. R. Majeed, N. M. Sadiq: “Availability & Reliability Evaluation of Dokan Hydro Power Station”. Transmission & Distribution Conference and Exposition: Latin America, 2006. TDC'06. IEEE/PES. IEEE, pp. 1-6, 2006

[45] F. Munteanu, C. Nemes: “The Maintenance Strategies Influence on the Reliability of Power Plant Generating Units”, Optimization of Electrical and Electronic Equipment (OPTIM), 2012 13th International Conference on. Date 24-26 May 2012. pp. 103-108, 2012

[46] A. Kagel, D. Bates, K. Gawell: “A Guide to Geothermal Energy and the Environment”, Geothermal Energy Association, Washington, D.C., USA 2007

[47] M. Gehringer, V. Loksha: “Geothermal Handbook: Planning and Financing Power Generation”, Energy Sector Management Assistance Program (ESMAP), Technical Report

002/12, The International Bank for Reconstruction And Development / The World Bank Group, USA, 2012

[48] H. Legmann, D. Citrin: “First twelve months of operation of The 60 MW Mokai Geothermal Project A High Pressure, Sustainable and Environmentally Benign Power Plant”, Proceeding of the 5th INAGA Annual Scientific Conference & Exhibitions, 2001

[49] H. Zhao, Q. Wu, S. Hu, H. Xu, C.N. Rasmussen: “Review of energy storage system for wind power integration support”, Elsavier, Applied Energy Volume 137, Pages 545-553, 2015

[50] P. Deane, B.Ó Gallachóir: “Pumped Hydro Energy Storage”, Wiley Online Library, 2015, https://doi.org/10.1002/9781118991978.hces137

[51] Li, Li & Liang, Weiguo & Lian, Haojie & Yang, Jianfeng & Dusseault, Maurice. (2018). Compressed air energy storage: characteristics, basic principles, and geological considerations. ADVANCES IN GEO-ENERGY RESEARCH. 2. 10.26804/ager.2018.02.03.

[52] Aljohani, Tawfiq. (2014). The Flywheel Energy Storage System: A Conceptual Study, Design, and Applications in Modern Power Systems. International Journal of Electrical Energy. 10.12720/ijoee.2.2.146-153.

[53] Zaman, Md. Abdullah & Ahmed, Sabbir & Monira, Nusrath. (2018). An overview of Superconducting Magnetic Energy Storage (SMES) and Its Applications.

[54] Aljanad, Ahmed & Omar, Rosmaria & Rasheed, Mohanad & Ahmed, Azhar. (2013). Comparative study of super capacitor and battery as storage energy in three phase system. 118-123. 10.1109/CEAT.2013.6775611.

[55] M. C. Kocer *et al.*, “Assessment of battery storage technologies for a Turkish power network,” *Sustain.*, vol. 11, no. 13, 2019.

[56] D. Akinyele, J. Belikov, and Y. Levron, “Battery storage technologies for electrical applications: Impact in stand-alone photovoltaic systems,” *Energies*, vol. 10, no. 11, pp. 1–39, 2017.

[57] G.J. May, A. Davidson, B. Monahov, "Lead batteries for utility energy storage: A review," *J. Energy Storage*, vol. 15, pp. 145–157, 2018.

[58] H. Keshan, J. Thornburg, T. S. Ustun, "Comparison of lead-Acid and lithium ion batteries for stationary storage in off-grid energy systems," *IET Conf. Publ.*, vol. 2016, no. CP688, pp. 1–7, 2016.

[59] S. Anuphappharadorn, S. Sukchai, C. Sirisamphanwong, N. Ketjoy, "Comparison the economic analysis of the battery between lithium-ion and lead-acid in PV stand-alone application," *Energy Procedia*, vol. 56, no. C, pp. 352–358, 2014.

[60] B. Banerjee, „Feasibility of Utility-Provided Telecommunication Applications - Final Report", EPRI, November 2001

[61] M. Pehnt, M. Cames, C. Fischer, B. Praetorius, L. Schneider, K. Schumacher, J.P. Voß: „Micro Cogeneration, Towards Decentralized Energy Systems", Springer-Verlag, Berlin, Heidelberg, 2006

[62] B. Fortenbery, "Power Quality in Interned Data Centers", EPRI, Power Quality Knowledge Program, 2007

[63] Ponemone Institute: Cost of Data Center Outages, Ponemon Institute, Traverse City, Michigan, SAD, 2016

[64] E.C.W. de Jong, P.T.M. Vaessen, "DC power distribution for server farms", Leonardo ENERGY, KEMA Consulting, 2007

[65] M. Rausand, "System Reliability Theory – Models, Statistical Methods, and Applications, 2nd Edition", John Wiley & Sons, Inc., New Jersey, USA, 2004.

[66] R.K. Mobley, "Maintenance Fundamentals, 2nd Edition", Elsevier Butterworth–Heinemann, ISBN: 0-7506-7798-8, USA, 2004

[67] B. Christiansen," MTTR, MTBF, or MTTF? – A Simple Guide To Failure Metrics", dostupno na https://limblecmms.com/blog/mttr-mtbf-mttf-guide-to-failure-metrics/ (17.08.2019.)

[68] D. Šljivac, "Vjerojatnosna analiza troškova prekida opskrbe električnom energijom," *Doktorska Disertacija, Sveučilište u Zagrebu, Fakultet Elektrotehnike i računarstva*, 2005.

[69] F. Arnold, A. Belinfante, F. Van Der Berg, D. Guck, and M. Stoelinga, "DFTCalc: A tool for efficient fault tree analysis," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 8153 LNCS, pp. 293–301, 2013.

[70] K. Durga Rao, V. Gopika, V.V.S. Sanyasi Rao, H.S. Kushwaha, A.K. Verma, A. Srividya, "Dynamic fault tree analysis using Monte Carlo simulation in probabilistic safety assessment," *Reliab. Eng. Syst. Saf.*, vol. 94, no. 4, pp. 872–883, 2009.

[71] D. Codetta-Raiteri, "Extended Fault Trees Analysis supported by Stochastic Petri Nets," *Citeseer*, 2005.

[72] P. Zhu, J. Han, L. Liu, and M. J. Zuo, "A stochastic approach for the analysis of fault trees with priority and gates," *IEEE Trans. Reliab.*, vol. 63, no. 2, pp. 480–494, 2014.

[73] Y. F. Li, H. Z. Huang, Y. Liu, N. Xiao, and H. Li, "A new fault tree analysis method: Fuzzy dynamic fault tree analysis," *Eksploat. i Niezawodn.*, vol. 14, no. 3, pp. 208–214, 2012.

[74] X. Meng, S. Wang, "Optimal Research of Equipment Maintenance Interval Based on Monte-Carlo Simulation," 4th International Conference on Mechatronics, Materials, Chemistry and Computer Engineering (ICMMCCE 2015), pp. 1628–1632, 2015.

[75] T.M. Cover, J.A. Thomas, „Elements of Information Theory", Second Edition, John Wiley & Sons, Inc., SAD, 2006

[76] V. Yakovyna and O. Bachka, "The comparison of holt – winters and box – jenkins methods for software failures prediction," *CEUR Workshop Proc.*, vol. 2136, pp. 90–98, 2018.

[77] K.D. Makatjane, N.D. Moroke, "Comparative study of holt-winters triple exponential smoothing and seasonal arima: Forecasting short term seasonal car sales in South Africa," *Risk Gov. Control Financ. Mark. Institutions*, vol. 6, no. 1, pp. 71–82, 2016.

[78] E. y Stellwagen, L. Tashman, "ARIMA : The Models of Box and Jenkins," . *Foresight Int. J. Appl. Forecast.*, no. 30, pp. 28–34, 2013.

[79] F. Chen, F. Ding, „Recursive Least Squares Identification Algorithm for Multiple-Input Nonlinear Box-Jenkins Systems Using Maximum Likelihood Principle“, Journal of Computational and Nonlinear Dynamics, 2015

[80] Y.A. Al-sbou, K. M. Alawasa, “Nonlinear Autoregressive Recurrent Neural Network Model For Solar Radiation Prediction,” *Int. J. Appl. Eng. Res.*, vol. 12, no. 14, pp. 4518–4527, 2017.

[81] K.A. Baharin, H.A. Rahman, M.Y. Hassan, G.C. Kim, “Hourly irradiance forecasting for Peninsular Malaysia using dynamic neural network with preprocessed data,” *Proceeding - 2013 IEEE Student Conf. Res. Dev. SCOReD 2013*, no. December, pp. 191–197, 2013.

[82] S. Karasu, A. Altan, Z. Sarac, R. Hacioglu, “Rüzgâr Hizinin Doğrusal Olmayan Otoregresif Sinir Ağlari ile Tahmini,” *2017 25th Signal Process. Commun. Appl. Conf. SIU 2017*, pp. 2–5, 2017.

[83] A. Ruhan, G. Cheng, “The Application of NAR Dynamical Neural Network on Quantitative Investment,” *Proc. 2018 2nd IEEE Adv. Inf. Manag. Commun. Electron. Autom. Control Conf. IMCEC 2018*, no. Imcec, pp. 2671–2674, 2018.

