Napredno planiranje energetski samodostatnih širih gradskih područja razvojem pametnog energetskog sustava

Falkoni, Anamarija

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:154526

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-10-28**

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb

Sveučilište u Zagrebu

Fakultet strojarstva i brodogradnje

Anamarija Falkoni

NAPREDNO PLANIRANJE ENERGETSKI SAMODOSTATNIH ŠIRIH GRADSKIH PODRUČJA RAZVOJEM PAMETNOGA ENERGETSKOGA SUSTAVA

DOKTORSKI RAD

Zagreb, 2022.

Sveučilište u Zagrebu

Fakultet strojarstva i brodogradnje

Anamarija Falkoni

NAPREDNO PLANIRANJE ENERGETSKI SAMODOSTATNIH ŠIRIH GRADSKIH PODRUČJA RAZVOJEM PAMETNOGA ENERGETSKOGA SUSTAVA

DOKTORSKI RAD

Mentor:
Izv. prof. dr. sc. Goran Krajačić

Zagreb, 2022.

University of Zagreb

Faculty of Mechanical Engineering and Naval Architecture

Anamarija Falkoni

ADVANCED PLANNING OF ENERGY SELF-SUFFICIENT WIDER URBAN AREAS USING SMART ENERGY SYSTEM APPROACH

DOCTORAL DISSERTATION

Supervisor:
Assoc. prof. dr. sc. Goran Krajačić

Zagreb, 2022.

INFORMACIJE O MENTORU

Izv. prof. dr. sc. Goran Krajačić radi kao izvanredni profesor na Fakultetu strojarstva i brodogradnje, Sveučilišta u Zagrebu, na Katedri za energetska postrojenja i energetiku, Zavod za energetska postrojenja, energetiku i okoliš. Od listopada 2018. do rujna 2022. obnašao je funkciju voditelja Katedre za energetska postrojenja i energetiku na istom zavodu. U posljednjih 5 godina je djelovao kao koordinator hrvatskog sudjelovanja FSB-a na istraživačkim projektima financiranim kroz program Obzor 2020, projekt „Phoenix - People for The European Bioenergy mix“ (H2020-EU-SCA-RISE 2015), „KeepWarm - Improving the performance of district heating systems in Central and East Europe“ (H2020-EE-2017-CSA-PPI), a trenutno vodi FSB tim na projektu INSULAE – Maximizing the impact of innovative energy approaches in the EU islands LC-SC3-ES-4-2018-2020. Od 2014. do 2017. koordinira FSB participaciju na projektu BEAST - Beyond Energy Action Strategies (IEE program). Od 2012. do 2016. koordinira FSB participaciju u projektu DISKNET - DIStributed Knowledge-Based Energy Saving NETworks (FP7-PEOPLE-2011-IRSES). Kao suradnik sudjeluje ili sudjelovao je na projektima RESFlex - Energetski neovisna Hrvatska bazirana na visokom udjelu obnovljivih izvora energije te različitih tehnologija brzog odziva financiran od Hrvatske zaklade za znanost (HRZZ) u periodu od 2017.-2019. Od 2016.-2018. radio je na projektu „PRISMI-Promoting RES Integration for Smart Mediterranean Islands“ (Interreg MED), a od 2014. do 2016. je suradnik na projektu STRATEGO - Multi-level actions for enhanced Heating & Cooling plans (IEE), s ciljem potpore i istraživanja u području razvoja nacionalnih planova za grijanje i hlađenje, od 2012. do 2017. suradnik je na projektu 4DH - Strategic Research Centre for 4th Generation District Heating Technologies and Systems financiranog od strane Danskog vijeća za strateška istraživanja. Također je od 2014. do 2016. imao ulogu znanstvenika zaduženog za mentoriranje voditelja projekta te koordinaciju i implementaciju aktivnosti od strane gostujuće institucije u projektu CARBEN (NEWFELPRO) Carbon footprint reduction and energy efficiency via development advanced techniques for Total Site integration. Na poziv Europske komisije održao je predavanje Prosumer Models and Energy Systems on the EU islands na skupu Energy prosumer - New opportunities in the Energy Industry in EU and Korea organiziranom u Seulu u travnju 2017. Od 2014. godine u dva navrata boravi po tri mjeseca na Sveučilištu Mohammad I, Oujda u Maroku. Od 2015. godine je gostujući urednik u časopisu Energy Conversion and Management koji je prema WoS rangiran na drugom mjestu od 52 časopisa u području Termodinamike. Pored uredništva u ECM-u radi i recenzije za mnoge druge znanstvene časopise Applied Energy, Energy, Energy policy, Energy conversion and management, Renewable and sustainable energy reviews, Thermal science, Journal of Cleaner Production, Energy Research & Social Science, Energy Strategy Reviews. Rezultati njegovih istraživanja su do sada objavljeni u više od 50 znanstvenih radova u časopisima indeksiranim u SCIE/CC-bazi te su isti radovi citirani više od 3000 puta prema SCOPUS bazi. Prema istoj bazi h-indeks mu je 33. Kao recenzent radio je na ocjenjivanju projekata iz programa Obzor 2020 za agencije Europske komisije.

ZAHVALE

Izloženi doktorski rad rezultat je višegodišnjeg istraživanja, rada i studiranja na poslijediplomskom doktorskom studiju Strojarstva, brodogradnje, zrakoplovstva i metalurgije, Fakulteta strojarstva i brodogradnje, Sveučilišta u Zagrebu. Zahvaljujem se svom mentoru Izv. prof. dr. sc. Goranu Krajačiću na vodstvu, pomoći i podršci tijekom istraživanja. Njegovo znanje i profesionalnost uvelike su doprinijeli mom osobnom napretku. Kroz višegodišnju suradnju sam imala priliku naučiti mnoge korisne vještine za rad u znanosti. Također se želim zahvaliti na strpljenju, pristupačnosti i u konačnici prijateljstvu koje je rezultiralo ugodnom dosadašnjom suradnjom, a vjerujem i u budućnosti.

Neki dijelovi i rezultati ovoga rada već su prethodno objavljeni kao znanstveni radovi u časopisima i izlagani na međunarodnim konferencijama te više puta citirani. Zahvaljujem se svim koautorima objavljenih i izlaganih radova, kao i recenzentima i svim znanstvenicima koji su radove prepoznali kao korisne doprinose znanosti.

Zahvaljujem se predsjedniku i članovima komisije na uloženom trudu za pregled rada, te korisnim pitanjima i komentarima koji su uvelike doprinijeli poboljšanju i izgledu konačne verzije ovog rada.

Zahvaljujem se kolegi Marku Mimici na pomoći i upoznavanju sa radom u računalnom programu Calliope, koje mi je bilo od velikog značaja u cilju što kvalitetnije izrade ovoga rada i dobivenih rezultata te potvrde hipoteze.

Zahvaljujem se mojim kolegama sa Sveučilišta u Dubrovniku, posebice Pomorskom odjelu na kojem sam i zaposlena, na iskazanoj podršci, razumijevanju, savjetima i prijateljskom okruženju. Posebno se zahvaljujem Izv. prof. dr. sc. Nikši Koboeviću i Doc. dr. sc. Matku Bupiću na kolegijalnosti, ljudskosti i pomoći u nastavi kada god je to bilo potrebno.

Naposljetku, zahvaljujem se mojoj obitelji na iznimnoj ljubavi i podršci. Posebno se zahvaljujem voljenoj mami Sandri i sestrama Matei i Nikolini na razumijevanju i pomoći koja mi je mnogo značila i doprinijela uspješnoj izradi rada. Zahvaljujem se i ostaloj rodbini i prijateljima na podršci, kojih ima puno i uvijek su tu i na tome sam neizmjerno zahvalna. I konačno, zahvaljujem se mojoj najvećoj ljubavi i sreći, mom voljenom sinu Luku. Već kao mali pokazao je veliku empatiju, strpljenje i ljubav. Uz njegov osmjeh i zagrljaj svaka prepreka se s lakoćom svladavala i veliki je moj poticaj i motivacija.

PODACI O BIBLIOGRAFIJI

Ključne riječi: energetsko planiranje, obnovljivi izvori energije, električna vozila, dizalice topline, spremnici energije, tržište električne energije, fleksibilnost, vozila-na-mreži

Znanstveno područje: TEHNIČKE ZNANOSTI
Znanstveno polje: Strojarstvo
Znanstvena grana: procesno energetsko strojarstvo
Ustanova: Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu
Mentor: Izv. prof. dr. sc. Goran Krajačić, dipl. ing.
Broj stranica: 193
Broj slika: 56
Broj tablica: 61
Broj referenci: 188
Datum usmenog ispita: 27. 10. 2022. godine
Povjerenstvo za obranu doktorskog rada:
- Prof. dr. sc. Neven Duić, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, predsjednik
- Doc. dr. sc. Tomislav Pukšec, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, član
- Izv. prof. dr. sc. Iva Ridjan Skov, Aalborg University, Department of Planning, Danska, član
- Doc. dr. sc. Matko Bupić, Sveučilište u Dubrovniku, Pomorski odjel, član
- Dr. sc. Dominik Franjo Dominković, Technical University of Denmark, Danska, član.

SAŽETAK

Postizanje 100% udjela obnovljivih izvora energije u energetskom sustavu zahtjeva dodatne napore u planiranju kako bi se postigao samodostatan i održiv energetski sustav. To se posebno odražava na manje energetske sustave čija je raznolikost sudionika ponude i potražnje za energijom manja, što stvara manjak fleksibilnosti u sustavu i otežava prelazak na obnovljive izvore energije. Potrebno je provesti napredno energetsko planiranje koje će ići u cilju postizanja pametnog energetskog sustava, čime će se omogućiti integracija visokog udjela promjenjive i nestalne proizvodnje energije iz obnovljivih izvora energije.

U ovome radu izradio se algoritam na 10-minutnoj bazi unosa podataka po uzoru na satni model EnergyPLAN. Cilj ovog rada je usporedba satnog modela za energetskog planiranje s novim modelom koji se bazira na 10-minutnom unosu podataka. Za izradu proračuna odabran je manji energetski sustav šireg gradskog područja i definirane su se granice sustava. Izradio se model energetskog plana za razvoj pametnog energetskog sustava do 2050. godine. Planom je određena integracija transportnog i toplinskog sektora i njihov prelazak na električnu energiju uvođenjem električnih vozila i dizalica topline. Planirano je povećanje skladišnih kapaciteta energije te povezanost energetskog sustava kroz otvoreno tržište električnom energijom, koje će omogućiti tržišno vrednovanje izvora fleksibilnosti. Povezivanje svih sudionika energetskog sustava osigurat će korištenje informacijsko komunikacijskih tehnologija, što će im omogućiti aktivno i ekonomično sudjelovanje u sustavu i doprinijeti ostvarivanju bolje fleksibilnosti unutar sustava. Novi algoritam nadogradio se razvijanjem modela u programu Calliope u kojem se izradio model za energetski plan do 2050. godine.

Rezultati analiza u novom modelu pokazali su da regulacija iznimno brzog punjenja i pražnjenja EV, uvođenjem modela "vozila na mreži", pruža veću fleksibilnost energetskom sustavu i potiče integraciju obnovljivih izvora energije. Proračun modela baziran na 10-minutnom vremenskom koraku u programu Calliope rezultirao je smanjenjem prekograničnih kapaciteta i povećanjem izvora fleksibilnosti, te većoj stabilnosti sustava u odnosu na satni model. Samodostatnost sustava ostvarila se integracijom toplinskog i transportnog sektora, uz dodatne skladišne kapacitete i povezanost s tržištem električne energije.

Novi model baziran na kratkoročnom vremenskom koraku unosa podataka pruža detaljniju sliku rada elektroenergetskog sustava. Time se stvara više mogućnosti za različite izvore fleksibilnosti, integraciju više sektora, razvoja tržišta i sigurniji prelazak na obnovljive izvore energije. Uvođenje modela "vozila-na-mrežu" uz regulaciju iznimno brzog punjenja i pražnjenja električnih vozila na 10-minutnoj bazi rezultira značajno većom mogućnošću integracije obnovljivih izvora energije i pruža veću fleksibilnost elektroenergetskom sustavu.

EXTENDED SUMMARY

Key words: energy planning, renewable energy sources, electric vehicles, heat pumps, energy storage, electricity market, flexibility, vehicle-to-grid

Increase in greenhouse gas emissions is becoming a global concern and many countries are taking effort in dealing with the emission reduction. The first thing to do on that path is the introduction of laws and directives which will lead to goal achievement. The Paris agreement is one of them. Its goal is to limit global warming to well below 2°C, preferably to 1,5°C, compared to pre-industrial levels. It means the reduction of fossil fuel use which causes the emission increase and therefore increase in global temperature. Europe is aiming to reduce the use of fossil fuels by 55% until 2030, as it is prescribed by directives REPowerEU and Fit for 55. The goal can be achieved by replacing the fossil fuels with the renewable energy source (RES) in different sectors. Energy production, transport and thermal sectors are responsible for most of the air pollution. Their transition to electricity and mutual integration could enhance emission reduction. Replacing fossil fuels in energy production with RES could cause instability and uncertainty of energy supply due to intermitted RES, such as wind and solar power. Although, the combination of wind and solar power in electricity production has shown benefits over the stand-alone production systems, it still requires additional efforts in order to achieve stability and security of electricity supply, especially in the systems with a high share of RES in electricity production. Transport and thermal sector have a potential to utilize a high amount of electricity produced by RES if they convert to electricity. In transport sector, it can be done by replacing conventional vehicles with electric (EV) ones. Heat pumps are given as the best solution for thermal sector in order to replace heating and cooling systems based on fossil fuels.