[84] Y. Pan, J. Zheng, Y. Yang, R. Zhu, C. Zhou, T. Shi, “An Electricity Load Forecasting Approach Combining DBN-Based Deep Neural Network and NAR Model for the Integrated Energy Systems,” *2019 IEEE Int. Conf. Big Data Smart Comput. BigComp 2019 - Proc.*, pp. 1–4, 2019.

[85] L. Ruiz, M. Cuéllar, M. Calvo-Flores, M. Jiménez, “An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings,” *Energies*, vol. 9, no. 9, p. 684, 2016.

[86] Z. Boussaada, O. Curea, A. Remaci, H. Camblong, N. M. Bellaaj, “A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation,” *Energies*, vol. 11, no. 3, 2018.

[87] O.O. Philip, B.T. Adeleke, “Predictive and Comparative Analysis of NARX and NIO Time Series Prediction,” *Am. J. Eng. Res.*, vol. 6, no. 9, pp. 155–165, 2017.

[88] R. Rojas, „Neural Networks“, Springer-Verlag, Berlin, 1996

[89] P.V.S. Reddy, “Fuzzy risk sets for decision making,” *iFUZZY 2014 - 2014 Int. Conf. Fuzzy Theory Its Appl. Conf. Dig.*, no. x, pp. 128–131, 2014.

[90] A. Nagoor Gani and S. N. Mohamed Assarudeen, “A new operation on triangular fuzzy number for solving fuzzy linear programming problem,” *Appl. Math. Sci.*, vol. 6, no. 9–12, pp. 525–532, 2012.

[91] P.T. Chang, L.C. Huang, H.J. Lin, „The fuzzy Delphi method via fuzzy statistics and membership function fitting and an application to the human resources“, Fuzzy Sets and Systems 112:511-520, 2000

[92] Murray TJ, Pipino LL, JP van Gigch, „A pilot study of fuzzy set modification of Delphi“, Human Systems Mgmt.5: 76-80, 1985

[93] R.J. Kuo, „A decision support system for the stock market through integration of fuzzy neural networks and fuzzy Delphi“, Applied Artificial Intelligence 12:511-520, 1998

[94] D. Wang, Y. Lu, J. Gan, “An Information Security Evaluation Method Based on Entropy Theory and Improved TOPSIS,” *Proc. - 2017 IEEE 2nd Int. Conf. Data Sci. Cyberspace, DSC 2017*, pp. 595–600, 2017.

[95] S. Bandyopadhyay, “Multi-Criteria Decision Making,” *Evol. Algorithms Solving Multi-Objective Probl.*, no. Li, pp. 515–545, 2007.

[96] M. Panda and A. K. Jagadev, “TOPSIS in Multi-Criteria Decision Making: A Survey,” *Proc. - 2nd Int. Conf. Data Sci. Bus. Anal. ICDSBA 2018*, pp. 51–54, 2018.

[97] Z. Pavić and V. Novoselac, “Notes on TOPSIS Method,” *Int. J. Res. Eng. Sci.*, vol. 1, no. 2, pp. 5–12, 2013.

[98] A. Realini, E. Bura´, N. Cereghetti, D. Chianese, S. Rezzonico, “Study of 20-year old PV plant (MTBF Project) ”, 17th EPVSEC, Munich, Germany, 2001.

[99] M. Vasquez, I. Rey-Stolle, "Photovoltaic module reliability model based on field degradation studies, Progress in Photovoltaics: Research and Applications", Volume 16, Issue 5, pages 419–433, John Wiley & Sons, Ltd., August 2008

[100] A. Realini, "MTBF – PVm Mean Time Before Failure of Photovoltaic Modules", Federal Office for Education and Science BBW, Final report BBW 99.0579, June 2003

[101] Department of Defense USA: "Military Handbook: Reliability Prediction of Electronic Equipment", MIL-HDBK-217F Notice 2, 1995

[102] Council of European Energy Regulators: "6th CEER Benchmarking Report on the Quality of Electricity and Gas Supply", CEER, Brussels, Belgium, 2016

[103] EUROSTAT, (30. kolovoz 2019.) cijene električne energije, dostupno na: http://ec.europa.eu/eurostat/statistics-explained/index.php?title=Electricity_price_statistics

[104] A. Moro and L. Lonza, "Electricity carbon intensity in European Member States: Impacts on GHG emissions of electric vehicles," *Transp. Res. Part D Transp. Environ.*, vol. 64, no. July 2017, pp. 5–14, 2018.

[105] HOMER, (18. kolovoza 2019.) dostupno na: https://www.homerenergy.com/products/pro/docs/latest/finding_data_to_run_homer.html

[106] EUROSTAT, (30. kolovoza 2019.) cijena prirodnog plina, dostupno na: http://appsso.eurostat.ec.europa.eu/nui/show.do?query=BOOKMARK_DS-052778_QID_4D2C7138_UID_-3F171EB0&layout=TIME,C,X,0;GEO,L,Y,0;PRODUCT,L,Z,0;CONSOM,L,Z,1;UNIT,L,Z,2;TAX,L,Z,3;CURRENCY,L,Z,4;INDICATORS,C,Z,5;

[107] EIA, (29. kolovoz 2019.) cijena plina u Missouri-u, dostupno na: https://www.eia.gov/dnav/ng/hist/n3035mo3m.htm

[108] EIA, (4. rujan 2019.) cijana dizelskog goriva u SAD-u, dostupno na: https://www.eia.gov/dnav/pet/hist/LeafHandler.ashx?n=pet&s=emd_epd2d_pte_nus_dpg&f=m

[109] STATISTA, (5. rujan 2019.) faktori pretvorbe EUR/USD na godišnjoj razini, dostupno na: https://www.statista.com/statistics/412794/euro-to-u-s-dollar-annual-average-exchange-rate/

[110] MZOE, „Povjerenstva za izradu Strategije energetskog razvoja Republike Hrvatske do 2030. s pogledom do 2050.: Nacrt prijedloga Strategije energetskog razvoja Republike Hrvatske do 2030. s pogledom na 2050. godinu“, Ministarstvo zaštite okoliša i energetike RH. 2019.

[111] F. Đedović, M. Svjetličić, R. Bošnjak „Plan razvoja plinskog transportnog sustava u okviru buduće Strategije energetskog razvoja Republike Hrvatske do 2030. s pogledom na 2050.“, Nafta i Plin, Vol. 39 No. 159. - 160., 2019

[112] Energetski institut Hrvoje Požar, „Analize i podloge za izradu Strategije energetskog razvoja Republike Hrvatske“, Ministarstvo zaštite okoliša i energetike Republike Hrvatske, STU-19-00013/1, Zagreb, svibanj 2019.

[113] A. Armonaite, „The Energy Security Challenge in Central and Eastern Europe“, NATO Economi and Security Committee (ESC), 2018

14. POPIS KRATICA I OZNAKA

μ - intenzitet popravka

μ_n - srednja vrijednost odnosno očekivanje u kontekstu normalne razdiobe

A – raspoloživost u ustaljenom stanju

$\boldsymbol{A}^-$ - vektor negativnog idealnog rješenja u TOPSIS metodi

a i b – krajnje točke unutar uniformne razdiobe

$A(\infty)$ – granična raspoloživost

$A(t)$ – raspoloživost kao funkcija vjerojatnosti u ovisnosti o vremenu

$\boldsymbol{A}^+$ - vektor pozitivnog idealnog rješenja u TOPSIS metodi

AC – izmjenična struja (eng. *Alternating Current*)

AFC – tehnologija alkalnih gorivih ćelija (eng. *Alkaline Fuel Cells*)

A_I – inherentna raspoloživost

$A_m(T)$ – prosječna raspoloživost

A_O – operativna raspoloživost

AR – autoregresija (eng. *Autoregression*)

A_r - površina pokrivena rotorom vjetroagregata

ARIMA - autoregresivna integrirana pomična srednja vrijednost (eng. *Auto Regressive Integrated Moving Average*)

ARMA - autoregresivna integrirana pomična srednja vrijednost (eng. *Auto Regressive Integrated Moving Average*)

ATS – automatska transfer sklopka

b_t - prirast kod predviđanja nizova

CAP_{BAT} – kapitalna ulaganja u bateriju

CAP_{SE} – kapitalna ulaganja u sunčevu elektranu

CAP_{VE} – kapitalna ulaganja u vjetroelektranu

CHP – Combined Heat and Power

CHP - generator električne energije i topline (eng. *Combined Heat and Power*)

c_p - koeficijent značajke vjetroagregata

$\boldsymbol{D}$ – ulazna matrica odlučivanja u TOPSIS metodi

DC – istosmjerna struja (eng. *Direct Current*)

DFTA - analiza dinamičkim stablom kvara (eng. *Dynamic Fault Tree Analysis*)

EMHIRES – baza podataka unutar SETIS projekta Europske Komisije

ENTSO-E – europska mreža operatora prijenosnih elektroenergetskih mreža (eng. *European Network of Transmission System Operators for Electricity*)

$f(t)$ - funkcija gustoće vjerojatnosti u ovisnosti o vremenu

$F(t)$ – kumulativna funkcija razdiobe vjerojatnost kvara

$f(x)$ - funkcija gustoće vjerojatnosti u ovisnosti o varijabli x

$F(x)$ – kumulativna funkcija razdiobe

$F_t(A)$ – vrijeme kvara (događaja) A

$F_t(B)$ – vrijeme kvara (događaja) B

$F_t(OUT)$ – vrijeme kvara (događaja) PAND vrata u DFTA

FTA – analiza stablom kvara (eng. *Fault Tree Analysis*)

h – broj perioda u budućnosti kod predviđanja nizova

H – hibridni sustav

h – parametar učenja UNM

$H(X)$ – entropija u ovisnosti o varijabli X

H_{XY} – hibridni sustav zasnovan na X(SE) i Y(VE)