Electrical power systems with a high share of RES, even by 100% share, can be achieved but they require additional flexibility in the system in order to enhance stabile and sustainable system. Flexibility needs are derived from intermitted RES electricity production, especially wind and solar power, as well as uncertain electricity demand and unexpected events. On the other hand, there are different sources of flexibility that can be integrated into the system in order to enhance utilization of high share of RES and provide stability to the system. The flexible resource exists in different parts of the power system: in the portfolio of dispatchable power plants; in the ability of the demand side to respond or to be managed; in storage facilities; in interconnections to adjacent power systems to allow trade; and in integration of different sectors. Wind and solar power plants, together with hydropower plants,

can be defined as flexible resources as well, since they belong to dispatchable power plants, with the ability to ramp output up and down on demand.

Smaller electrical power systems, such as city, region and municipality, have higher needs for flexibility due to their lower number and possibly lower diversity of electric power plants as well as flexible resources. This thesis analyses such a smaller electrical power system of a wider urban area. Dubrovnik wider urban area is selected and energy plan is done until the year 2050. in order to achieve 100% renewable and self-sufficient energy system.

Hypothesis and research description

The aim of the thesis is the comparison between the hourly energy plan model and a new model based on 10-minute time step. A new model is build according to the EnergyPLAN model tool based on hourly data input and used for energy planning. New model is developed for 10-minute and hourly data input base. It is compared with the EnergyPLAN model tool in order to demonstrate the validity of a new model. New algorithm is upgraded using the Calliope computer program in order to achieve self-sufficient 100% renewable energy system of the selected wider urban area using smart energy system approach.

The boundaries of the Dubrovnik wider urban area are defined. They considered urban city and its surrounding which is spatially, demographically, functionally and traffic-wise closely connected to the city. The selected area covers the area from Slano in the northwest to Pločice in the southeast. The aim is to develop the energy plan model of 100% renewable energy system of the selected area until 2050 with 100% share of RES electricity production and transition of thermal and transport sector to electricity. All of the personal conventional vehicles are considered to be replaced by the electric ones and all of the fossil fuels used in thermal sector will be replace with seawater heat pumps (SWHP) until 2050. Year 2014 is selected as a base scenario.

The first step was to collect the data on electricity demand, electricity production, thermal demand and transport, as well as the potential on renewable electricity production capacities, storage capacities and capacities of interconnection lines to the adjacent energy systems of the selected area based on 2014. Collected data are arranged in hourly and 10-minute time step.

Collected data on electricity demand, outside temperature, solar radiation and wind speed are selected to analyse linear correlation and regression in-between the data based on a short-term scale of 10 minutes. The analyses are done in STATISTICA program tool for the data selected for 2012, 2013 and 2014 for four selected scenarios. First group of data considered the analyses of the relationship in between three consecutive years for each of the selected data

based on a 10-minute time scale. Other three groups of data took into account analyses of the relationship in between the data for all selected years based on a mean monthly values and 10-minute time step. These analyses present a novelty according to previous literature and give an insight in a relationship between the selected data based on a short-term scale, which are used for further calculations in a new model.

Energy plan model of the Dubrovnik wider urban area was done until 2050 for all system participants located within the boundaries of the selected area. Electricity demand data are provided by Elektrojug d.o.o. for substation Komolac and projections are done until 2050. Electricity production consists of the production from hydropower plant (HPP) Dubrovnik and the projected production capacities of wind (WPP) and solar power plants (SPP). Data on transport sector are collected for 2014 and projections are done until 2050 with the assumption that all of the personal conventional vehicles will be replaced with electric ones. Characteristics of the EV batteries (BES) are defined and EV electricity demand until 2050 is gained based on the traffic data. Data on thermal demand are collected and projected until 2050, with the assumption that all of the fossil fuel based heating and cooling system will be replaced with SWHP systems. Energy storage facilities are also considered in the system in order to provide additional flexibility. These are additional thermal energy storages (TES) for heating and cooling purposes, battery second use (B2U) and hydrogen energy storage with electrolyser and fuel cell. B2U model is used for BEV when they end their life in EV and lose 20% of their initial capacity. Hydrogen is used to store electricity by converting it to hydrogen gas using electrolyser, storing hydrogen in a tank and converting it again to electricity using fuel cell.
The ability of SWHP system to utilize high share of RES in electricity production is analysed for one part of the selected area, the old city of Dubrovnik. District heating and cooling SWHP system is analysed for three scenarios and three cases. First scenario took into account SWHP as a stand-alone system and the other two scenarios took into a consideration battery energy storage (BES) and TES. First scenario is done on the hourly and 10-minute data calculation base, while the other two are done on the hourly basis. First two cases considered WPP and SPP as stand-alone systems while the third case considered combination of wind and solar resources in electricity production. BES and TES are compared according to their required capacity, volume and costs.

Transport sector is in more detail analysed developing a new model. New model is built on hourly and 10-minute data base input according to EnergyPLAN model tool. Analyses done using new model took into account electricity production from RES, electricity demand and EV electricity demand of the selected area and projections until 2050. Two scenarios are

observed, for 2030 and 2050, doing calculation on hourly and 10-minute time step. Comparison is done according to two different time step calculations and regulation of EV charging and discharging in the system. Unregulated system considered unregulated EV charging which is based on consumer needs and habits due to their driving needs. Regulated system took into account the implementation of 'vehicle-to-grid' (V2G) model and a regulation of EV charging and discharging according to the production from RES. V2G vehicles are charged when there is excess in electricity production and discharged in the time of a lack of electricity production in the system in order to reduce import and export capacities. All of the EV are considered as one integrated battery. It is assumed that all of V2G vehicles are available for charging and discharging in every time step, if they are not driving or charging in order to meet the user's driving needs. V2G are charged and discharged if there is enough battery capacity available in each time step.

Hourly time step calculations took into account EV standard charging and discharging that requires 5 hours to recharge the BEV up to 100% SOC. 10-minute time step calculations took into account EV extremely fast charging and discharging that requires 10 minutes to recharge the BEV up to 100% SOC. Four cases are done for two scenarios and comparison is done according to unregulated and regulated system on hourly and 10-minute time base. Case 1 took into account production from WPP and SPP, electricity demand and EV electricity demand with the assumption that all of the EV are available for charging and discharging in each time step. In case 2, defined system in case 1 is upgraded with HPP Dubrovnik. Case 3 analysed minimal BEV connection capacity required in order to meet the results gained in case 1. Case 4 analysed cost and saving of EV consumers after the implementation of V2G model and the replacement of present two-tariff model (P2T) in electricity prices with variable two-tariff model (V2T). Results of a new model are compared to the results gained in EnergyPLAN according to the scenario 1 and case 1.

New model is upgraded in Calliope energy plan model tool in hourly and 10-minute time base in order to achieve self-sufficient and 100% renewable smart energy system of a wider urban area until 2050. The upgrade contained the integration and electrification of transport and thermal sector through implementation of EV and SWHP systems, additional ES and the integration through the open electricity market. Transport sector included 100% share of personal EV with regulated model V2G. V2G model is developed in Calliope and the results are compare to the results of a new model gained according to the scenario 2 and case 1.

Thermal sector included the implementation of SWHP systems with the additional TES for heating and cooling purposes. Other additional storage facilities are also considered within

the upgrade, such as B2U and hydrogen energy storage with electrolyser and fuel cell. Input data of each of the selected technologies, with their main characteristics, are defined within the model together with their operation, maintenance and installation costs. Data on technology costs are taken from the Danish Energy Agency. Energy system is considered to be connected to the adjacent system through interconnection lines, which will enable electricity trade according to the variable electricity prices at the open market. Market electricity prices are defined according to CROPEX electricity prices from 2018. Calliope model operation is focused on RES integration and minimization of costs. Of all of the provided and defined technologies of the developed model, optimization analyses done in Calliope will result in optimal solution with minimum cost for the developed system. The aim of Calliope model is to achieve 100% renewable, self-sufficient and stable energy system.

Research results and contributions

Results of the linear correlation and regression analyses, for the first group of data, showed that the 10-minute values of solar radiation, air temperature and electricity demand can be pronounced with linear regression line. The relationship between the data for three consecutive years is shown to be significant with correlation coefficient of around 0,8. This means that the data distributions have similar pattern in between years even on 10-minute resolution. Results for the wind speed data showed that the data cannot be pronounced with linear regression line in between years and their relationship is not significant. It confirms the fact that the wind speed, as a renewable resource, is very hard to predict, with a variable pattern on 10-minute resolution in between years. Results of the analyses of the third and fourth group of data, based on 10-minute resolution, in between the selected data for all three years, showed that the relationship between the data cannot be pronounced with linear regression line since it was not significant. This means that none of the data can be used to predict other type of the selected data on 10-minute resolution. 10-minute resolution analyses can provide more details and insight in a real state of the system. These analyses present an upgrade according to the previous literature and give an insight in possible weather cast on 10-minute resolutions.

The analyses of the SWHP district heating and cooling system, in the old city of Dubrovnik, showed the ability of the system to utilize high share of RES electricity production. Results of the scenario 1 showed that the combination of WPP and SPP in electricity production, in case C, provides more opportunities for RES utilization than stand-alone WPP or SPP. RES production, in case C, was able to cover up to 67% of electricity demand of the stand-alone SWHP system. Adding TES and BES to the SWHP system in other two scenarios and their comparison resulted in 60 – 78% of ES cost and volume reduction in case C with

combined RES production. It is shown that BES requires 13 times higher cost, but 40 times lower volume in each case in comparison to TES.

New algorithm for energy planning is developed, based on hourly and 10-minute data input, according to EnergyPLAN model. Comparison of the results, gained by a new model and EnergyPLAN, showed that models provide similar results on hourly and 10-minute data base, which approved validity of a new model. Transport sector of the selected area is analysed in a new model for four different cases. Results of a case 1 showed no significant difference between hourly (standard charging and discharging) and 10-minute (extreme fast charging and discharging) based model after the implementation of regulated V2G model. Implementation and regulation of V2G model led to about 60 – 70% decrease in export, while import was still high. Case 1 presented the limiting case when all of V2G, available for charging and discharging at the given moment, are able to be connected to the grid. Adding HPP Dubrovnik to the electricity production, in case 2, led to decrease of import by 97%, while export increased by 15 times. Case 3 analysed the minimum BEV capacity required in order to gain the same results as the one gained by a limiting case, case 1. Comparison of hourly and 10-minute model in case 3 showed that regulated V2G model of extreme fast charging and discharging, requires only 3% V2G vehicles to be connected to the grid in each time step, while standard charging and discharging resulted in 80% of V2G connection. When compared on hourly basis, regulated V2G model of extreme fast charging and discharging can provide 7 times more flexibility to the system, than the standard one. Due to that, regulated V2G model of extremely fast charging and discharging could enhance the integration of high share of RES production in the system. Results of the case 4 showed that, the replacement od P2T model in electricity prices with V2T model and the implementation of regulated V2G model of extreme fast charging and discharging, could provide saving for EV owners. Highest savings are provided by 10-minute model, about 200 EUR/year per EV.

The results of the analyses, done using a new model, showed that the regulated V2G model of extreme fast charging and discharging could provide higher flexibility to the electrical power system. 10-minute based model provided more details on a real state of the system and enabled better integration of high share of intermitted RES production. The implementation of V2T model could enhance participants of the system to take active action and earn savings if they are stimulated with electricity prices.

Upgrade of the new model in Calliope showed that the 100% renewable self-sufficient system of a wider urban area can be achieved through the integration and electrification of transport and thermal sectors, connection through the open electricity market based on variable

electricity prices and additional storage facilities. Calliope model was developed on hourly and 10-minute data base. The result showed that 10-minute model can provide more details for electricity market development and more favourable market valuation of flexible sources, since it provides opportunity for the integration of more different sources of flexibility. It enables safer integration of high share of RES, which was manifested in the reduction of cross-border transmission capacities and contributed to the system stability. The total reduction of cross-border transmission capacities was about 60% compared to the hourly model. 10-minute model provided safer system operation by equalizing import and export capacities, which contributed to the reduction of the difference between import and export by 7 times compared to the hourly model.

KLJUČNE RIJEČI

energetsko planiranje, obnovljivi izvori energije, električna vozila, dizalice topline, spremnici energije, tržište električne energije, fleksibilnost, vozila-na-mreži

KEY WORDS

energy planning, renewable energy sources, electric vehicles, heat pumps, energy storage, electricity market, flexibility, vehicle-to-grid

SADRŽAJ

INFORMACIJE O MENTORU I

ZAHVALE II

PODACI O BIBLIOGRAFIJI III

SAŽETAK IV

EXTENDED SUMMARY V

KLJUČNE RIJEČI XII

SADRŽAJ XIII

POPIS SLIKA XVII

POPIS TABLICA XX

POPIS OZNAKA XXIV

POPIS SKRAĆENICA XXVIII

1 UVOD 1

1.1 Energetski sustavi s visokim udjelom OIE u proizvodnji energije 3

1.2 Energija Sunca i vjetra 6

1.2.1 Iskorištavanje energije Sunca 6

1.2.2 Iskorištavanje energije vjetra 7

1.2.3 Integracija FN i VE sustava u proizvodnje električne energije 8

1.3 Fleksibilnost elektroenergetskog sustava 12

1.4 Električna vozila 17

1.5 Dizalice topline 20

1.5.1 Dizalica topline s izvorom morske vode 21

1.6 Skladištenje energije 21

1.6.1 Baterije EV i model V2G – mobilni energetski spremnik 22

1.6.2 Baterije EV i B2U – stacionarni energetski spremnik 24

1.6.3 Vodik 25

1.6.4 Toplinski i rashladni spremnici energije 28

1.7 Tržište električnom energijom 29
1.8 Cilj i hipoteze istraživanja 31
1.9 Očekivani znanstveni doprinos 31
2 METODE I PODACI 32
2.1 Definiranje granica sustava 35
2.2 Fleksibilnost odabranog elektroenergetskog sustava šireg gradskog područja 37
2.3 Potencijal OIE za proizvodnju električne energije na odabranom području 39
2.3.1 Energija iz Sunca 39
2.3.2 Energija iz vjetra 41
2.3.3 Hidroenergija 45
2.3.4 Energija biomase 47
2.3.5 Geotermalna energija 47
2.3.6 Energija mora – DTMV 48
2.4 Potrošnja energije na odabranom području 48
2.4.1 Opća potrošnja električne energije – opterećenje TS Komolac 48
2.4.2 Konvencionalna i električna vozila 49
2.4.3 Potrošnja energije za grijanje i hlađenje 50
2.5 Energetski sustav – prijenos prekograničnih dalekovoda i distribucija i opskrba 52
2.6 Skladištenje energije 54
2.6.1 Baterije EV – mobilni i stacionarni spremnici energije 54
2.6.2 SEV – stacionarni spremnici energije 54
2.6.3 TES i RES – stacionarni spremnici energije 55
2.7 Linearna korelacija i regresija 56
2.7.1 Ulazni podaci za statističke analize 61
2.8 Daljinsko grijanje i hlađenje sa sustavom DTMV za područje Starog grada Dubrovnika 65
2.8.1 Sustav DTMV u Starom gradu Dubrovniku 66

2.9 Energetski plan do 2050. godine 70
2.9.1 Planirana proizvodnja električne energije do 2030. i 2050. godine 70
2.9.2 Planirana potrošnja i skladištenje električne energije do 2030. i 2050. godine 73
2.10 Novi algoritam satnog i 10-minutnog modela za integraciju OIE regulacijom modela V2G po uzoru na EnergyPLAN 80
2.10.1 Izrada algoritma novog modela i opis scenarija 83
2.11 EnergyPLAN model 91
2.11.1 Opis EnergyPLAN modela 92
2.12 Integracija transportnog i toplinskog sektora 100% obnovljivog šireg gradskog područja 96
2.12.1 Izrada energetskog plana samodostatnog šireg gradskog područja do 2050. godine nadogradnjom novog modela u programu Calliope 96
2.12.2 Tržišno vrednovanje izvora fleksibilnosti u sustavu 104
3 REZULTATI 105
3.1 Linearne korelacijske i regresijske veze između parametara 105
3.1.1 Rezultati analiza prve grupe podataka za vremenski korak od 10 minuta i razdoblje od tri uzastopne godine 105
3.1.2 Rezultati analize druge grupe podataka koje se temelje na srednjim mjesečnim vrijednostima 107
3.1.3 Rezultati analize treće grupe podataka za 10-minutni vremenski korak 109
3.1.4 Rezultati analize četvrte grupe podataka za vremenski korak od 10 minuta za zimski i ljetni period 111
3.2 Daljinski sustav grijanja i hlađenja DTMV sa i bez skladišta energije za područje Starog grada, Dubrovnik 114
3.2.1 Rezultati scenarija 1 116
3.2.2 Rezultati scenarija 2 i 3 118
3.3 Rezultati analiza scenarija u novom modelu 119
3.3.1 Rezultati scenarija za slučaj S1 i usporedba novog modela i modela EnergyPLAN 120

3.3.2 Rezultati scenarija za slučaj S2 133
3.3.3 Rezultati scenarija za slučaj S3 134
3.3.4 Rezultati scenarija za slučaj S4 137
3.4 Rezultati energetskog plana u programu Calliope – integracija transportnog i toplinskog sektora 142
3.4.1 Usporedba novog algoritma s programom Calliope za slučaj S1 142
3.4.2 Rezultati modela 100% obnovljivog energetskog sustava šireg gradskog područja u programu Calliope 151
4 ZAKLJUČAK I PREPORUKE 158
4.1 Komplementarnost OIE u proizvodnji električne energije – energija vjetra i sunčeva energija 158
4.2 Integracija visokog udjela OIE proizvodnji električne energije uvođenjem sustava DTMV s ES 159
4.3 Integracija visokog udjela OIE u proizvodnji električne energije uvođenjem EV i reguliranog modela V2G – usporedba standardnog i iznimno brzog punjenja EV 160
4.3.1 Integracija VE i SE u proizvodnji električne energije uz 100% EV i regulirani model V2G 160
4.3.2 Integracija VE, SE i HE Dubrovnik u proizvodnji električne energije uz 100% EV i regulirani model V2G 161
4.3.3 Usporedba standardnog i iznimno brzog punjenja EV uvođenjem reguliranog modela V2G u integraciji 100% OIE u proizvodnji električne energije 161
4.3.4 Usporedba P2T i V2T modela cijena električne energije 162
4.4 100% obnovljiv energetski sustav šireg gradskog područja 162
4.5 Preporuke za računalne alate i modele naprednog energetskog planiranja 163
LITERATURA 165
PRILOG 1 182
ŽIVOTOPIS 192

POPIS SLIKA

Slika 1. Fleksibilnost elektroenergetskog sustava: zahtjevi i izvori fleksibilnosti [70].....14
Slika 2. Koraci i metode u planiranju energetski samodostatnog šireg gradskog područja 34
Slika 3. Tok razvoja novog modela, validacija i nadogradnja.....35
Slika 4. Shema distribucijske mreže, [156] 37
Slika 5. Lokacija i granice odabranog šireg gradskog područja 37
Slika 6. Fleksibilnost elektroenergetskog sustava odabranog šireg gradskog područja 38
Slika 7. Karta srednje godišnje ozračenosti na području Dubrovačko-neretvanske županije, [37] 40
Slika 8. Prikaz karte s označenim potencijalnim lokacijama za odabrano području, [36] 41
Slika 9. Karta vjetra za područje Dubrovačko-neretvanske županije, [37] 42
Slika 10. Trenutno stanje korištenja vjetropotencijala na području DNŽ, [37].....43
Slika 11. Prikaz prijedloga lokacija za izgradnju SE i VE, [36].....44
Slika 12. Proizvodnja električne energije HE Dubrovnik za 2014. godinu 46
Slika 13. Potencijal primjene daljinskog grijanja za odabrano šire gradsko područje [155]...52
Slika 14. Shema EES – šire gradsko područje Dubrovnika i veza s ostatkom Hrvatske i susjednim EES - izvor HOPS 53
Slika 15. Princip rada i energetski tokovi u sustavu SEV.....55
Slika 16. Prikaz energetskih tokova u sustavu DTMV s TES i RES.....56
Slika 17. Dijagram toka za ispitivanje linearne i regresijske veze među podacima 59
Slika 18. Godišnja raspodjela normaliziranih srednjih mjesečnih vrijednosti sunčeva zračenja, brzine vjetra, temperature zrak i potrošnje električne energije za odabrano šire gradsko područje.....62
Slika 19. Dnevne 10-minutne normalizirane vrijednosti odabranih varijabli za jedan dan ljeta i zime u 2013. godini.....63
Slika 20. Dnevne 10-minutne normalizirane vrijednosti odabranih varijabli za jedan dan ljeta i zime u 2014. godini.....64
Slika 21. Model scenarija za sustav DTMV 66
Slika 22. Shema procesa grijanja DTMV 67
Slika 23. Potrošnja električne energije za odabrano šire gradsko područje, prva srijeda u mjesecu siječnju u 2014. godini.....75
Slika 24. Satne krivulje potrošnje električne energije za 2020., 2030. i 2050. godinu.....75
Slika 25. Potrošnja električne energije za punjenje EV za jedan dan u 2050. godini.....80

Slika 26. Dijagram toka nereguliranog sustava s EV i reguliranog sustava primjenom V2G i G2V modela 87
Slika 27. Prikaz metode usporedbe i validacije rezultata korištenih modela za energetsko planiranje 90
Slika 28. Model energetskog sustava odabranog područja u programu Calliope prema scenariju S1 100
Slika 29. Energetski tokovi baterije EV – punjenje i pražnjenje baterije 102
Slika 30. Model 100% obnovljivog energetskog sustava šireg gradskog područja do 2050. godine u programu Calliope 103
Slika 31. Godišnja raspodjela potreba električne energije za rad dizalice topline za vremenski korak od 1 sat i 10 minuta 115
Slika 32. Usporedba normaliziranih vrijednosti proizvodnje električne energije iz OIE i potreba DTMV za jedan odabrani dan sezone grijanja i hlađenja za vremenski korak od 1 sat i 10 minuta 117
Slika 33. Rezultati scenarija 1 118
Slika 34. Smanjenje emisija CO_2 iskorištenjem proizvodnje električne energije iz OIE 118
Slika 35. Usporedba rezultata energetskog plana sustava u novom algoritmu s reguliranim i nereguliranim punjenjem i pražnjenjem EV za odabrani ljetni i zimski period za 2030. i 2050. godinu 127
Slika 36. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_1h_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV 129
Slika 37. Prikaz energetskih tokova u bateriji EV i kapaciteta baterije za regulirani sustav standardnog punjenja i pražnjenja, 15. siječnja za scenarij 2050_1h_S1. 129
Slika 38. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_10min_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV 131
Slika 39. Prikaz energetskih tokova u bateriji EV i kapaciteta baterije za regulirani sustav brzog punjenja i pražnjenja, 15. siječnja za scenarij 2050_10 min_S1. 131
Slika 40. Prikaz energetskih tokova za 16. srpnja za scenarij 2050_10min_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV 132
Slika 41. Prikaz energetskih tokova u bateriji EV i kapaciteta baterije za regulirani sustav brzog punjenja i pražnjenja, 16. srpnja za scenarij 2050_10 min_S1. 132
Slika 42. Usporedba rezultata scenarija za slučaj S1 sa S2 za 2030. i 2050. godinu i model brzog i standardnog punjenja 134

Slika 43. Usporedba rezultata standardnog i iznimno brzog punjenja i pražnjenja EV primjenom reguliranog modela G2V i V2G za jedan sat 136
Slika 44. Analiza troškova u slučaju S4 za 2050. godinu prema S1 i S3 – usporedba P2T s V2T modelom cijena električne energije u regulaciji standardnog i brzog punjenja i pražnjenja. 140
Slika 45. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_1h_S1 s usporedbom neregulirano g i reguliranog punjenja i pražnjenja EV u novom algoritmu 144
Slika 46. Prikaz energetskih tokova u BEV i kapaciteta baterije za regulirani sustav standardnog punjenja i pražnjenja u novom algoritmu, 15. siječnja za scenarij 2050_1h_S1 144
Slika 47. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_1h_S1 s usporedbom neregulirano g i reguliranog punjenja i pražnjenja EV u programu Calliope 145
Slika 48. Prikaz energetskih tokova u BEV za neregulirani i regulirani sustav standardnog punjenja i pražnjenja u programu Calliope, dan zime. Lijevi dijagram – neregulirani sustav; desni dijagram – regulirani sustav 145
Slika 49. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_10 min_S1 s usporedbom neregulirano g i reguliranog punjenja i pražnjenja EV u novom algoritmu 148
Slika 50. Prikaz energetskih tokova u BEV i kapaciteta baterije za regulirani sustav brzog punjenja i pražnjenja u novom algoritmu, 15. siječnja za scenarij 2050_10 min_S1 148
Slika 51. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_10 min_S1 s usporedbom neregulirano g i reguliranog punjenja i pražnjenja EV u programu Calliope 149
Slika 52. Prikaz energetskih tokova u BEV i kapaciteta baterije za neregulirani i regulirani sustav punjenja i pražnjenja u programu Calliope, 15. siječnja za scenarij 2050_10 min_S1 150
Slika 53. Prikaz tokova električne energije prema mreži za jedan odabrani dan za satni i 10-minutni model proračuna u programu Calliope 153
Slika 54. Prikaz energetskih tokova toplinske energije i električne energije u EV za satni i 10-minutni model u programu Calliope 154
Slika 55. Energetski tokovi u i kapaciteti skladišta energije u satnom i 10-minutnom modelu dobiveni u programu Calliope 155
Slika 56. Usporedba rezultata novog modela za slučaj S1 i S2, te Calliope modela za scenarij 2050. godine za vremenski korak od 1 h i 10 minuta 157