ICT - informacijske i komunikacijske tehnologije (eng. *Information and communications technology*)

ISO oznaka za međunarodni standard – (eng. *International Organization for Standardization*)

$\boldsymbol{J}$ - Jakobijeva matrica

l_t - razina niza kod predviđanja nizova

m - je duljina sezone kod predviđanja nizova

MA – pomična (srednja) vrijednost (eng. *Moving Average*)

MCFC - tehnologija gorivih ćelija sa otopljenim karbonatima

MTBF – srednje vrijeme između kvarova (eng. *Mean Time Between Failures*)

MTTF – srednje vrijeme do kvara (eng. *Mean Time to Failure*)

MTTR – srednje vrijeme do popravka (eng. *Mean Time to Repair*)

N – prirodni broj

NAR - tip UNM, nelinearni autoregresivni model (*eng. Nonlinear AutoRegressive*)

NARX – tip UNM, nelinearni autoregresivni modeli s vanjskim ulazom, (*eng. Nonlinear AutoRegressive with Exogenous Inputs*)

NIO - tip UNM, nelinearni ulaz – izlaz (*eng. Nonlinear Input-Output*)

N_S – broj sati

NUTS(1, 2, 3) – sustav regija Europske Unije s obzirom na granularnost pojedinih indikatora

OP_{BAT} – operativni troškovi baterije

OP_{SE} – operativni troškovi SE

OP_{VE} – operativni troškovi VE

P – snaga, općenito

$P(A)$ – vjerojatnost događaja A

$P(v)$ – električna snaga vjetroagregata u ovisnosti o brzini vjetra

PAFC – tehnologija gorivih ćelija sa fosfornom kiselinom

PAND – prioritetna *I* vrata u DFTA (eng. *Priority AND*)

PEMFC (ili samo PEM) – tehnologija gorivih ćelija zasnovana na membrani sa izmjenom protona (eng. *Proton-Exchange Membrane Fuel Cells*)

P_i - relativne blizine idealnom rješenju u TOPSIS metodi

$P_{I\%}$ - Instalirana snaga (izraženo u %)

P_{PS} – snaga proizvodnog sustava

P_{SEy} – instalirana snaga SE u hibridnom sustavu H

P_T – snaga tereta

P_{VEx} – instalirana snaga VE u hibridnom sustavu H

$\boldsymbol{R}$ – normirana matrica odlučivanja u TOPSIS metodi

$R(t)$ – funkcija vjerojatnosti pouzdanosti u ovisnosti o vremenu

SARIMA - sezonska autoregresivna integrirana pomična srednja vrijednost (eng. *Seasonal Auto Regressive Integrated Moving Average*)

SE – sunčeva elektrana

SETIS – informacijski sustav europskih strateških energetskih tehnologija (*eng. Strategic Energy Technologies Information System*)

S_i^- - geometrijska udaljenost od najboljeg rješenja u TOPSIS metodi

S_i^+ - geometrijska udaljenost od najboljeg rješenja u TOPSIS metodi

SOFC - tehnologija gorivih ćelija sa krutim oksidima

s_t - komponenta sezonalnosti kod predviđanja nizova

T – vremenska domena

t – vrijeme u formi varijable

TCO – ukupni trošak vlasništva (eng. *Total Cost of Ownership*)

TK – telekomunikacije

TOPSIS – metoda iznalaženja najboljeg rješenja pomoću geometrijske udaljenosti (eng. *Technique for Order of Preference by Similarity to Ideal Solution*)

TTR(*1* i *2*) – vrijeme do popravka (eng. *Time to Repair*)

UNM - umjetne neuronske mreže

UPS – besprekidni sustav napajanja (eng. *uninterruptible power supply*)

v - brzina vjetra

v_{ci} – minimalna brzina vjetra za početak generiranja električna energija (eng. *Cut In*)

v_{co} – brzina vjetra isključenja vjetroagregata (eng. *Cut Out*)

VE - vjetroelektrana

v_r – minimalna brzina vjetra nužna za nazivnu snagu vjetroagregata (eng. *Rated*)

VRLA – ventilom regulirane olovne baterije s kiselinom (eng. *Valve Regulated Lead Acid Battery*)

$\boldsymbol{W}$ – težinska matrica odlučivanja u TOPSIS metodi

W_{B-} - energija pražnjenja baterije

W_B – krajnji kapacitet baterije

W_{B+} - energija punjenja baterije

W_{PS} – energija proizvodnog sustava

W_T – energija opskrbe tereta

X – slučajna varijabla

x_i – slučajna varijabla iz skupa slučajnih varijabli

α – faktor inhibicije kod učestalosti kvarova (rezervna vrata, DFTA)

β – parametar oblika Weibullove razdiobe

Γ – gama (eng. *gamma*) funkcija

δ – parametar ugađanja u Levenberg - Marquardtov algoritmu za rješavanje problema najmanjeg kvadrata

Δt – promatrani vremenski odsječak (u predmetnoj disertaciji 1 h)

$\varepsilon(t)$ – šum ili greška aproksimirane vrijednosti kod UNM

$\zeta_A(x)$ – funkcija pridruživanja u neizrazitoj logici

η – parametar skale Weibullove razdiobe

λ – intenzitet kvara

$\lambda(t)$ – intenzitet kvara u ovisnosti o vremenu

ρ_{zraka} – gustoća zraka

σ – standardna devijacija

y_{t+h} - predviđanje budućeg elementa niza y_1, y_2,..., y_n

15. PRILOG 1 – PODACI O MODELIRANOM HIBRIDNOM SUSTAVU

1. Tablice kapitalnih ulaganja u konfiguracije hibridnih sustava

	VS 0 MW	VS 1 MW	VS 2 MW	VS 3 MW	VS 4 MW	VS 5 MW
SS 0 MW						
SS 1 MW		9.961.526.782,04	7.429.244.850,28	4.916.095.339,32	2.483.266.020,85	426.857.026,83
SS 2 MW		8.120.482.185,53	5.588.319.962,46	3.095.492.595,37	662.681.791,82	205.036.702,13
SS 3 MW		6.279.548.109,03	3.747.869.412,97	1.275.000.371,43	143.252.119,17	100.615.369,03
SS 4 MW		4.438.614.032,53	1.907.901.538,70	133.208.718,63	102.685.317,85	85.573.774,19
SS 5 MW		2.597.569.436,03	211.336.280,79	103.672.775,61	88.134.533,48	71.027.646,35
SS 6 MW		771.809.732,20	155.312.669,24	89.136.747,69	73.598.505,56	56.841.834,71
SS 7 MW		211.343.718,09	124.879.903,47	74.711.239,76	59.172.997,63	53.482.843,04
SS 8 MW		180.932.654,30	94.584.554,71	62.639.121,86	52.008.752,08	51.710.709,91
SS 9 MW		152.215.712,60	73.923.424,64	56.937.401,38	51.068.642,03	51.619.298,25
SS 10 MW		126.676.105,76	67.533.111,31	51.346.200,89	50.246.946,04	52.329.573,97
SS 11 MW		108.136.505,91	61.889.498,73	48.650.213,00	50.217.114,19	52.929.329,69
SS 12 MW		90.363.616,42	56.187.778,24	49.186.515,66	51.112.481,82	53.529.085,40
SS 13 MW		75.502.924,56	50.669.736,07	50.420.236,13	52.346.202,29	54.239.361,12
SS 14 MW		64.109.561,68	51.247.748,97	51.543.436,59	53.469.402,75	54.839.116,84
SS 15 MW		57.144.479,11	52.370.949,43	52.666.637,06	54.592.603,22	55.438.872,55
MIN		57.144.479,11	50.669.736,07	48.650.213,00	50.217.114,19	51.619.298,25
Global MIN		**48.650.213,00**	EUR			

	VS 6 MW	VS 7 MW	VS 8 MW	VS 9 MW	VS 10 MW
SS 0 MW					
SS 1 MW	267.004.714,74	226.094.098,26	183.650.761,33	141.227.168,85	118.186.179,81
SS 2 MW	162.474.581,83	121.563.965,35	93.857.843,74	86.391.924,42	81.765.242,36
SS 3 MW	82.924.403,18	75.970.329,78	74.541.438,73	75.806.367,53	77.172.079,38
SS 4 MW	69.693.091,68	68.434.707,99	69.835.186,39	71.202.024,63	72.989.804,83
SS 5 MW	60.897.369,06	63.776.541,25	65.406.691,43	67.349.713,86	69.350.189,27
SS 6 MW	57.111.468,88	59.984.881,81	61.985.357,23	63.985.832,64	65.988.767,32
SS 7 MW	53.761.102,54	57.442.531,79	60.182.343,06	62.933.012,48	65.692.197,05
SS 8 MW	53.733.831,23	58.042.287,50	60.782.098,78	63.532.768,19	66.291.952,77
SS 9 MW	54.333.586,94	58.642.043,22	61.381.854,50	64.132.523,91	66.891.708,48
SS 10 MW	55.043.862,66	59.352.318,94	62.092.130,21	64.842.799,63	67.601.984,20
SS 11 MW	55.643.618,38	59.952.074,65	62.691.885,93	65.442.555,34	68.201.739,92
SS 12 MW	56.243.374,09	60.551.830,37	63.291.641,65	66.042.311,06	68.804.833,76
SS 13 MW	56.953.649,81	61.262.106,09	64.001.917,37	66.752.586,78	69.519.580,10
SS 14 MW	57.553.405,53	61.861.861,81	64.601.673,08	67.353.302,67	70.123.806,45
SS 15 MW	58.153.161,25	62.461.617,52	65.201.428,80	67.957.529,01	70.728.032,79
MIN	53.733.831,23	57.442.531,79	60.182.343,06	62.933.012,48	65.692.197,05