POPIS TABLICA

Tablica 1. Usporedba KV s EV, te usporedba različitih vrsta EV i punionica na temelju tehničkih i financijski aspekata prema prethodnim studijama. 19
Tablica 2. Validacija podataka sunčeva zračenja za 2014. godinu za vremenski korak od 1 sata i 10 minuta 40
Tablica 3. Popis potencijalnih lokacija za SE odobrenih Planom [36] za odabrano područje 41
Tablica 4. Validacija podataka brzina vjetra za 2014. godinu za vremenski korak od 1 sat i 10 minuta 44
Tablica 5. Validacija podataka proizvodnje električne energije iz HE Dubrovnik za vremenski korak od 1 sata i 10 minuta 46
Tablica 6. Validacija podataka o potrošnji električne energije na TS Komolac 49
Tablica 7. Broj osobnih vozila u Hrvatskoj i Dubrovniku u 2010. godini 50
Tablica 8. Validacija podataka o broju vozila za 2010. i 2014. godinu 50
Tablica 9. Toplinske i rashladne potrebe odabranog šireg gradskog područja gada Dubrovnika za 2014. godinu 51
Tablica 10. Učinkovitosti sustava SEV, [149] 55
Tablica 11. Koeficijent regresije 60
Tablica 12. Godišnje maksimalne i minimalne vrijednosti analiziranih varijabli 62
Tablica 13. Termodinamičke veličine DTMV u Starom gradu 67
Tablica 14. Ulazni podaci 68
Tablica 15. Srednje mjesečne vrijednosti brzine vjetra i sunčeva zračenja za Dubrovačku regiju za 2014. godinu 69
Tablica 16. Financijske i tehničke karakteristike TES i BES 70
Tablica 17. Karakteristike odabranog FN modula 70
Tablica 18. Podaci korišteni za određivanje instalirane snage FN sustava na građevinama za 2030. i 2050. godinu 72
Tablica 19. Instalirana snaga SE i FN sustava za proizvodnju električne energije na odabranom području za 2030. i 2050. godinu 72
Tablica 20. Instalirana snaga VE za proizvodnju električne energije na odabranom području za 2030. i 2050. godinu 73
Tablica 21. Instalirana snaga HE za proizvodnju električne energije na odabranom području za 2030. i 2050. godinu 73
Tablica 22. Potrošnja električne energije za Hrvatsku i Dubrovnik do 2050. godine 74

Tablica 23. Toplinske i rashladne potrebe za odabrano šire gradsko područje do 2030. i 2050. godine....76
Tablica 24. Predviđena potrošnja toplinske i rashladne energije za grijanje i hlađenje prostora na sustave DTMV za 2030. i 2050. godinu....77
Tablica 25. Broj EV u Hrvatskoj i Dubrovniku za svaki od budućih scenarija....77
Tablica 26. Podaci o broju EV, HEV i PHEV u RH za 2020. godinu, [181]....78
Tablica 27. Karakteristike baterija EV....79
Tablica 28. Karakteristike punjenja EV za jedan dan....79
Tablica 29. Opis scenarija i slučaja ispitivanih u analizama u novom modelu....89
Tablica 30. Rezultati analize prve grupe podataka za uzastopne tri godine za vremenski korak od 10 minuta....106
Tablica 31. Rezultati analize druge grupe podataka koji se temelje na srednjim mjesečnim vrijednostima odabranih parametara....108
Tablica 32. Rezultati analize treće grupe podataka čije se vrijednosti temelje na 10-minutnom vremenskom koraku....109
Tablica 33. Rezultati linearne korelacije i regresija za ljetni i zimski period za 2012. godinu....112
Tablica 34. Rezultati linearne korelacije i regresija za ljetni i zimski period za 2013. godinu....113
Tablica 35. Rezultati linearne korelacije i regresija za ljetni i zimski period za 2014. godinu....114
Tablica 36. Maksimalne vrijednosti proizvodnje električne energije iz OIE i potrebe električne energije za rad DTMV za jedan odabrani dan u sezoni grijanja i hlađenja....116
Tablica 37. Rezultati scenarija 2 i 3....119
Tablica 38. Ulazni podaci za novi model i EnergyPLAN za vremenski korak od 1 sat....120
Tablica 39. Rezultati dobiveni proračunom u EnergyPLAN-u za energetski plan odabranog područja za 2030. godinu i za satni model....121
Tablica 40. Rezultati dobiveni proračunom u novom algoritmu za energetski plan odabranog područja za 2030. godinu za satni model i 10-minutni model....121
Tablica 41. Rezultati dobiveni proračunom u novom algoritmu za energetski plan odabranog područja za 2050. godinu za satni model i 10-minutni model....123
Tablica 42. Utjecaj regulacije standardnog i brzog punjenja EV na smanjenje vršnih opterećenja proizvodnje električne energije iz OIE....123

Tablica 43. Ulazni podaci za novi model i EnergyPLAN za vremenski korak od 10 minuta 124
Tablica 44. Rezultati proračuna u EnergyPLAN-u za lipanj i srpanj 2030. godine za vremenski korak od 1 sat i 10 min.....125
Tablica 45. Rezultati proračuna u novom algoritmu za lipanj i srpanj 2030. godine za vremenski korak od 1 sat i 10 minuta.....125
Tablica 46. Rezultati proračuna u novom algoritmu za lipanj i srpanj 2050. godine za vremenski korak od 1 sat i 10 minuta.....126
Tablica 47. Rezultati proračuna u novom algoritmu za studeni i prosinac 2030. godine za vremenski korak od 1 sat i 10 minuta 127
Tablica 48. Rezultati proračuna u novom algoritmu za studeni i prosinac 2050. godine za vremenski korak od 1 sat i 10 minuta 127
Tablica 49. Usporedba scenarija S1 za 2050. godinu za 1 sat i 10 minuta i period ljeta i zime za jedan odabrani dan u godini 130
Tablica 50. Rezultati slučaja S2 za 2030. godinu za model brzog i standardnog punjenja EV 134
Tablica 51. Rezultati slučaja S2 za 2050. godinu za model brzog i standardnog punjenja EV 134
Tablica 52. Rezultati potrebne minimalne BEV za standardno i brzo punjenje i pražnjenje EV u slučaju S3 za jednak rezultat smanjenja uvoza i izvoza kao u slučaju S1 135
Tablica 53. Usporedba rezultata za brzo i standardno punjenje i pražnjenje EV kod minimalne baterije na raspolaganju za punjenje i pražnjenje za 2030. godinu.....136
Tablica 54. Usporedba rezultata za brzo i standardno punjenje i pražnjenje EV kod minimalne baterije na raspolaganju za punjenje i pražnjenje za 2050. godinu.....137
Tablica 55. Rezultati scenarija za 2050. godinu za slučaj S4 – usporedba P2T i V2T modela cijena u regulaciji standardnog i brzog punjenja i pražnjenja EV 139
Tablica 56. Usporedba rezultata novog algoritma i programa Calliope za 15.01.2050. godine za slučaj S1 i vremenski korak od 1 sat 143
Tablica 57. Usporedba rezultata novog algoritma i programa Calliope za 2050. godinu za slučaj S1 i vremenski korak od 1 sat.....146
Tablica 58. Usporedba rezultata novog algoritma i programa Calliope za 15.01.2050. godine za slučaj S1 i vremenski korak od 10 minuta 147
Tablica 59. Usporedba rezultata novog algoritma i programa Calliope za 2050. godinu za slučaj S1 i vremenski korak od 10 minuta 151

Tablica 60. Rezultati proračuna i analize 100% obnovljivog energetskog sustava šireg gradskog područja u programu Calliope, za vremenski korak od 1 sat i 10 minuta za jedan odabrani dan u godini 152
Tablica 61. Rezultati proračuna i analize 100% obnovljivog energetskog sustava šireg gradskog područja u programu Calliope, za vremenski korak od 1 sat i 10 minuta za 2050. godinu...156

POPIS OZNAKA

Oznaka	Opis	Jedinica
$\widehat{x_i}$	Nezavisna varijabla	-
$\widehat{y_i}$	Zavisna varijabla	-
$C_{Charger}$	Opterećenje elektroenergetske mreže od priključenih EV na mrežu	MW
C_i	Trošak punjenja EV u jednom vremenskom trenutku	kn
D_{BEV}	Ukupna godišnja potrošnja električne energije u prometu za EV	TWh/god.
D_{V2G}	Ukupna godišnja potrošnja električne energije za pametno punjenje EV i V2G	TWh/god.
$E_{DEM,i}$	Opća potrošnja električne energije za jedan vremenski korak preuzeta s TS Komolac	MWh, MW·10min
$E_{ES,i}$	Kapacitet ES za jedan vremenski korak	MWh, MW·10min
$E_{ES,i-1}$	Kapacitet ES u prethodnom vremenskom koraku	MWh, MW·10min
$E_{ES,max}$	Maksimalni kapacitet ES	MWh, MW·10min
$E_{EV,FD,max,i/6}$	Maksimalna energija za brzo pražnjenje EV u 10 minuta	MW·10min
$E_{EV,SD,max,i}$	Maksimalna energija za standardno pražnjenje EV za jedan sat	MWh
$E_{EV,dem,i}$	Potrošnja električne energije za punjenje EV za jedan vremenski korak prema potrebama i navikama potrošača	MWh, MW·10min
$E_{EV,dem,i+1}$	Potrošnja električne energije za punjenje EV za sljedeći vremenski korak prema potrebama i navikama potrošača (vozila koja se voze u vremenskom koraku i)	MWh, MW·10min
$E_{EV,dem,i+2}$	Potrošnja električne energije za punjenje EV za sljedeća dva vremenska koraka prema potrebama i navikama potrošača	MWh, MW·10min
$E_{EXP,i}$	Izvoz električne energije u jednom vremenskom trenutku	MWh, MW·10min
$E_{G2V,i}$	Raspoloživi kapacitet baterije EV za punjenje za jedan vremenski korak	MWh, MW·10min
$E_{G2V,max,i}$	Maksimalni mogući kapacitet baterije za punjenje EV u jednom vremenskom koraku	MWh, MW·10min
$E_{IMP,i}$	Uvoz električne energije u jednom vremenskom trenutku	MWh, MW·10min
E_{JZ}	Potrošnja električne energije u sektoru javnih zgrada	GWh/god.
E_K	Potrošnja električne energije u sektoru kućanstva	GWh/god.
$E_{RES,i}$	Proizvodnja električne energije iz OIE za jedan vremenski korak	MWh, MW·10min
$E_{SWHP,i}$	Potrošnja električne energije za rad DTMV za jedan vremenski korak	MWh, MW·10min

E_T	Potrošnja električne energije u tercijarnom sektoru	GWh/god.
$E_{V2G,i}$	Raspoloživi kapacitet baterije EV za pražnjenje za jedan vremenski korak	MWh, MW·10min
$E_{V2G,max,i}$	Maksimalni mogući kapacitet baterije za pražnjenje EV u jednom vremenskom koraku	MWh, MW·10min
$E_{batt,SC,max,i}$	Maksimalna akumulirana energije za jedan sat za standardno punjenje EV	MWh
$E_{batt,FC,max,i/6}$	Maksimalna akumulirana energije u 10 minuta za brzo punjenje EV	MW·10min
$E_{batt,i}$	Raspoloživi kapacitet baterije EV u trenutnom vremenskom koraku	MWh, MW·10min
$E_{batt,i-1}$	Raspoloživi kapacitet baterije EV iz prethodnog vremenskog koraka	MWh, MW·10min
$E_{batt,max,i}$	Maksimalni kapacitet baterije EV za jedan vremenski korak	MWh, MW·10min
$E_{batt,uk}$	Ukupni kapacitet baterije svih EV	MWh
E_i	Zarada pražnjenjem EV u jednom vremenskom trenutku	kn
N_{Ch}	Broj punjenja u jednome danu	-
N_{EV}	Broj EV za punjenje u jednome danu	-
$N_{L,uk}$	Ukupan broj velikih EV	-
$N_{M,uk}$	Ukupan broj srednjih EV	-
$N_{S,uk}$	Ukupan broj malih EV	-
$P_{FC,uk,i/6}$	Ukupna snaga za brzo punjenje EV u 10 minuta	MW
P_{FC}	Snaga iz mreže za brzo punjenje EV	kW
$P_{L,FC}$	Potrebna snaga iz mreže za brzo punjenje velikih EV	kW
$P_{L,SC}$	Potrebna snaga iz mreže za standardno punjenje velikih EV	kW
$P_{M,FC}$	Potrebna snaga iz mreže za brzo punjenje srednjih EV	kW
$P_{M,SC}$	Potrebna snaga iz mreže za standardno punjenje srednjih EV	kW
$P_{S,FC}$	Potrebna snaga iz mreže za brzo punjenje malih EV	kW
$P_{S,SC}$	Potrebna snaga iz mreže za standardno punjenje malih EV	kW
$P_{SC,uk,i}$	Ukupna snaga za standardno punjenje EV u jednome satu	MW
P_{SC}	Snaga iz mreže za standardno punjenje EV	kW
P_i	Cijena električne energije u jednom vremenskom trenutku	kn/kWh, kn/kW·10min
SS_{xx}	Suma kvadrata varijable x	-
SS_{xy}	Suma umnožaka varijabli x i y	-
SS_{yy}	Suma kvadrata varijable y	-
$S_{V2G-Battery}$	Kapacitet baterije EV	GWh
T_P	Unutarnja temperatura zraka	°C

T_V	Vanjska temperatura zraka	°C
$V2G_{Connection-Share}$	Udio parkiranih V2G vozila spojenih na mrežu	%
$V2G_{MaxShare}$	Maksimalni udio vozila u vožnji u satu vršne potrošnje	%
c_{V2G}	Opterećenje priključka ukupnog V2G voznog parka na mrežu na satnoj osnovi	kWh
d_{BEV}	Satna potrošnja električne energije u prometu za EV	kWh
d_E	Opća potrošnja električne energije	kWh
d_{Total}	Ukupna potrošnja električne energije	kWh
d_{V2G}	Satna potrošnja električne energije za pametno punjenje EV i V2G	kWh
e_{Charge}	Punjenje baterije EV	kWh
e_{CEEP}	Višak proizvodnje električne energije	kWh
e_{Inv}	Dostupna energije pohranjena u baterijama nakon vožnje	kWh
e_{PP}	Višak ili manjak proizvodnje električne energije	kWh
e_{Res}	Proizvodnja energije iz OIE	kWh
e_{Res1}	Proizvodnja energije iz jednog od OIE	kWh
e_{Res2}	Proizvodnja energije iz jednog od OIE	kWh
e_{Total}	Ukupna proizvodnja energije	kWh
$e_{el.en.,JZ}$	Udio potrošnje električne energije u neposrednoj potrošnji finalne energije za sektor javnih zgrada	%
$e_{el.en.,K}$	Udio potrošnje električne energije u neposrednoj potrošnji finalne energije za sektor kućanstva	%
$e_{el.en.,T}$	Udio potrošnje električne energije u neposrednoj potrošnji finalne energije za tercijarni sektor	%
$e_{el.en.}$	Udio potrošnje električne energije u neposrednoj potrošnji finalne energije za tri sektora	%
$e_{max,i}$	Maksimalni kapacitet baterije u svakom vremenskom trenutku	%
r^2	Koeficijent determinacije	-
$s_{V2G-Battery}$	Novi sadržaj baterije	kWh
$s_{V2G-Battery-min}$	Minimalna količina energije u bateriji	kWh
t_{V2G}	Pražnjenje baterije EV uzrokovano vožnjom	kWh
δ_{V2G}	Distribucija satne krivulje potrošnje u transportu od 8784 satne vrijednosti	-
η_{CHARGE}	Efikasnost punjenja EV	%
η_{ch}	Efikasnost punjenja EV	%
η_{disch}	Efikasnost pražnjenja EV	%
μ_{Charge}	Efikasnost mreže spojene na bateriju (punjač)	%
μ_{Inv}	Efikasnost baterije spojene na mrežu (inverter)	%

a	Konstanta, očekivana vrijednost zavisne varijable kada je nezavisna varijabla nula	-
b	Koeficijent regresije koji pokazuje prosječnu promjenu zavisne varijable uzrokovanu promjenom nezavisne varijable	-
CFX	Maksimalna potrošnja električne energije	kWh
DD	Stupanj sat ili 10 minuta	°C
E_n	Potrošnja električne energije	kWh, kW·10min
I_n	Sunčevo zračenje	J/cm^2
STP	Potrošnja toplinske energije	MWh
THP	Ukupna proizvodnja toplinske energije	MWh
T_n	Temperatura zraka	°C
V_n	Brzina vjetra	m/s
P	Snaga iz mreže za punjenje EV	kWh
r	Koeficijent korelacije	-

POPIS SKRAĆENICA

4GDG – daljinsko grijanje 4. generacije

4GDH – *"4th generation district heating"*

Ar – argon

B2U – baterijska sekundarna upotreba (*"battery second use"*)

BES – baterijski energetski spremnik

BEV – baterija električnog vozila

CEEP – kritični višak proizvodnje električne energije, (*"critical excess in electricity production"*)

CH_4 – metan

CO – ugljikov monoksid

CO_2 – ugljikov dioksid

COP – faktor grijanja, (*"Coefficient Of Performance"*)

DG – daljinsko grijanje

DGH – daljinsko grijanje i hlađenje

DHMZ – Državni hidrometeorološki zavod

DNŽ – Dubrovačko-neretvanska županija

DT – dizalica topline

DTMV – dizalica topline s izvorom morske vode

DV – dalekovod

DZS – Državni zavod za statistiku

EEM – elektroenergetska mreža

EES – elektroenergetski sustav

ES – energetski spremnik

EU – Europska unija

EV – električna vozila

FBiH – Federacija Bosne i Hercegovine

FN – fotonaponska ćelija

G2V – mreža na vozilo, (*"grid-to-vehicle"*)

H_2 – vodik

HE – hidroelektrana

HEP – Hrvatska elektroprivreda

HEV – hibridna električna vozila

HOPS – Hrvatski operator distribucijskog sustava

IKT – informacijske i komunikacijske tehnologije, (*''ICT-tools, information and communication technologies''*)

KV – konvencionalna vozila

LCOH – nivelirani trošak topline, (*''levelised cost of heat''*)

LOHC – *''liquid organic hydrogen carriers''*

MUP – Ministarstvo unutarnjih poslova

N_2 – dušik

NOS – neovisni operateri sustava

ODS – operator distribucijskog sustava

OIE – obnovljivi izvori energije

P2T – postojeći dvotarifni sustav

PHEV – vozila na hibridni pogon s vanjskim punjenjem (*''plug in hybrid electric vehicle''*)

PMR - parno-metanski reformer (*''SMR – steam-methane reformer''*)

PTV – potrošna topla voda

RES – rashladni energetski spremnik

RH – Republika Hrvatska

RP – rasklopno postrojenje

SCOP – sezonski faktor grijanja, (*''Seasonal Coefficient Of Performance''*)

SE – sunčana elektrana

SEER – sezonski faktor hlađenja SEER, (*''Seasonal Energy Efficiency Ratio''*)

SEV – spremnik energije vodika

SOC – stanje napunjenosti baterije, (*''state of charge''*)

TES – toplinski energetski spremnik

TS – trafostanica

UNESCO – *''The United Nations Educational, Scientific and Cultural Organization''*

UNP – ukapljeni naftni plin

V2G – vozila na mreži (*''vehicle-to-grid''*)

V2T – varijabilni dvotarifni sustav

VE – vjetroelektrana

ZK – Zelena knjiga

1 UVOD

Porast udjela stakleničkih plinova u atmosferi, koji uzrokuju zagađenje zraka i ubrzani porast globalne temperature, predstavljaju problem na globalnoj razini. U njegovu rješavanju sudjeluje većina zemalja u svijetu na razne načine. Prvotni način rješavanja, odnosno umanjivanja problema, jesu zakoni, direktive i strategije koje izdaju i potpisuju zemlje diljem svijeta. Njihovom primjenom i realizacijom nastoji se smanjiti utjecaj na klimatske promjene. Pariški sporazum o klimatskim promjenama spada u one novijeg datuma [1]. Glavni cilj Pariškog sporazuma je ojačati borbu s klimatskim promjenama i ograničiti globalno zatopljenje zadržavanjem povećanja porasta globalne temperature znatno ispod 2°C u usporedbi s predindustrijskim razdobljem, te ulaganjem napora u ograničavanje povišenja temperature iznad 1,5°C iznad razine u predindustrijskom razdoblju. Smatra se da će se tim naporima smanjiti rizici i utjecaji klimatskih promjena. Sporazum je 2016. godine ratificirala Europska unija (EU) a potpisalo ga je 196 zemalja. Republika Hrvatska (RH), kao članica EU, također je supotpisnica sporazuma.

Najveći utjecaj na porast stakleničkih plinova i na klimatske promjene imaju fosilna goriva. Ulaganjem napora u zamjenu fosilnih goriva s alternativnim obnovljivim izvorima energije (OIE) mogu se postići dobri rezultati u smanjenju emisija u svim sektorima. Jedni od najvećih udjela u emisijama stakleničkih plinova otpadaju na proizvodnju električne energije, transportni i toplinski sektor. Ulaganjem napora u tim sektorima i uvođenjem promjena mogu se postići dobri rezultati u širem opsegu. Transportni sektor u EU zauzima 20% udjela u emisijama stakleničkih plinova i 31,7% u konačnoj potrošnji energije [2]. Jedan od načina postizanja ciljeva u smanjenju staklenički plinova jest zamjena fosilnih goriva u transportu i proizvodnji energije uvođenjem električnih vozila (EV) i OIE. Korištenje EV može utjecati na 10 do 24% smanjenja stakleničkih plinova u odnosu na konvencionalna vozila (KV) [3].

Predviđanja u potrošnji energije do 2030. pokazuju njen globalni porast od 50%, što ukazuje na potrebu za novim izvorima energije u budućnosti i održivom razvoju. EU teži razvitku održivog, konkurentnog, sigurnog i niskougljičnog energetskog sustava do 2050. Shodno tome, Pariškom sporazumu su prethodile i druge direktive. Direktiva 2009/30/EC se bazirala na planovima do 2020. godine [4], a Direktiva 12/27/EU na planovima do 2030. i 2050. godine [5]. Planovi EU do 2030. uključuju smanjenje emisije staklenički plinova za najmanje 40%, povećanje upotrebe OIE za najmanje 32%, poboljšanje energetske efikasnosti za najmanje 32,5% u usporedbi s 1990. godinom, te uređenje unutarnjeg tržišta energijom u cilju postizanja međusobnog povezivanja električne energije od 15% između zemalja EU.

Planovi EU do 2050. obuhvaćaju postizanje 80-95% smanjenja emisija stakleničkih plinova u usporedbi s 1990. godinom. Novije smjernice EU za 2030., REPowerEU [6] i "Spremni za 55%" [7], predlažu povećanje upotrebe OIE sa 40 na 45% i smanjenje emisija do 55%.

Scenariji za 2030. i 2050. baziraju se na malom ili mikro daljinskom grijanju i hlađenju i elektrifikaciji grijanja i hlađenja, prvenstveno korištenjem tehnologije dizalica topline (DT) [8]. Razlog tome je upravo u činjenici da se opskrba energije za daljinske sustave grijanja još uvijek bazira na fosilnim gorivima, 90% u svijetu i 70% u EU [9]. Potrošnja energije za potrebe grijanja i hlađenja u EU iznosi gotovo 50% u ukupnoj konačnoj potrošnji energije, od čega 80% otpada na zgrade. Stoga EU nastoji obnoviti i dekarbonizirati svoj fond zgrada do 2050., koji je odgovoran za 36% svih emisija ugljikova dioksida (CO_2) u EU [10]. Zamjena fosilnih goriva i povećanje kombinirane proizvodnje električne i toplinske energije u sustavima daljinskog grijanja i hlađenja može utjecati na smanjenje od 3,7 do 7% ukupne primarne potrošnje energije s tržišnim udjelom daljinskih sustava grijanja i hlađenja od 30 do 50%, kao što je to i pokazano u slučaju EU [9].

RH je prihvatila europske planove kao članica EU. Uredila je svoju Strategiju energetskog razvoja po uzoru na ostatak EU, za plan do 2020. [11], te novu Strategiju energetskog razvoja do 2030. s pogledom na 2050 [12]. Prema Direktivi 2009/30/EC, RH je prihvatila plan postizanja minimalnog udjela od 20% OIE u bruto neposrednoj potrošnji energije. Sektorska raspodjela tog cilja uključivala je 35% proizvodnje energije iz OIE u konačnoj potrošnji energije, uključujući velike hidroelektrane, 10% u konačnoj potrošnji energije u transportu i 20% udjela bruto neposredne potrošnje energije za grijanje i hlađenje iz OIE u bruto neposrednoj potrošnji energije za grijanje i hlađenje [4]. RH ostvarila je udio OIE od 27,3% u bruto neposrednoj potrošnji u 2017., dok je prosjek EU iznosio 17,5%. Ostvarenim udjelom u 2017. godini RH je premašila postavljeni cilj do 2020. godine koji iznosi 20% udjela OIE u bruto neposrednoj potrošnji. U 2016. godini RH je imala 5,80 tCO_2e/st, dok je prosjek na razini EU bio 8,44 tCO_2e/st. Također, ukupne emisije sektora energetike u RH su smanjene s 21,8 milijuna tCO_2e u 1990. na 17,1 milijuna tCO_2e u 2016. godini. To je manje od linearno transponiranog nacionalnog cilja do 2020. koji bi iznosio 21,5 milijuna tCO_2e, odnosno 17,2 milijuna tCO_2e do 2030. godine [12]. RH ima velik potencijal u iskorištavanju OIE u proizvodnji energije. Kako bi povećala sigurnost i konkurentnost opskrbe energijom, RH se opredijelila za elastični energetski sustav s raznovrsnim OIE (vjetroelektrane (VE), elektrane na biomasu, male hidroelektrane (HE), solarne elektrane (SE), elektrane na otpad, geotermalne elektrane) i poboljšanje energetske efikasnosti [11].

1.1 Energetski sustavi s visokim udjelom OIE u proizvodnji energije

Poticanje proizvodnje električne energije iz OIE dovodi do sve većeg udjela OIE u proizvodnji energije, pa je moguće očekivati jako visoke udjele OIE u budućnosti, primjerice i do 100% udjela u 2050. godini. U literaturi [13] se razglaba o postojanju dokaza jesu li sustavi sa 100% udjela OIE u proizvodnji energije uopće ostvarivi. Shodno tome, ispitale su se 24 najnovije studije koje analiziraju 100% obnovljive sustave i autori su postavili kriterije koje bi one trebale zadovoljiti. Pokazalo se da za 100% obnovljive sustave uopće nema dokaza u literaturi da ih je moguće ostvariti, ni na globalnoj, regionalnoj ni državnoj razini, a nijedna od analiziranih studija nije zadovoljila postavljene kriterije. Stoga, literatura [13] upućuje na postojanje rizika da će se formiranje politike za ublažavanje klimatskih promjena više temeljiti na razmatranjima javnosti i javnog mišljenja nego na dokazima o učinkovitosti, utjecajima ili izvedivosti. Literatura [14] daje odgovor na prethodnu studiju. Analizom metodologije autora prethodne studije, navode da je smatraju problematičnom. Za odabrane kriterije izvedivosti smatraju da jesu važni, ali ne utječu na tehničku izvedivost sustava. Zaključili su da su energetski sustavi, koji se temelje na obnovljivim izvorima energije, izvedi, ekonomski održivi i bilježe smanjenje troškova svake.