	VS 11MW	VS 12MW	VS 13MW	VS 14MW	VS 15MW
SS 0 MW					
SS 1 MW	110.606.642,03	102.501.839,25	96.202.996,47	89.789.400,84	91.038.006,02
SS 2 MW	83.158.513,57	84.015.210,84	87.092.778,04	85.904.292,07	87.152.897,25
SS 3 MW	78.684.065,06	80.097.437,57	83.318.189,27	82.129.703,30	83.378.308,48
SS 4 MW	74.919.650,86	76.337.547,45	79.562.823,23	78.378.861,35	79.631.990,62
SS 5 MW	71.350.664,68	72.825.875,10	76.107.045,51	74.970.230,92	76.267.529,21
SS 6 MW	67.993.109,54	69.996.208,73	74.061.950,68	73.719.553,99	75.814.014,64
SS 7 MW	68.457.174,48	70.710.107,85	74.776.697,03	74.434.300,33	76.528.760,99
SS 8 MW	69.056.930,20	71.314.334,20	75.380.923,38	75.038.526,68	77.132.987,33
SS 9 MW	69.657.931,36	71.918.560,54	75.985.149,72	75.642.753,02	77.737.213,68
SS 10 MW	70.372.677,71	72.633.306,89	76.699.896,07	76.357.499,37	78.451.960,02
SS 11 MW	70.976.904,05	73.237.533,23	77.304.122,41	76.961.725,71	79.056.186,37
SS 12 MW	71.581.130,40	73.841.759,58	77.908.348,76	77.565.952,06	79.660.412,71
SS 13 MW	72.295.876,74	74.556.505,92	78.623.095,10	78.280.698,41	80.375.159,06
SS 14 MW	72.900.103,09	75.160.732,27	79.227.321,45	78.884.924,75	81.126.230,95
SS 15 MW	73.504.329,44	75.791.484,68	80.021.421,68	79.841.777,66	82.095.668,64
MIN	67.993.109,54	69.996.208,73	74.061.950,68	73.719.553,99	75.814.014,64

2. Potrebne 2V baterijske ćelije za konfiguracije hibridnih sustava

number of 2V cells	VS 0 MW	VS 1 MW	VS 2 MW	VS 3 MW	VS 4 MW	VS 5 MW
SS 0 MW	-	8.424.648	6.613.549	4.806.072	3.060.587	1.319.591
SS 1 MW	8.920.071	7.108.590	5.297.576	3.500.228	1.759.132	288.027
SS 2 MW	7.604.013	5.792.532	3.981.603	2.198.772	457.688	128.558
SS 3 MW	6.287.955	4.476.474	2.665.891	897.315	85.562	52.866
SS 4 MW	4.971.897	3.160.415	1.350.523	80.644	55.480	41.017
SS 5 MW	3.655.839	1.844.357	137.664	58.521	44.061	29.601
SS 6 MW	2.340.011	539.217	96.621	47.112	32.652	18.442
SS 7 MW	1.024.303	137.779	73.778	35.703	21.242	14.937
SS 8 MW	210.222	115.031	51.112	26.053	15.099	12.645
SS 9 MW	183.610	93.492	35.328	20.954	13.401	11.553
SS 10 MW	162.072	74.144	29.658	15.855	11.709	10.956
SS 11 MW	141.318	59.876	24.601	12.904	10.661	10.358
SS 12 MW	120.626	46.154	19.502	12.260	10.275	9.760
SS 13 MW	99.934	34.434	14.456	12.036	10.051	9.162
SS 14 MW	81.015	25.270	13.842	11.812	9.827	8.564
SS 15 MW	65.650	19.269	13.618	11.588	9.603	7.966

number of 2V cells	**VS 6 MW**	**VS 7 MW**	**VS 8 MW**	**VS 9 MW**	**VS 10 MW**
SS 0 MW	299.623	214.714	182.156	149.612	117.082
SS 1 MW	171.606	139.023	106.465	73.922	55.223
SS 2 MW	95.916	63.332	41.301	33.728	28.182
SS 3 MW	37.989	29.660	26.399	25.061	23.796
SS 4 MW	27.433	23.172	21.932	20.667	19.703
SS 5 MW	20.124	18.819	17.742	16.889	16.077
SS 6 MW	16.393	15.084	14.272	13.460	12.650
SS 7 MW	12.895	12.163	11.879	11.603	11.333
SS 8 MW	11.849	11.565	11.281	11.005	10.735
SS 9 MW	11.251	10.967	10.683	10.407	10.137
SS 10 MW	10.653	10.370	10.086	9.809	9.539
SS 11 MW	10.056	9.772	9.488	9.212	8.942
SS 12 MW	9.458	9.174	8.890	8.614	8.346
SS 13 MW	8.860	8.576	8.292	8.016	7.751
SS 14 MW	8.262	7.978	7.694	7.419	7.157
SS 15 MW	7.664	7.380	7.096	6.824	6.562

number of 2V cells	**VS 11MW**	**VS 12MW**	**VS 13MW**	**VS 14MW**	**VS 15MW**
SS 0 MW	84.558	69.424	61.769	54.115	46.468
SS 1 MW	47.568	39.913	32.258	27.677	26.831
SS 2 MW	26.936	25.682	24.725	23.876	23.030
SS 3 MW	22.635	21.779	20.924	20.075	19.228
SS 4 MW	18.841	17.988	17.136	16.290	15.447
SS 5 MW	15.265	14.453	13.641	12.829	12.018
SS 6 MW	11.841	11.406	11.154	10.910	10.667
SS 7 MW	11.067	10.811	10.560	10.315	10.073
SS 8 MW	10.469	10.216	9.965	9.720	9.478
SS 9 MW	9.872	9.621	9.370	9.126	8.883
SS 10 MW	9.278	9.027	8.776	8.531	8.289
SS 11 MW	8.683	8.432	8.181	7.936	7.694
SS 12 MW	8.088	7.837	7.586	7.342	7.099
SS 13 MW	7.494	7.243	6.992	6.747	6.505
SS 14 MW	6.899	6.648	6.397	6.152	6.015
SS 15 MW	6.304	6.072	5.938	5.810	5.681

3. Kapitalna ulaganja u baterijske ćelije za konfiguracije hibridnih sustava

	VS 0 MW	VS 1 MW	VS 2 MW	VS 3 MW	VS 4 MW	VS 5 MW
SS 0 MW	-	11.794.507.113,54	9.258.968.183,11	6.728.501.169,41	4.284.821.282,96	1.847.426.865,63
SS 1 MW	12.488.099.412,63	9.952.025.757,04	7.416.606.535,28	4.900.319.734,32	2.462.784.480,85	403.238.196,83
SS 2 MW	10.645.618.056,13	8.109.544.400,53	5.574.244.887,46	3.078.280.230,37	640.763.491,82	179.981.112,13
SS 3 MW	8.803.136.699,63	6.267.063.044,03	3.732.247.057,97	1.256.240.726,43	119.786.539,17	74.012.499,03
SS 4 MW	6.960.655.343,12	4.424.581.687,53	1.890.731.903,70	112.901.793,63	77.672.457,85	57.423.624,19
SS 5 MW	5.118.173.986,62	2.582.100.331,03	192.729.885,79	81.929.090,61	61.684.913,48	41.440.736,35
SS 6 MW	3.276.015.583,47	754.903.867,20	135.269.514,24	65.956.302,69	45.712.125,56	25.818.164,71
SS 7 MW	1.434.024.056,56	192.890.573,09	103.289.468,47	49.983.514,76	29.739.337,63	20.911.893,04
SS 8 MW	294.310.943,22	161.042.749,30	71.557.359,71	36.474.636,86	21.138.332,08	17.702.999,91
SS 9 MW	257.053.580,47	130.889.047,60	49.459.469,64	29.336.156,38	18.761.462,03	16.174.828,25
SS 10 MW	226.900.713,79	103.802.160,76	41.521.876,31	22.197.675,89	16.392.486,04	15.337.823,97
SS 11 MW	197.844.510,11	83.825.800,91	34.441.503,73	18.064.928,00	14.925.894,19	14.500.819,69
SS 12 MW	168.875.712,37	64.616.151,42	27.303.023,24	17.164.470,66	14.384.501,82	13.663.815,40
SS 13 MW	139.906.914,62	48.208.179,56	20.237.701,07	16.850.911,13	14.070.942,29	12.826.811,12
SS 14 MW	113.421.231,53	35.378.056,68	19.378.953,97	16.537.351,59	13.757.382,75	11.989.806,84
SS 15 MW	91.909.513,87	26.976.214,11	19.065.394,43	16.223.792,06	13.443.823,22	11.152.802,55

	VS 6 MW	VS 7 MW	VS 8 MW	VS 9 MW	VS 10 MW
SS 0 MW	419.472.344,62	300.598.936,17	255.018.309,24	209.457.426,75	163.914.503,28
SS 1 MW	240.248.594,74	194.632.043,26	149.051.416,33	103.490.533,85	77.312.254,81
SS 2 MW	134.281.701,83	88.665.150,35	57.821.738,74	47.218.529,42	39.454.557,36
SS 3 MW	53.184.243,18	41.524.234,78	36.958.053,73	35.085.692,53	33.314.114,38
SS 4 MW	38.405.651,68	32.441.332,99	30.704.521,39	28.934.069,63	27.584.559,83
SS 5 MW	28.173.169,06	26.346.406,25	24.839.266,43	23.644.998,86	22.508.184,27
SS 6 MW	22.950.508,88	21.117.986,81	19.981.172,23	18.844.357,64	17.710.002,32
SS 7 MW	18.052.862,54	17.028.356,79	16.630.878,06	16.244.257,48	15.866.152,05
SS 8 MW	16.588.831,23	16.191.352,50	15.793.873,78	15.407.253,19	15.029.147,77
SS 9 MW	15.751.826,94	15.354.348,22	14.956.869,50	14.570.248,91	14.192.143,48
SS 10 MW	14.914.822,66	14.517.343,94	14.119.865,21	13.733.244,63	13.355.139,20
SS 11 MW	14.077.818,38	13.680.339,65	13.282.860,93	12.896.240,34	12.518.134,92
SS 12 MW	13.240.814,09	12.843.335,37	12.445.856,65	12.059.236,06	11.684.468,76
SS 13 MW	12.403.809,81	12.006.331,09	11.608.852,37	11.222.231,78	10.851.935,10
SS 14 MW	11.566.805,53	11.169.326,81	10.771.848,08	10.386.187,67	10.019.401,45
SS 15 MW	10.729.801,25	10.332.322,52	9.934.843,80	9.553.654,01	9.186.867,79

	VS 11MW	VS 12MW	VS 13MW	VS 14MW	VS 15MW
SS 0 MW	118.381.205,13	97.193.658,59	86.476.830,82	75.760.303,88	65.055.176,27
SS 1 MW	66.595.427,03	55.878.599,25	45.161.771,47	38.748.175,84	37.563.246,02
SS 2 MW	37.710.538,57	35.955.210,84	34.614.793,04	33.426.307,07	32.241.377,25
SS 3 MW	31.688.810,06	30.490.157,57	29.292.924,27	28.104.438,30	26.919.508,48
SS 4 MW	26.377.115,86	25.182.987,45	23.990.278,23	22.806.316,35	21.625.910,62
SS 5 MW	21.371.369,68	20.234.555,10	19.097.740,51	17.960.925,92	16.824.689,21
SS 6 MW	16.577.054,54	15.968.128,73	15.615.885,68	15.273.488,99	14.934.414,64
SS 7 MW	15.493.839,48	15.134.747,85	14.783.352,03	14.440.955,33	14.101.880,99
SS 8 MW	14.656.835,20	14.302.214,20	13.950.818,38	13.608.421,68	13.269.347,33
SS 9 MW	13.821.076,36	13.469.680,54	13.118.284,72	12.775.888,02	12.436.813,68
SS 10 MW	12.988.542,71	12.637.146,89	12.285.751,07	11.943.354,37	11.604.280,02
SS 11 MW	12.156.009,05	11.804.613,23	11.453.217,41	11.110.820,71	10.771.746,37
SS 12 MW	11.323.475,40	10.972.079,58	10.620.683,76	10.278.287,06	9.939.212,71
SS 13 MW	10.490.941,74	10.139.545,92	9.788.150,10	9.445.753,41	9.106.679,06
SS 14 MW	9.658.408,09	9.307.012,27	8.955.616,45	8.613.219,75	8.420.990,95
SS 15 MW	8.825.874,44	8.501.004,68	8.312.956,68	8.133.312,66	7.953.668,64

4. Konfiguracije vjetroagregata – broj vjetroagregata potreban za postizanje tražene razine raspoloživosti u ovisnosti o inkrementu snage

kW	1MW	4x9	2MW	4x9	3MW	4x9	4MW	4x9	5MW	4x9
500	2	5	4	7	6	9	8	12	10	14
800	2	5	3	6	4	7	5	8	7	11
1000	1	3	2	5	3	6	4	7	5	8
1500	1	3	2	5	2	5	3	6	4	7
1800	1	3	2	5	2	5	3	6	3	6
2000	1	3	1	3	2	5	2	5	3	6
2300	1	3	1	3	2	5	2	5	3	6
2500	1	3	1	3	2	5	2	5	2	5
3000	1	3	1	3	1	3	2	5	2	5
3500	1	3	1	3	1	3	2	5	2	5
4000	1	3	1	3	1	3	1	3	2	5

kW	6MW	4x9	7MW	4x9	8MW	4x9	9MW	4x9	10MW	4x9
500	12	16	14	19	16	21	18	23	20	25
800	8	12	9	13	10	14	12	16	13	18
1000	6	9	7	11	8	12	9	13	10	14
1500	4	7	5	8	6	9	6	9	7	11
1800	4	7	4	7	5	8	5	8	6	9
2000	3	6	4	7	4	7	5	8	5	8
2300	3	6	4	7	4	7	4	7	5	8
2500	3	6	3	6	4	7	4	7	4	7
3000	2	5	3	6	3	6	3	6	4	7
3500	2	5	2	5	3	6	3	6	3	6
4000	2	5	2	5	2	5	3	6	3	6

kW	11MW	4x9	12MW	4x9	13MW	4x9	14MW	4x9	15MW	4x9
500	22	27	24	30	26	32	28	34	30	36
800	14	19	15	20	17	22	18	23	19	24
1000	11	15	12	16	13	18	14	19	15	20
1500	8	12	8	12	9	13	10	14	10	14
1800	7	11	7	11	8	12	8	12	9	13
2000	6	9	6	9	7	11	7	11	8	12
2300	5	8	6	9	6	9	7	11	7	11
2500	5	8	5	8	6	9	6	9	6	9
3000	4	7	4	7	5	8	5	8	5	8
3500	4	7	4	7	4	7	4	7	5	8
4000	3	6	3	6	4	7	4	7	4	7

5. Kapitalna ulaganja u vjetroagregate (EUR)

kW	1MW	2MW	3MW	4MW	5MW
500	6.033.250,00	8.446.550,00	10.859.850,00	14.479.800,00	16.893.100,00
800	9.221.248,00	11.065.497,60	12.909.747,20	14.753.996,80	20.286.745,60
1000	6.708.000,00	11.180.000,00	13.416.000,00	15.652.000,00	17.888.000,00
1500	9.324.450,00	15.540.750,00	15.540.750,00	18.648.900,00	21.757.050,00
1800	10.693.036,80	17.821.728,00	17.821.728,00	21.386.073,60	21.386.073,60
2000	11.529.600,00	11.529.600,00	19.216.000,00	19.216.000,00	23.059.200,00
2300	12.680.350,80	12.680.350,80	21.133.918,00	21.133.918,00	25.360.701,60
2500	13.383.750,00	13.383.750,00	22.306.250,00	22.306.250,00	22.306.250,00
3000	14.947.200,00	14.947.200,00	14.947.200,00	24.912.000,00	24.912.000,00
3500	16.280.250,00	16.280.250,00	16.280.250,00	27.133.750,00	27.133.750,00
4000	17.443.200,00	17.443.200,00	17.443.200,00	17.443.200,00	29.072.000,00

kW	6MW	7MW	8MW	9MW	10MW
500	19.306.400,00	22.926.350,00	25.339.650,00	27.752.950,00	30.166.250,00
800	22.130.995,20	23.975.244,80	25.819.494,40	29.507.993,60	33.196.492,80
1000	20.124.000,00	24.596.000,00	26.832.000,00	29.068.000,00	31.304.000,00
1500	21.757.050,00	24.865.200,00	27.973.350,00	27.973.350,00	34.189.650,00
1800	24.950.419,20	24.950.419,20	28.514.764,80	28.514.764,80	32.079.110,40
2000	23.059.200,00	26.902.400,00	26.902.400,00	30.745.600,00	30.745.600,00
2300	25.360.701,60	29.587.485,20	29.587.485,20	29.587.485,20	33.814.268,80
2500	26.767.500,00	26.767.500,00	31.228.750,00	31.228.750,00	31.228.750,00
3000	24.912.000,00	29.894.400,00	29.894.400,00	29.894.400,00	34.876.800,00
3500	27.133.750,00	27.133.750,00	32.560.500,00	32.560.500,00	32.560.500,00
4000	29.072.000,00	29.072.000,00	29.072.000,00	34.886.400,00	34.886.400,00

kW	11MW	12MW	13MW	14MW	15MW
500	32.579.550,00	36.199.500,00	38.612.800,00	41.026.100,00	43.439.400,00
800	35.040.742,40	36.884.992,00	40.573.491,20	42.417.740,80	44.261.990,40
1000	33.540.000,00	35.776.000,00	40.248.000,00	42.484.000,00	44.720.000,00
1500	37.297.800,00	37.297.800,00	40.405.950,00	43.514.100,00	43.514.100,00
1800	39.207.801,60	39.207.801,60	42.772.147,20	42.772.147,20	46.336.492,80
2000	34.588.800,00	34.588.800,00	42.275.200,00	42.275.200,00	46.118.400,00
2300	33.814.268,80	38.041.052,40	38.041.052,40	46.494.619,60	46.494.619,60
2500	35.690.000,00	35.690.000,00	40.151.250,00	40.151.250,00	40.151.250,00
3000	34.876.800,00	34.876.800,00	39.859.200,00	39.859.200,00	39.859.200,00
3500	37.987.250,00	37.987.250,00	37.987.250,00	37.987.250,00	43.414.000,00
4000	34.886.400,00	34.886.400,00	40.700.800,00	40.700.800,00	40.700.800,00