Prethodne studije pružile su rezultate analiza iz području energetskog planiranja za sustave s visokim udjelom OIE u proizvodnji energije Primjerice, u literaturi [15] se analizira slučaj integracije vjetroagregata u energetski sustav Makedonije, u programu EnergyPLAN, u svrhu smanjenja emisija štetnih plinova u okoliš. Rezultati rada ukazuju na smanjenje emisija, povećanje udjela OIE za 13% i smanjenje kritičnog viška proizvodnje. Veći porast udjela OIE moguće je ostvariti kroz dodatna skladišta električne energije, koja uključuju EV, te transformaciju električne energije u toplinsku putem DT i skladištenjem u toplinske (TES) i rashladne energetske spremnike (RES). Pomoću EnergyPLAN-a analizirao se i energetski sustav Srbije uz povećani porast udjela OIE [16], gdje se za povećanje udjela OIE predlaže daljnje ispitivanje prilagođenih tarifnih modela cijena električne energije. Slučaj Makedonije analiziran je i za energetski sustav koji uključuje 50% i 100% udjela OIE u proizvodnji električne energije. Zaključak rada je da je 50% udjela OIE moguće ostvariti uz primjenu obveznih direktiva i smanjenje potrošnje električne energije, dok je 100% udjela moguće ostvariti uz dodatne spremnike električne energije [17]. Slična analiza provela se i za teritorij Republike Hrvatske, kao 100% energetski obnovljive i nezavisne regije. Postavljeni cilj nije postignut. Dosegao se udio OIE od 78,4% i smanjenje emisija CO_2 za 20 Mt [18].

U dosadašnjim istraživanjima korišteni su i drugi računalni alati sa satnom analizom u energetskom planiranju, kao što je program H2RES. Njime se ispitao energetski sustav

Portugala sa 100% udjela OIE u proizvodnji električne energije [19] i visokog udjela instalirane snage vjetroagregata u energetskom sustavu [20]. Istraživanja ukazuju na potrebe za skladištenjem električne energije u sustavu u svrhu ostvarenja ciljeva, kao i tehno-ekonomske analize utjecaja na okolinu. U prethodnim analizama [21], [22] i [23] pokazalo se da su samoodrživi energetski sustavi mogući na otocima, kao izoliranim područjima, uz odgovarajuću kombinaciju OIE u proizvodnji električne energije i uz njena moguća skladištenja. Doktorska disertacija [24] ukazuje na važnu ulogu skladišta električne energije kod penetracije OIE u nezavisnim energetskim sustavima. Time bi se osigurala sigurnost dobave električne energije i ostvario minimalan utjecaj na okoliš. Energetski sustav sa 100% udjela OIE u proizvodnji energije moguć je ukoliko nije izoliran i ima otvoreno energetsko tržište ili uz osiguran dovoljan kapacitet spremnika električne energije. Disertacija također upućuje na potrebna poboljšanja računalnih programa H2RES i EnergyPLAN.

U studiji [25] dat je kratak pregled ciljeva za uvođenje do 100% OIE u sustav do 2050. za pojedine države i njihove energetske planove. Studija smatra da je uz državne energetske planove vrlo bitno raditi i na energetskom razvoju i planovima pojedinih regija, općina i gradova. Razlog tome su različitih zahtjevi i mogućnosti pojedinog sustava na regionalnoj razini kao i klimatski uvjeti što uvjetuje razlike unutar države. Bitno je naglasiti da razvoj manjih sustava, gradova, općina i regija, uvijek mora biti u skladu s većim i susjednim sustavom, čiji je dio ili s kojim je u kontaktu, kako bi razvoj energetskog sustava išao u istom smjeru i bio funkcionalan. Studija je istražila integraciju i svojstva 100% OIE na trideset tipičnih gradova u različitim regijama u Kini. Ekonomska analiza je pokazala da su sustavi sa 100% OIE izvedivi u općinama s manjom gustoćom naseljenosti. Period povrata investicije je nešto manje od šest godina. Može se smanjiti i za 30 do 60% ukoliko se trošak za fotonaponske sustave (FN) smanji na pola. U studiji se upućuje na prepreke na koje nailazi realizacija 100% OIE u energetskom sustavu, kao što je manjak znanstvene literature koja analizira 100% OIE u općinama. Dosadašnje analize većinom se baziraju na državnim energetskim sustavima. Manjak je dosadašnjih studija koje se bave ekonomskom analizom 100% OIE i općenito su za takve sustave potrebne detaljnije analize.

U radu [26] se govori o prelasku gradova na 100% OIE i njihovoj važnosti za postizanje globalnih ciljeva u povećanju zastupljenosti OIE u energetskom sektoru i zadovoljenju ciljeva u smanjenju štetnih emisija. Iako u svijetu postoje dobri primjeri gradova koji uspješno provode 100% OIE, upozorava se na činjenicu da se njima ne nalaže da njihov prijelaz na OIE ide u skladu s ostatkom države i svijeta, koji također prelaze na OIE i koriste potencijalno iste izvore energije. To je vrlo bitan dio procesa prelaska kako bi on na globalnoj razini bio što uspješnije

proveden. Također se ukazuje na bitnu ulogu transportnog i toplinskog sektora, konkretno EV i DT, kao prvog koraka u smanjenju izvoza električne energije. Sljedeći korak je povoljna kombinacija OIE, a u prvom redu to je kombinacija vjetra i Sunca. Posljednji korak u smanjenju viška proizvodnje električne energije su skladišta električne energije, u što prvenstveno spadaju baterije, TES i elektrolizatori. Jednake mjere za povećanje udjela OIE u sustavu predlaže i studija [27], koja analizira prelazak Njemačke na 100% OIE do 2050. godine. Zaključak studije je da je prelazak Njemačke na 100% OIE moguću s postojećim domaćim OIE uz održavanje troška na prihvatljivoj razini.

U većini spomenutih radova ukazuje se na potrebe skladištenja energije, a kao jedna od mogućnosti predlaže se integracija EV u energetski sustav. Studija [28] je pokazala da bi flotom od 5000 EV bilo moguće zamijeniti jedno kombinirano plinsko-parno turbinsko postrojenje za potrebe kontrole frekvencije, što bi rezultiralo ekvivalentu smanjenja emisija od najmanje 62,5 t CO_2 mjesečno. Smanjenja emisija su se pokazala i kod primjene modela vozila na mreži (V2G – *"Vehicle-to-grid"*) unutar mikromreže. Primjenom modela V2G u sustavima mikromreža pokazalo se da 200 EV smanjuje emisije za 515,56 t/god [29], dok u model V2G smanjuje nivelirani trošak energije do 5,7% [30]. Analizama modela voznih ciklusa i ciklusa punjenja i pražnjenja EV, V2G model, u [31] i [32], pokazalo se da više različitih mjesta punjenja osigurava bolju fleksibilnost sustava, manji utjecaj EV na povećanje vršnog opterećenja i pruža mu stabilnost. Prilikom korištenja modela planiranja flote EV kod pojedinog sustava, upućuje se na detaljnije analize sektora transporta i utjecaj većeg broja faktora. Oni se odnose na određivanje voznih ciklusa u svrhu preciznijeg određivanja utjecaja EV na opterećenje energetskog sustava [33] i [34].

U studiji [35], koja je izrađena za Hrvatsku, predlaže se da se u sustavu ipak zadrži određena razina konvencionalnih izvora energije, uz predviđene buduće troškove goriva i tehnologije za pokrivanje toplinskih potreba i uzimanje u obzir nepovoljnih vremenskih uvjeta. Studija [2] analizirala je energetski sustav Dubrovačke regije s visokim udjelom OIE u proizvodnji električne energije. Studija je razmatrala 100% proizvodnju električne energije iz OIE i zamjenu svi osobnih KV s EV do 2050. Rezultati su pokazali visok kritični višak proizvodnje električne energije u sustavu. Iako su se EV pokazala kao dobar izvor fleksibilnosti u kombinaciji s promjenjivom proizvodnjom električne energije iz OIE, rezultati su pokazali da su u sustavu potrebni dodatni izvori fleksibilnosti kako bi se smanjio kritični višak proizvodnje električne energije.

Studija [2] prethodila je izradi ovoga rada. U ovom radu odabran je energetski sustav šireg gradskog područja i definirale su se granice sustava. Izrađen je energetski plan do 2050. godine.

U radu se teži ostvarenju 100% obnovljivog samodostatnog elektroenergetskog sustava (EES) šireg gradskog područja, uz integraciju i elektrifikaciju transportnog i toplinskog sektora, te dodatnim skladišnim kapacitetima i integracijom kroz otvoreno tržište električne energije. Uvođenje EV i DT, s dodatnim skladištima električne energije, bit će u cilju smanjenja viška proizvodnje električne energije i poboljšanja integracije 100% udjela OIE u proizvodnji električne energije. Kao OIE u proizvodnji energije odabrani su vjetar i Sunce uz postojeću HE Dubrovnik, što su i najpovoljniji OIE na odabranom području.

1.2 Energija Sunca i vjetra

Sunce je osnovni izvor svjetlosne i toplinske energije na Zemlji i pokretač svih procesa u atmosferi, gdje samo mali dio ukupne sunčeve energije dolazi na Zemlju. Dozračena energija na jediničnu površinu u jedinici vremena naziva se gustoća toka energije, a u meteorologiji se često naziva "ozračenje", čega je mjera džul po jedinici površine u jedinici vremena (npr. $J/cm^2/h$). Za standardnu mjeru sunčevog ozračenja koristi se sunčeva konstanta. Ona predstavlja količinu energije koju primi jedinična ploha okomita na smjer elektromagnetskog sunčevog zračenja u jedinici vremena na gornjoj granici atmosfere pri srednjoj udaljenosti Zemlja-Sunce. Prema normi Svjetske meteorološke organizacije (Duncan i sur. 1977.) koristi se vrijednost od 1367 W/m^2 [36].

Energija vjetra je transformirani oblik sunčeve energije. Vjetar je posljedica gibanja zraka uslijed neravnomjernog zagrijavanja Zemlje, što rezultira različitim tlakovima zraka. Vjetar nastaje zbog težnje za izjednačavanjem tlakova zraka. Zemlja kontinuirano prima 174 PW dolazećeg sunčeva zračenja u gornjoj atmosferi, od čega se 1 do 2% pretvara u snagu vjetra (npr. polovi primaju manje sunčeve energije nego ekvator, pored toga, kopno se brže grije i brže hladi od mora). To zagrijavanje uzrokuje da se topli zrak sa površine Zemlje diže prema stratosferi koja se ponaša kao virtualni strop [36], [37].

1.2.1 Iskorištavanje energije Sunca

Postoje dva načina pretvorbe energije Sunca u električnu energiju. Prva je direktna pretvorba, kod koje se sunčeva energija pretvara u električnu putem FN. Druga je indirektna pretvorba, kod koje se koriste zrcala (obično u sklopu velikih elektrana), kako bi se stvorila koncentrirana toplinska solarna energija koja se dalje pretvara u električnu energiju putem klasičnog sustava s parnim turbinama. Prostorni plan Dubrovačko-neretvanske županije propisuje instaliranje samo fotonaponskih elektrana, stoga će se rad bazirati samo na FN sustavima. Od FN sustava razlikujemo dvije osnovne skupine: FN sustavi koji nisu priključeni na mrežu, koji se često nazivaju samostalnim sustavima i FN sustavi priključeni na javnu

elektroenergetsku mrežu (EEM). Kao poluvodič u FN ćelijama najčešće se koristi kristalni silicij u različitim morfološkim oblicima (monokristalni, polikristalni i amorfni), te niz drugih kristaličnih materijala (kao npr. galij-arsenid (GaAs), kadmij-telurij (CdTe) i bakar-indij(galij)-diselenid ($CuIn(Ga)Se_2$). U ovom radu su za FN sustave odabrane monokristalne silicijske ćelije s obzirom da, u usporedbi s ostalim ćelijama s kristalnim silicijem, imaju najbolja svojstva i karakteristike. Odabrani sustavi će se smatrati da pripadaju skupini sustava priključenih na EEM, bilo da su instalirani na objektima i priključeni preko kućne instalacije ili kao sustavi većih snaga na tlu. Takva vrsta sustava je odabrana zbog jednostavnosti proračuna jer se radi o širem gradskom području, iako u stvarnosti to ne mora biti tako. Određeni sustavi mogu pripadati samostalnim sustavim, što s obzirom na veličinu energetskog sustava neće predstavljati razliku kad sustav promatramo kao cjelinu [36], [37].