6. Troškovi održavanja svih konfiguracija vjetroagregata

kW	1MW	2MW	3MW	4MW	5MW
500	1.809.975,00	2.533.965,00	3.257.955,00	4.343.940,00	5.067.930,00
800	2.766.374,40	3.319.649,28	3.872.924,16	4.426.199,04	6.086.023,68
1000	2.012.400,00	3.354.000,00	4.024.800,00	4.695.600,00	5.366.400,00
1500	2.797.335,00	4.662.225,00	4.662.225,00	5.594.670,00	6.527.115,00
1800	3.207.911,04	5.346.518,40	5.346.518,40	6.415.822,08	6.415.822,08
2000	3.458.880,00	3.458.880,00	5.764.800,00	5.764.800,00	6.917.760,00
2300	3.804.105,24	3.804.105,24	6.340.175,40	6.340.175,40	7.608.210,48
2500	4.015.125,00	4.015.125,00	6.691.875,00	6.691.875,00	6.691.875,00
3000	4.484.160,00	4.484.160,00	4.484.160,00	7.473.600,00	7.473.600,00
3500	4.884.075,00	4.884.075,00	4.884.075,00	8.140.125,00	8.140.125,00
4000	5.232.960,00	5.232.960,00	5.232.960,00	5.232.960,00	8.721.600,00

kW	6MW	7MW	8MW	9MW	10MW
500	5.791.920,00	6.877.905,00	7.601.895,00	8.325.885,00	9.049.875,00
800	6.639.298,56	7.192.573,44	7.745.848,32	8.852.398,08	9.958.947,84
1000	6.037.200,00	7.378.800,00	8.049.600,00	8.720.400,00	9.391.200,00
1500	6.527.115,00	7.459.560,00	8.392.005,00	8.392.005,00	10.256.895,00
1800	7.485.125,76	7.485.125,76	8.554.429,44	8.554.429,44	9.623.733,12
2000	6.917.760,00	8.070.720,00	8.070.720,00	9.223.680,00	9.223.680,00
2300	7.608.210,48	8.876.245,56	8.876.245,56	8.876.245,56	10.144.280,64
2500	8.030.250,00	8.030.250,00	9.368.625,00	9.368.625,00	9.368.625,00
3000	7.473.600,00	8.968.320,00	8.968.320,00	8.968.320,00	10.463.040,00
3500	8.140.125,00	8.140.125,00	9.768.150,00	9.768.150,00	9.768.150,00
4000	8.721.600,00	8.721.600,00	8.721.600,00	10.465.920,00	10.465.920,00

kW	11MW	12MW	13MW	14MW	15MW
500	9.773.865,00	10.859.850,00	11.583.840,00	12.307.830,00	13.031.820,00
800	10.512.222,72	11.065.497,60	12.172.047,36	12.725.322,24	13.278.597,12
1000	10.062.000,00	10.732.800,00	12.074.400,00	12.745.200,00	13.416.000,00
1500	11.189.340,00	11.189.340,00	12.121.785,00	13.054.230,00	13.054.230,00
1800	11.762.340,48	11.762.340,48	12.831.644,16	12.831.644,16	13.900.947,84
2000	10.376.640,00	10.376.640,00	12.682.560,00	12.682.560,00	13.835.520,00
2300	10.144.280,64	11.412.315,72	11.412.315,72	13.948.385,88	13.948.385,88
2500	10.707.000,00	10.707.000,00	12.045.375,00	12.045.375,00	12.045.375,00
3000	10.463.040,00	10.463.040,00	11.957.760,00	11.957.760,00	11.957.760,00
3500	11.396.175,00	11.396.175,00	11.396.175,00	11.396.175,00	13.024.200,00
4000	10.465.920,00	10.465.920,00	12.210.240,00	12.210.240,00	12.210.240,00

7. Ukupni troškovi kapitalnih troškova i troškova održavanja

kW	1MW	2MW	3MW	4MW	5MW
500	7.843.225,00	10.980.515,00	14.117.805,00	18.823.740,00	21.961.030,00
800	11.987.622,40	14.385.146,88	16.782.671,36	19.180.195,84	26.372.769,28
1000	8.720.400,00	14.534.000,00	17.440.800,00	20.347.600,00	23.254.400,00
1500	12.121.785,00	20.202.975,00	20.202.975,00	24.243.570,00	28.284.165,00
1800	13.900.947,84	23.168.246,40	23.168.246,40	27.801.895,68	27.801.895,68
2000	14.988.480,00	14.988.480,00	24.980.800,00	24.980.800,00	29.976.960,00
2300	16.484.456,04	16.484.456,04	27.474.093,40	27.474.093,40	32.968.912,08
2500	17.398.875,00	17.398.875,00	28.998.125,00	28.998.125,00	28.998.125,00
3000	19.431.360,00	19.431.360,00	19.431.360,00	32.385.600,00	32.385.600,00
3500	21.164.325,00	21.164.325,00	21.164.325,00	35.273.875,00	35.273.875,00
4000	22.676.160,00	22.676.160,00	22.676.160,00	22.676.160,00	37.793.600,00
Min	**7.843.225,00**	**10.980.515,00**	**14.117.805,00**	**18.823.740,00**	**21.961.030,00**
Config	**5x500kW**	**7x500kW**	**9x500kW**	**12x500kW**	**14x500kW**

kW	6MW	7MW	8MW	9MW	10MW
500	25.098.320,00	29.804.255,00	32.941.545,00	36.078.835,00	39.216.125,00
800	28.770.293,76	31.167.818,24	33.565.342,72	38.360.391,68	43.155.440,64
1000	26.161.200,00	31.974.800,00	34.881.600,00	37.788.400,00	40.695.200,00
1500	28.284.165,00	32.324.760,00	36.365.355,00	36.365.355,00	44.446.545,00
1800	32.435.544,96	32.435.544,96	37.069.194,24	37.069.194,24	41.702.843,52
2000	29.976.960,00	34.973.120,00	34.973.120,00	39.969.280,00	39.969.280,00
2300	32.968.912,08	38.463.730,76	38.463.730,76	38.463.730,76	43.958.549,44
2500	34.797.750,00	34.797.750,00	40.597.375,00	40.597.375,00	40.597.375,00
3000	32.385.600,00	38.862.720,00	38.862.720,00	38.862.720,00	45.339.840,00
3500	35.273.875,00	35.273.875,00	42.328.650,00	42.328.650,00	42.328.650,00
4000	37.793.600,00	37.793.600,00	37.793.600,00	45.352.320,00	45.352.320,00
Min	**25.098.320,00**	**29.804.255,00**	**32.941.545,00**	**36.078.835,00**	**39.216.125,00**
Config	**16x500kW**	**19x500kW**	**21x500kW**	**23x500kW**	**25x500kW**

kW	11MW	12MW	13MW	14MW	15MW
500	42.353.415,00	47.059.350,00	50.196.640,00	53.333.930,00	56.471.220,00
800	45.552.965,12	47.950.489,60	52.745.538,56	55.143.063,04	57.540.587,52
1000	43.602.000,00	46.508.800,00	52.322.400,00	55.229.200,00	58.136.000,00
1500	48.487.140,00	48.487.140,00	52.527.735,00	56.568.330,00	56.568.330,00
1800	50.970.142,08	50.970.142,08	55.603.791,36	55.603.791,36	60.237.440,64
2000	44.965.440,00	44.965.440,00	54.957.760,00	54.957.760,00	59.953.920,00
2300	43.958.549,44	49.453.368,12	49.453.368,12	60.443.005,48	60.443.005,48
2500	46.397.000,00	46.397.000,00	52.196.625,00	52.196.625,00	52.196.625,00
3000	45.339.840,00	45.339.840,00	51.816.960,00	51.816.960,00	51.816.960,00
3500	49.383.425,00	49.383.425,00	49.383.425,00	49.383.425,00	56.438.200,00
4000	45.352.320,00	45.352.320,00	52.911.040,00	52.911.040,00	52.911.040,00
Min	**42.353.415,00**	**44.965.440,00**	**49.383.425,00**	**49.383.425,00**	**51.816.960,00**
Config	**27x500kW**	**9x2000kW**	**7x3500kW**	**7x3500kW**	**8x3000kW**