1.2.2 Iskorištavanje energije vjetra

Iskorištavanje energije vjetra je brzo rastući dio sektora OIE koji sve više počinje otkrivati svoje prave potencijale. To je prepoznato i od mnogih država koje sve više ulažu u instalacije novih vjetrogeneratora. Provode i istraživanja za tehnologije koje bi mogle poboljšati iskorištavanje energije vjetra, čime su turbine, koje pogoni vjetar, znatno unaprijeđene i poboljšane [37]. Teoretski ni praktično nije iskoristiva sva raspoloživa snaga vjetra. Dio ukupne kinetičke energije vjetra je neiskoristiv. Najveći mogući stupanj aerodinamičke pretvorbe je tzv. Betzova granica i ona iznosi 0,593 (16/27). Ta granica proizlazi iz Betzovog zakona koji matematički prikazuje stupanj aerodinamičke pretvorbe. On je jednak omjeru snage na vratilu vjetroagregata i raspoložive snage u slobodnoj struji vjetra. Betzov zakon praktički znači da niti jedan vjetroagregat ne može biti učinkovitiji od 59,3%. U praktičnom smislu postoje i dodatni gubici pri pretvorbi energije. Iz toga proizlazi da se manje od pola kinetičke energije vjetra može iskoristiti kao korisna električna energija. Za moderne vjetroagregate (vjetroturbine) je stupanj iskorištenja ≈ 45%, a iznimno se na nekim turbinama približava vrijednosti od 50%. Različiti lokalni uvjeti uzrokuju razlike načina puhanja vjetra širom Zemlje. Jačina vjetra tradicionalno se iskazuje Beaufortovom ljestvicom [36]. Postoje dijelovi Zemlje na kojima pušu takozvani stalni (planetarni) vjetrovi i na tim područjima je iskorištavanje energije vjetra najisplativije [37]. Pretvorba energije vjetra u koristan rad (korisnu energiju) obavlja se pomoću vjetroagregata koji se, s obzirom na orijentaciju osi vrtnje, mogu podijeliti na horizontalno ili vertikalno postavljenu os vrtnje [36]. U ovom radu će se razmatrati vjetroagregati s horizontalnom osi vrtnje s obzirom da su oni i inače korišteni kod VE na odabranom području.

OIE ravnomjernije su raspoređeni nego nalazišta fosilnih goriva omogućavajući globalno ravnomjerniji razvoj. S druge strane, javlja se zabrinutost zbog potencijalnih, negativnih utjecaja neodrživog korištenja energije vjetra na okoliš, prije svega vezano uz utjecaj buke, vizualni utjecaj te utjecaj na biološku raznolikost. Iz tog razloga, nužno je iskorištavanje energije vjetra sustavno planirati, uključujući sve tri sastavnice održivog razvitka – ekonomsku, socijalnu te sastavnicu zaštite okoliša [37].

1.2.3 Integracija FN i VE sustava u proizvodnje električne energije

Visok interes za proizvodnju električne energije iz OIE posljednji godina doveo je do visokog udjela instaliranih FN i VE sustava u energetskom sustavu, koji su uzrokom nesigurne i promjenjive proizvodnje električne energije. Proizvodnja električne energije iz vjetra i Sunca je nesigurna i promjenjiva jer ovisi o vremenskim prilikama i klimatskim promjenama. Zbog stohastičkog ponašanja brzina vjetra i sunčeva zračenja, teško je predvidjeti proizvodnju energije iz tih izvora energije. Prethodne studije su pokazale da se stohastičko ponašanje brzina vjetra i sunčeva zračenja može opisati na temelju analiza meteoroloških podataka o brzinama vjetra, trajanju sijanja Sunca i sunčevom zračenju. Utvrđeno je da se Weibull i Gamma krivuljama može opisati distribucija brzine vjetra, dok Beta krivulja odgovara opisu relativnog trajanja sijanja sunca [38]. Analize rađene na temelju europskih meteorološki podataka polučile su jednake rezultate [39]. Promjenjiva proizvodnja električne energije iz OIE može uzrokovati višak ili manjak proizvodnje energije, što rezultira preopterećenjem mreže EES. Rezultati prethodnih studija su pokazali da energetski sustav ima bolji učinak kada koristi kombiniranu proizvodnju iz vjetra i Sunca, negoli zasebno FN sustave i VE. Zaključeno je da optimalna kombinacija i odgovarajuća raspodjela te količina OIE rezultira pozitivnim učincima na sustav. Neki od njih su poboljšanje stabilnosti napona, smanjenje niskih gubitaka na mreži i poboljšanje uvjeta opterećenja dalekovoda (DV) [40].

Mnoge studije obrađivale su ove teme i ponudile različita rješenja i mogućnosti za održavanje sigurnosti energetskog sustava i postizanje fleksibilnosti i stabilnosti u sustavu. Rezultati studije [41] pokazali su da visok udio promjenjivih OIE u sustavu izaziva visoku nesigurnost u proizvodnji električne energije. Autori predlažu da se proizvodnja električne energije iz OIE kombinira sa skladištima energije, kombiniranom proizvodnjom toplinske i električne energije, čije se gorivo može lako pohraniti, kao i sa prekograničnim prijenosnim kapacitetima koji mogu sudjelovati u učinkovitom iskorištavanju energije iz OIE. U studiji [42] je predstavljen model mikromreže. Model teži usklađivanju proizvodnje iz OIE i potrošnje električne energije kombiniranjem sa skladištima i cijenama električne energije. Pokazalo se

da su hibridni energetski sustavi, koji uključuju FN i vjetroagregate s baterijama, pouzdaniji i isplativiji zbog komplementarnosti ova dva izvora energije. Studija [43] je dala pregled od 140 znanstvenih radova u časopisima koji analiziraju samostojeće hibridne sustave i one spojene na mrežu. Dva hibridna sustava su analizirana u [44]. Prvi je uključivao FN sustav, uplinjač biomase i baterije, dok je u drugom postojećem sustavu dodan vjetroagregat. Prvi sustav je pokazao bolje rezultate i omogućio je fleksibilniju i pouzdaniju opskrbu s dosta manje gubitaka. Model buduće samoodržive kuće s proizvodnjom električne energije korištenjem sunčeve energije i EV analiziran je u studiji [45] za Hrvatsku. Predstavljeni su rezultati tri različita scenarija i pokazalo se da treći scenarij, koji uključuje kontrolu punjenja EV i upravljanje potrošnjom električne energije, može balansirati 100% proizvodnju iz OIE.

U radu [46] je prezentiran model pogrešaka u prognozi proizvodnje električne energije iz vjetra u kombinaciji s baterijama. Izvedena je korelacija između cijena električne energije i proizvodnje električne energije iz vjetra u cilju postizanja fleksibilnosti i stabilnosti u energetskom sustavu Njemačke. Prognoze proizvodnje električne energije iz vjetra i Sunca te rad energetskog sustava uglavnom se baziraju na neposrednom kratkoročnom vremenskom periodu od sekunda do minuta, kratkoročnom periodu od sata do dva dana i srednjoročnom periodu od dva do sedam dana. Kratkoročne prognoze su uglavnom bazirane na statistici. Autori u [47] su dali detaljan pregled postojećih metoda i saznanja o prognozama energije vjetra. Nekoliko modela za prognozu brzine vjetra i snage, za različite vremenske periode, analizirani su u studijama [48], [49], [50]. U studiji [51] su se podaci prognoze razvrstali prema podacima prognoze brzine vjetra (neizravna metoda) i podaci prognoze snage vjetra (izravna metoda). Autori predlažu kombinaciju različitih fizikalnih i statističkih modela u cilju postizanja dobrih rezultata u kratkoročnim i dugoročnim prognozama, kao i daljnja istraživanja praktične primjene metoda, a ne samo teoretske. Rezultati novog modela prognoze snage vjetra, temeljeni na mjernim podacima brzine vjetra i snage VE u sjevernoj Siciliji prezentirani su u [52]. U studiji [53] se predlaže i nova metoda za kratkoročnu prognozu snage i brzine vjetra. U radu [54] su prikazani rezultati modela kratkoročne i srednjoročne prognoze sunčeva zračenja. Studije [55] i [56] su dale rezultate modela prognoze koje obuhvaćaju i brzine vjetra i sunčevo zračenje. Uz prognoze brzine vjetra i sunčeva zračenja, razvijeni su i modeli predviđanja potrošnje električne energije koje su u posljednje vrijeme polučile dobre rezultate u industriji [57]. Autori su zaključili da su satne vrijednosti vanjske temperature zraka značajne za predviđanje satne potrošnje električne energije i da njihov sustav treba biti poboljšan ovim tipom podataka. Krivulja opterećenja potrošnjom energije u vrijeme vikenda oblikom se

razlikuje od ostalih dana, pa je period vikenda teže predvidjeti. Potrebno je model doraditi i poboljšati kako bi se postigla točnost u predviđanjima opterećenja vikendom.

Profili proizvodnje električne energije iz vjetra i Sunca trebali bi se nadopunjavati kako bi pružili stabilnost energetskom sustavu s visokim udjelom OIE u proizvodnji električne energije i smanjili potrebe za dodatnim skladištima energije i proizvodnim jedinicama. Visoka komplementarnost mjesečnih vrijednosti proizvodnje električne energije iz vjetra i Sunca pokazala je dobru korelaciju između ta dva energetska izvora. Dnevne vrijednosti rezultirale su osrednjom korelacijom, a kratkoročne satne vrijednosti još lošijom korelacijom [58]. Uz ispitivanja komplementarnosti proizvodnje električne energije iz vjetra i Sunca, potrebno je i raditi analize komplementarnosti između profila proizvodnje energije iz OIE i potrošnje električne energije. Analize komplementarnosti profila proizvodnje iz vjetroelektrana i potrošnje električne energije u studiji [59], pokazala je slabu korelacijsku vezu između profila i problem velikog odstupanja. Analiza korelacije između opterećenja električnom energijom i vremenskih uvjeta [60], u kojoj su obuhvaćene tri zgrade, pružila je rezultate odziva potražnje za električnom energijom u zgradi s obzirom na vremenske prilike. Rezultati su pokazali da temperatura i specifična vlažnost zraka imaju značajan utjecaj na potrošnju električne energije, dok statistička ispitivanja brzine vjetra nisu polučila značajne rezultate.

Studija [61] je dala rezultate analize korelacije između krivulje opterećenja električnom energijom i statističkih podataka o brzini vjetra i sunčevom zračenju za tipičnu godinu i tipični dan. Rezultati su pokazali dobru korelaciju između potencijala OIE i potrošnje električne energije za tipičnu godinu i dan. To daje poticaj povećanoj integraciji OIE u energetski sustav i u proizvodnju električne energije na ekološki prihvatljiviji način od elektrana na fosilna goriva. Rezultati su pokazali komplementarnost između energije vjetra, Sunca i hidroenergije, što su i glavni izvori energije za odabranu regiju. Stabilnost energetskog sustava, s visokim udjelom OIE u proizvodnji električne energije, ovisi o zemljopisnoj veličini sustava. Veći sustavi imaju manje zahtjeve za fleksibilnošću od manjih sustava [62]. Zahtjevi za fleksibilnošću energetskog sustava ovisit će o optimalnoj kombinaciji OIE i njihovim udjelima, veličini područja za uravnoteženje, kao i cilju ostvarenja prekograničnih rješenja kao najefikasnijeg načina za integraciju visokog udjela OIE u sustav. Analize modela sustava za vremenski period dulji od 12 sati nužne su za razvoj dugoročnog sustava skladištenja energije kao dio stabilnosti i fleksibilnosti integriranih OIE. Zahtjevi za fleksibilnošću u vremenskom periodu od minuta značajni su za izradu programa za automatsko upravljanje potrošnjom. Sve prethodno spomenute studije su predstavile neku vrstu rješenja kako bi potakle integraciju OIE

u energetski sustav. Stabilnost i sigurnost takvih sustava može se postići ako se u obzir uzmu vremenske prognoze i analize, skladišta energije (ES) i energetska tržišta.

Zadovoljavajući rad i upravljanje energetskim sustavom s visokim udjelom OIE u proizvodnji električne energije teško se može ostvariti bez primjene informacijskih i komunikacijskih tehnologija (IKT-alata, "*ICT-tools - information and communication technologies"*). One pomažu i omogućuju kontrolu i regulaciju energetskih tokova u energetskom sustavu. Cjelokupna elektroenergetska infrastruktura i povezani društveno-tehnički sustavi, uključujući rad sustava, opskrbu, proizvodnju, potrošače, prijenosne i distribucijske mreže te tržišne mehanizme, potrebno je povezati kako bi se ostvarila suradnja i održala sigurnost mreže, takozvane pametne mreže [63], [64], [65]. Studije [66] i [67] su prezentirale standarde za elektroenergetsku komunikaciju koji pomažu u osiguravanju nesmetanih i pouzdanih aktivnosti na mreži. Uz pametne mreže, energetski sustavi bi trebali biti uređeni kao pametni energetski sustavi koji koriste nove dostupne tehnologije i infrastrukturu koja stvara nove oblike fleksibilnosti i koristi OIE na učinkovitiji način. Pametni energetski sustav uključuje sve sektore energetskog sustava, pružajući fleksibilnost kombiniranjem sektora transporta, električnog i toplinskog sektora, kako bi nadomjestio manjak fleksibilnosti uslijed proizvodnje električne energije iz OIE [68], [69].