8. Konfiguracije sunčevih elektrana

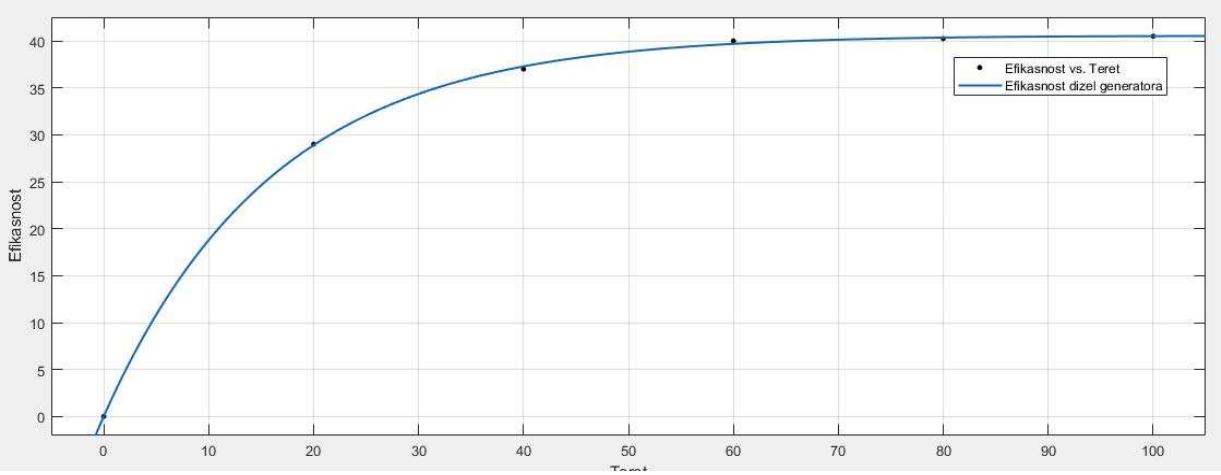
	1MW	2MW	3MW	4MW	5MW
P(W)	1000000	2000000	3000000	4000000	5000000
grupa	66,66666667	133,3333333	200	266,6666667	333,3333333
nizova	13,33333333	26,66666667	40	53,33333333	66,66666667
nizova	14	27	40	54	67
raspoloživost	0,999978253	0,999922019	0,999998926	0,999997419	0,999995143
nizova za Ai	15	28	42	56	69
degradacija	10%	10%	10%	10%	10%
ukupno panela	4.950	9.240	13.860	18.480	22.770
ukupno instal €	1.381.500,00	2.578.800,00	3.868.200,00	5.157.600,00	6.354.900,00
Održavanje (€)	276.300,00	515.760,00	773.640,00	1.031.520,00	1.270.980,00
UKUPNO	1.657.800,00	3.094.560,00	4.641.840,00	6.189.120,00	7.625.880,00

	6MW	7MW	8MW	9MW	10MW
P(W)	6000000	7000000	8000000	9000000	10000000
grupa	400	466,6666667	533,3333333	600	666,6666667
nizova	80	93,33333333	106,6666667	120	133,3333333
nizova	80	94	107	120	134
raspoloživost	0,999991827	0,999986876	0,999980802	0,999973121	0,999962847
nizova za Ai	82	96	109	122	136
degradacija	10%	10%	10%	10%	10%
ukupno panela	27.060	31.680	35.970	40.260	44.880
ukupno instal €	7.552.200,00	8.841.600,00	10.038.900,00	11.236.200,00	12.525.600,00
Održavanje (€)	1.510.440,00	1.768.320,00	2.007.780,00	2.247.240,00	2.505.120,00
UKUPNO	9.062.640,00	10.609.920,00	12.046.680,00	13.483.440,00	15.030.720,00

	11MW	12MW	13MW	14MW	15MW
P(W)	11000000	12000000	13000000	14000000	15000000
grupa	733,3333333	800	866,6666667	933,3333333	1000
nizova	146,6666667	160	173,3333333	186,6666667	200
nizova	147	160	174	187	200
raspoloživost					
nizova za Ai	149	162	176	189	202
degradacija	10%	10%	10%	10%	10%
ukupno panela	49.170	53.460	58.080	62.370	66.660
ukupno instal €	13.722.900,00	14.920.200,00	16.209.600,00	17.406.900,00	18.604.200,00
Održavanje (€)	2.744.580,00	2.984.040,00	3.241.920,00	3.481.380,00	3.720.840,00
UKUPNO	16.467.480,00	17.904.240,00	19.451.520,00	20.888.280,00	22.325.040,00

16. PRILOG 2 - INTERPOLOCAIJSKE KRIVULJE UČINKOVITOSTI TEHNOLOGIJA PROIZVODNJE ELEKTRIČNE ENERGIJE

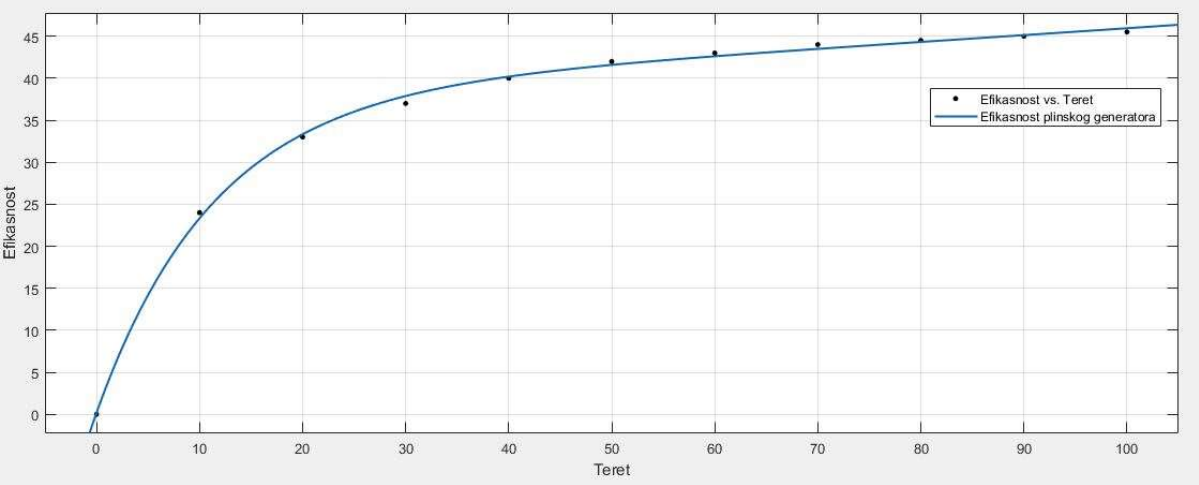
1. Učinkovitost dizel agregata



General model Exp2:
f(x) = a*exp(b*x) + c*exp(d*x)
Coefficients (with 95% confidence bounds):
a = 40.85 (35.77, 45.94)
b = -6.277e-05 (-0.001482, 0.001356)
c = -40.84 (-46.02, -35.66)
d = -0.06167 (-0.07548, -0.04786)

Goodness of fit:
SSE: 0.1976
R-square: 0.9998
Adjusted R-square: 0.9996
RMSE: 0.3143

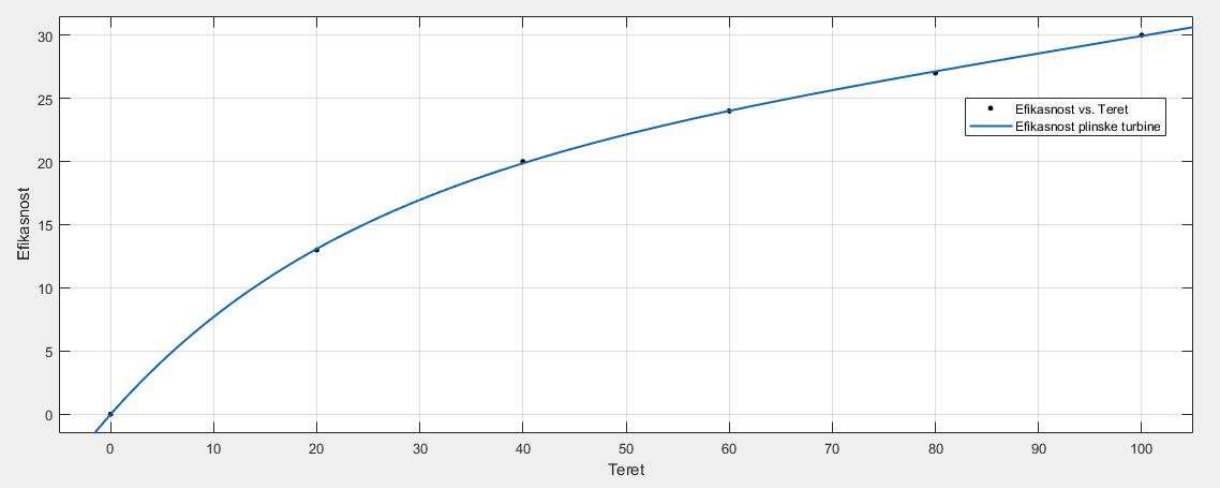
2. Učinkovitost plinskog agregata



General model Exp2:
f(x) = a*exp(b*x) + c*exp(d*x)
Coefficients (with 95% confidence bounds):
a = 38.48 (36.51, 40.45)
b = 0.001777 (0.001114, 0.002439)
c = -38.32 (-40.57, -36.07)
d = -0.08836 (-0.09977, -0.07696)

Goodness of fit:
SSE: 2.216
R-square: 0.9988
Adjusted R-square: 0.9983
RMSE: 0.5627

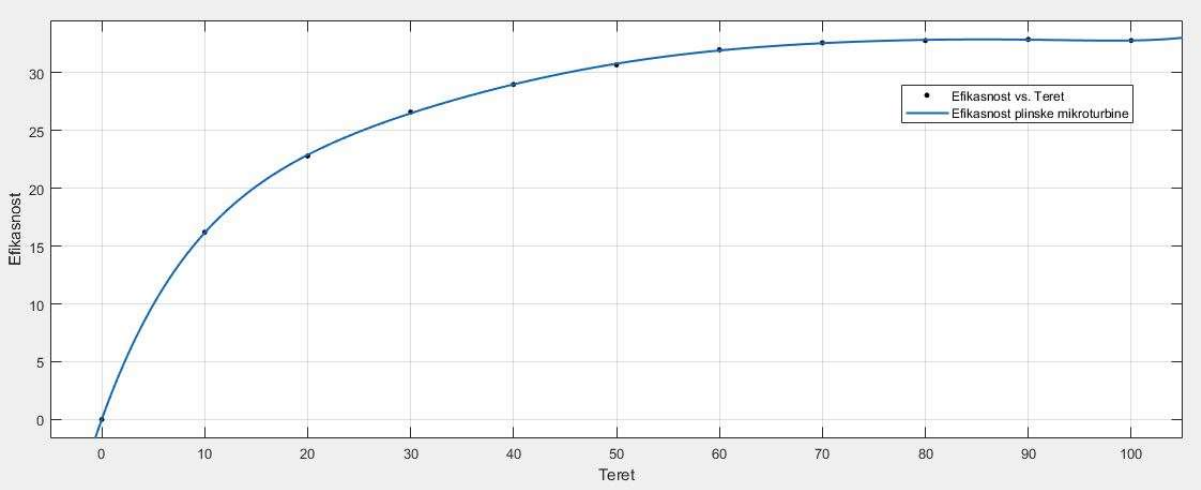
3. Učinkovitost plinske turbine



General model Exp2:
f(x) = a*exp(b*x) + c*exp(d*x)
Coefficients (with 95% confidence bounds):
a = 19.93 (16.82, 23.04)
b = 0.004163 (0.00259, 0.005736)
c = -19.95 (-23.04, -16.85)
d = -0.04222 (-0.05298, -0.03145)

Goodness of fit:
SSE: 0.04945
R-square: 0.9999
Adjusted R-square: 0.9998
RMSE: 0.1572

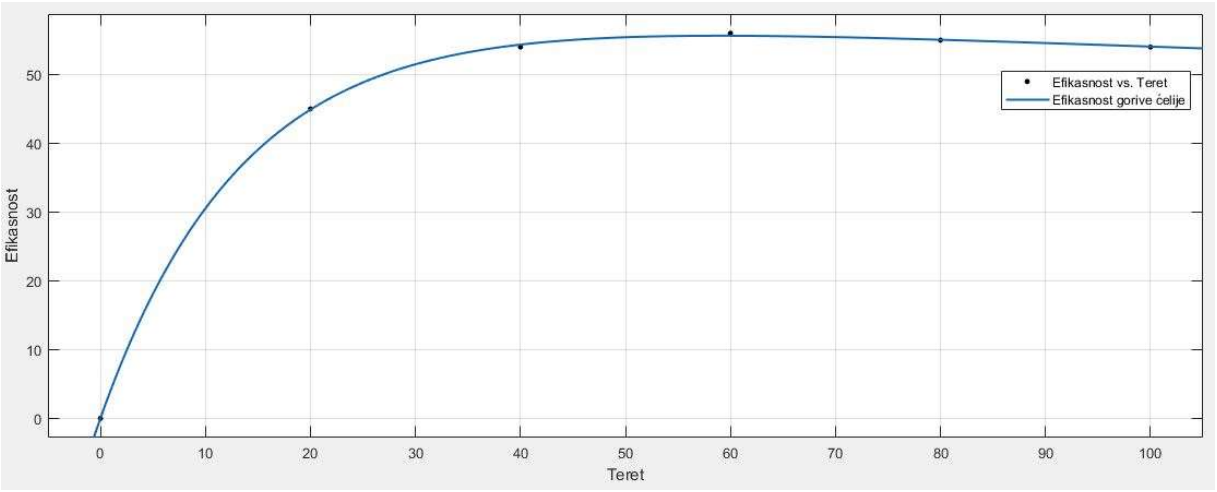
4. Učinkovitost plinske mikroturbine



General model Exp2:
f(x) = a*exp(b*x) + c*exp(d*x)
Coefficients (with 95% confidence bounds):
a = 30 (27.17, 32.83)
b = 0.00106 (-8.805e-05, 0.002208)
c = -29.76 (-32.67, -26.84)
d = -0.06886 (-0.08195, -0.05576)

Goodness of fit:
SSE: 2.263
R-square: 0.9978
Adjusted R-square: 0.9969
RMSE: 0.5686

5. Učinkovitost gorive ćelije



General model Exp2:
f(x) = a*exp(b*x) + c*exp(d*x)
Coefficients (with 95% confidence bounds):
a = 59.97 (54.81, 65.12)
b = -0.00103 (-0.002062, 3.008e-06)
c = -59.96 (-65.29, -54.62)
d = -0.07327 (-0.08615, -0.06038)

Goodness of fit:
SSE: 0.2719
R-square: 0.9999
Adjusted R-square: 0.9997
RMSE: 0.3687

17. ŽIVOTOPIS

Domagoj Talapko je rođen 10. lipnja 1983. godine u Osijeku. Nakon završene osnovne škole upisuje klasično odjeljenje druge gimnazije u Osijeku nakon koje upisuje Elektrotehnički fakultet u Osijeku 2001 godine. Na Elektrotehničkom fakultetu završava smjer elektroenergetike 2007. godine i stječe titulu diplomiranog inženjera elektrotehnike. Iste godine se zapošljava u Zagrebu u firmi ETS-Farago gdje radi na poziciji Inženjer – projektant. 2008. godine odlazi u kompaniju Emerson Network Power u Zagrebu gdje radi na pozicijama Product Manager za istosmjerne sustave napajanja u telekomunikacijama za regiju južne Europe, Bid Manager za sustave besprekidnih napajanja i hlađenja u podatkovnoj infrastrukturi za regiju Europa, Bliski istok i Afrika. 2015. godine postaje globalni Bid Manager za podatkovne centre po modelu „ključ u ruke". 2016. godine prelazi u kompaniju ABB na poziciju globalnog Voditelja razvoja poslovanja za srednje naponske sustave besprekidnog napajanja u podatkovnoj industriji gdje radi i trenutno.

Popis objavljenih radova:

1. D.Talapko: Telecom Datacenter Power Infrastructure Availability Comparison of DC and AC UPS, INTELEC 2012, IEEE, Scottsdale, Arizona, USA, 2012
2. D.Talapko, S.Tešnjak: Influence of Distributed Power Generation Sources on Improvement of Power Supply Availability in Telecom Infrastructure, DPSP 2014, IET, Copenhagen, Denmark, 2014
3. D.Talapko, S.Tešnjak: Influence of Solar and Wind Power Generation Sources on Power Supply Availability in Telecom Infrastructure, INTELEC 2014, IEEE, Vancouver, Canada, 2014
4. D.Talapko, S.Tešnjak: Influence of Availability on the Cost Analysis of Solar Powered Data Centers with AC and DC Architecture and Mirroring Functionality, INTELEC 2015, IEEE, Osaka, Japan
5. D.Talapko, S.Tešnjak, H.Glavaš: Impact of Maintenance on Solar and Wind Powered Internet Data Center Electrical Infrastructure Availability, 27th International Scientific and Professional Conference „Organization and Maintenance Technologies" - OTO 2018, Osijek, Croatia, 2018

6. D.Talapko, S.Tešnjak, H.Glavaš: Comparison of Electrical Architectures for Support of the Software Defined Data Centers, SST 2018, IEEE, Osijek, Croatia, 2018
7. H.Glavaš, F.Zovko-Ribić, D. Dorić, D.Talapko: Development of energy management standards, SST 2018, IEEE, Osijek, Croatia, 2018

18. CURRICULUM VITAE

Domagoj Talapko was born on 10th of June 1983 in Osijek. After completing elementary school, he enrolled in the classical department of the Second grammar school in Osijek, after which he enrolled in the Faculty of Electrical Engineering in Osijek in 2001. At the Faculty of Electrical Engineering, he completed his electrical engineering course, power engineering, in 2007 and earned the title of Electrical Engineer. In the same year, he got a job in Zagreb at ETS-Farago where he worked as a Design Engineer. In 2008, she went to Emerson Network Power in Zagreb to work as Product Manager for DC power systems in the South European region, Bid Manager for uninterruptable power supply systems and cooling systems in the datacenter infrastructure for Europe, Middle East and Africa. In 2015, it became the global Bid Manager for turnkey data center solutions. In 2016, he transferred to ABB to become the Global Business Development Manager for Medium Voltage Uninterruptible Power Systems in the datacenter industry where he currently works.