U energetskim sustavima već postoje zahtjevi za fleksibilnošću. Postojeći izvor fleksibilnosti je presudan u pružanju mogućnosti brzog odziva, kada se potražnja za električnom energijom mijenja od maksimalne do minimalne vrijednosti, što se može odvijati dosta brzo. Također, pruža usluge kod kratkoročnih, mogućih neočekivanih vršnih opterećenja potrošnjom energije, koja mogu biti znatno veća od prosječnog vršnog opterećenja, kao i kod pogreške u prognozama potražnje. Fleksibilnost je potrebna i na strani opskrbe kako bi pokrila neočekivane događaje i prekide u sustavu, kao što su otkazivanje glavnog generatora ili dalekovoda. Ova podudarnost može biti od velikog značaja kada promjenjiva proizvodnja energije iz OIE i potražnja pokažu znatno povećanje kao rezultat istog poticaja. Primjerice, kada potražnja klima uređaja naglo poraste prema sredini dana, a u sustavu je instaliran značajan kapacitet FN sustava, oboje će istovremeno rasti u velikoj mjeri. U tom slučaju, proizvodnja iz FN sustava ne samo da predstavlja dodatni zahtjev za fleksibilnošću, već zapravo udovoljava postojećim zahtjevima, donekle oslobađajući izvore fleksibilnosti prethodno potrebne negdje drugdje u sustavu. Suprotno tome, smanjenje zahtjeva za fleksibilnošću neće se pojaviti u slučaju pojačanja vjetra, vala ili plime i oseke tijekom kasnih večernjih sati jer potražnja tada opada, što će rezultirati dodatnim zahtjevom za fleksibilnošću. S druge strane, ako povećane brzine vjetra rezultiraju povećanjem potrebe za grijanjem (u

području gdje je grijanje osigurano električnom energijom), vjerojatnost podudarnosti raste. Znanstveni podaci s meteoroloških postaja značajni su za otkrivanje razlika u izvorima fleksibilnosti u pojedinim regijama. Prije gradnje elektrane, ti podaci će biti uzeti u obzir i bit će nadopunjeni podacima s meteoroloških postaja, senzornim tehnologijama i modelima izvora. Podaci prikupljeni u cijeloj regiji tijekom jedne ili više godina dat će prilično jasnu predodžbu o vjerojatnoj promjenjivosti u sustavu, iako će i dalje biti podložni nesigurnosti. Sljedeći korak je procjena nesigurnosti rezultata prognoze tijekom vremenskog razdoblja uravnoteženja. Točna prognoza proizvodnje energije postrojenja na promjenjive OIE u cijelom sustavu je od velikog značaja, jer će omogućiti učinkovitije planiranje i korištenje izvora fleksibilnosti [70].

1.3 Fleksibilnost elektroenergetskog sustava

OIE, kao što su energija vjetra i Sunca, ovise o vremenskim prilikama i njihov visok udio u proizvodnji energije rezultira varijabilnošću i nesigurnošću opskrbe energijom. Te pojave predstavljaju izazov s kojim se energetski sustavi moraju suočiti u radu i u planiranju budućih potreba za energijom. Varijabilnost nije nova pojava s kojom su suočeni energetski sustavi. Opterećenje od strane potrošnje energije osciliralo je oduvijek, otkad je prvi potrošač bio priključen na prvu elektranu. Tim pojavama se upravljalo većinom korištenjem elektrana s brzim puštanjem u rad. Stoga, možemo reći da su promjenjivi OIE dodatni, ne i novi, izazov u energetskom sustavu koji predstavljaju dva elementa: promjenjivost i nesigurnost u proizvodnji energije. Nesigurnost opskrbe energijom je povezana s prognozom proizvodnje energije iz promjenljivih OIE. Prognozama proizvodnje, kao i potrošnje energije, teško je postići 100% točnost. Prognoze proizvodnje energije iz promjenljivih OIE rade se dan unaprijed, zatim se ažuriraju unutar dana, čak i unutar sata, kako bi podaci bili što točniji i precizniji. Stvarna količina proizvodnje energije se u konačnici uvijek razlikuje od one predviđene. Operator energetskog sustava mora na sebe preuzeti upravljanje viškom ili manjkom proizvodnje u vrlo kratkom vremenu. Promjenjivost i nesigurnost je veća kod promjenjive proizvodnje energije iz OIE nego kod potrošnje. Razlog tome je lakše predviđanje potrošnje energije što se ogleda u desetljećima iskustva i analizama podataka.

Promjenjivost u proizvodnji energije iz OIE ovisi o izvoru energije. Fotonaponske elektrane čak i za oblačnog vremena proizvode energiju. Njihova proizvodnja nikada ne pada ispod 20% nazivne snage što omogućuje određenu preciznost. S vjetrom to nije slučaj i proizvodnja je nepravilna. Kada bi prognoza proizvodnje energije bila 100% točna, izvori fleksibilnosti u sustavu bi u svakom vremenskom rasponu trebali iznositi udio maksimalnog porasta opterećenja na mreži uz uključeni dio za nepredviđene događaje. Međutim, to nije

slučaj i zbog toga je potrebno u sustavu zadržati neke od najfleksibilnijih izvora energije, kako bi se pokrila nesigurnost u slučaju viška ili manjka isporučene energije od one koja je predviđena. Održavanje ravnoteže između proizvodnje i potrošnje energije suočava se s najvećim izazovom u situacijama kada potrošnja pada a proizvodnja raste u isto vrijeme i obratno. U tom slučaju sustav po potrebi isključuje odnosno uključuje elektrane s brzim puštanjem u rad kako ne bi došlo do manjka ili viška proizvedene energije u sustavu. Najbolji odgovor na taj problem daje veća fleksibilnost u energetskom sustavu. Planiranje energetskog sustava treba osigurati dovoljno izvora fleksibilnosti kako bi se pokrila promjenjivost opterećenja u sustavu.

Fleksibilnost izražava opseg do kojeg energetski sustav može oblikovati proizvodnju i potrošnju energije kao odgovor na promjenjivost, očekivanu ili neku drugu. Drugim riječima, fleksibilnost izražava sposobnost energetskog sustava da održava pouzdanu opskrbu suočenu s brzim i velikim neravnotežama, bez obzira na uzrok. Ona se mjeri u megavatima (MW) koji su dostupni za pokrivanje viška ili manjka proizvodnje energije u danom trenutku. Primjerice, dano postrojenje s kombiniranim ciklusom plinske turbine može biti u stanju povećati ili smanjiti snagu od 10 MW u minuti. Fleksibilnost će varirati od područja do područja jer ovisi o prirodnim izvorima i povijesnom razvoju pojedinog područja. Neko će područje svoju fleksibilnost ostvariti instaliranim HE koje imaju brzi odziv, dok će energetski sustav susjednog područja svoju fleksibilnost ostvariti u kombinaciji plinske turbine i upravljanjem potražnjom energije.

Fleksibilnost u energetskom sustavu se tradicionalno povezuje s elektranama s brzim puštanjem u rad. One jesu od velike važnosti, međutim nisu i jedine koje mogu u energetskom sustavu pomoći u održavanju ravnoteže energetskih tokova. Među ostale izvore fleksibilnosti ubrajaju se i ES, upravljanje potražnjom i odzivom te povezanost sa susjednim tržištima energije. Pojedini izvori izvan energetskog sektora mogu doprinijeti fleksibilnosti sustava, kao što su transportni i toplinski sektor. Kod toplinskog sektora to su električni i toplinski spremnici dok su u transportu to EV s električnim baterijama (BEV). Oni mogu pružiti dodatni izvor fleksibilnosti pohranjujući višak proizvodnje ili pokrivanjem manjka proizvodnje u sustavu u danom vremenu. Promjenjiva proizvodnja iz OIE može biti po potrebi smanjenja (ograničena) u cilju smanjenja viškova proizvodnje energije. Može se i ponovno povećati, ako za to postoji potreba, kako bi se osigurala uravnotežena opskrba energijom. Takva ograničenja proizvodnje će možda biti potrebna nekoliko sati u cijelog godini. To predstavlja prihvatljiv trošak za proizvođača energije i pruža mogućnost energetskom sustavu upravljanje većim kapacitetom promjenjive proizvodnje iz OIE.

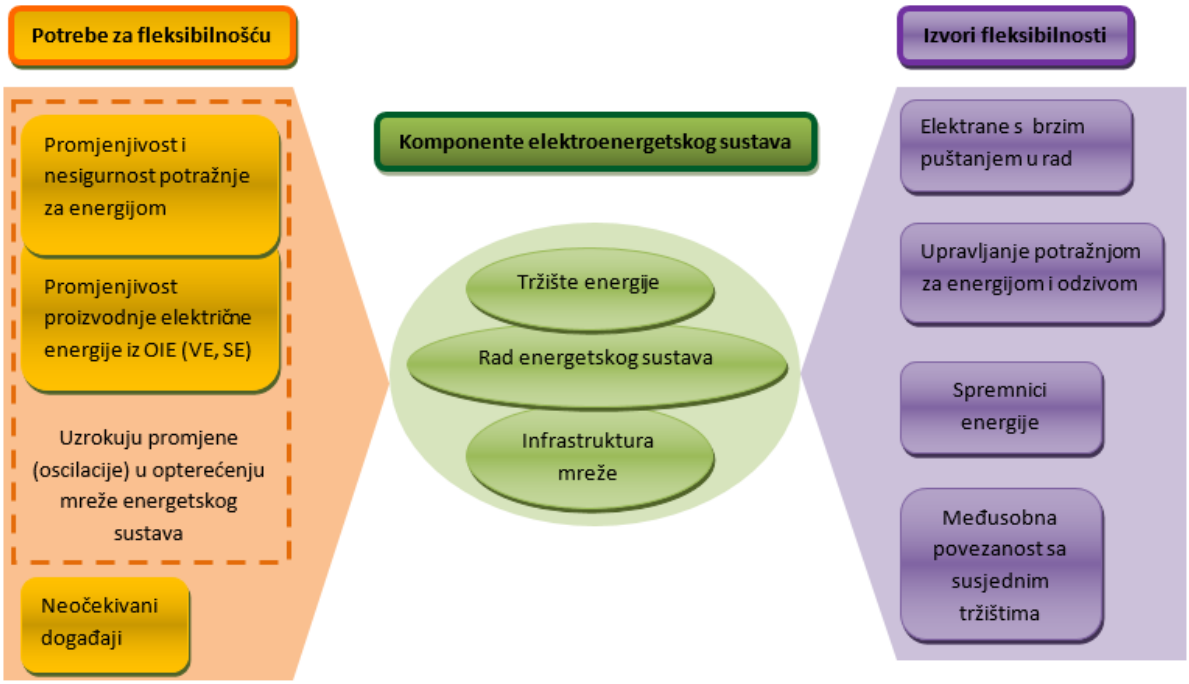

Slika 1. Fleksibilnost elektroenergetskog sustava: zahtjevi i izvori fleksibilnosti [70]

Ispitivanje glavnih čimbenika, koji se moraju uzeti u obzir prilikom procjene izvora fleksibilnosti sustava, daje predodžbu o njegovom sadašnjem potencijalu za upravljanje promjenjivom električnom energijom [Slika 1]. Lijeva strana slike pokazuje potrebe za fleksibilnošću, postojeće i nove. Oni će se vjerojatno donekle preklapati, što se odražava na opterećenju na mreži. Njima se dodaje i zahtjev protiv neočekivanih događaja u sustavu - nepredviđeni događaji - obično se mjeri kao gubitak najveće pojedinačne elektrane ili DV. Na desnoj strani slike navedena su četiri izvora fleksibilnosti koja se mogu koristiti za uravnoteženje promjenjivosti u sustavu. Sva četiri mogu pružiti jednaku fleksibilnost sustavu brzim ili planiranim povećanjem ili smanjenjem energije kao odgovor na promjenjivost u sustavu. Sredina slike prikazuje sastav EES u kojem se podudaraju zahtjevi i izvori fleksibilnosti kako bi se utvrdilo koliko je izvora stvarno dostupno za upotrebu u uravnoteženju. U nekim će područjima biti dostupna velika količina izvora, u drugima će biti ograničen njihov broj, obično kombinacijom tri ključna čimbenika: fizički prijenos mrežom; upravljanje EES; i struktura tržišta električne energije.

Pojedini energetski sustavi mogu imati različite izvore fleksibilnosti i jedno rješenje ne odgovara svakom sustavu. Sustavi se razlikuju strukturom, načinom rada, obrascima potrošnje energije, prirodnim izvorima, tržištem i prijenosnom mrežom koja ih povezuje. Neki će sustavi imati bolju mogućnost upravljanja promjenjivim OIE u proizvodnji električne energije, stoga ih nije moguće direktno uspoređivati s obzirom na OIE koje koriste. Područja s visokim

udjelom promjenjivih OIE u proizvodnji energije imaju u pravilu veće zatjeve za fleksibilnošću. I to zapravo ovisi, jer nijedan sustav nije jednak. Svi sustavi zasigurno dijele određene temeljne karakteristike na temelju kojih se mogu uspoređivati. Neki sustavi imaju visoke udjele instaliranih proizvodnih kapaciteta i opskrbljuju široko područje koje se može protezati na više država. S druge strane su vrlo mali sustavi i otoci. Sustavi mogu biti usko povezani sa susjednim područjima uz mogućnost trgovanja ili mogu biti izolirani i nemati tu mogućnost. Neki imaju mogućnost skladištenja energije, dok drugi nemaju. Potrošnja energije u svim sustavima oscilira u različitim omjerima i iz različitih razloga.

Elektrane s brzim puštanjem u rad mogu, u pojedinim sustavima, imati brži ili sporiji odziv. Svi EES imaju unutarnje prijenosne (i distribucijske) mreže; u jednom sustavu može biti jako i gusto umrežena (međusobno povezana), dok drugi može imati slabe veze. Slabe veze mogu rezultirati ozbiljnijim problemima u slučaju pojave neočekivanih događaja kada jedna linija otkaže. Kod usporedbe energetskih sustava razlikujemo više čimbenika, a to su: veličina područja, međusobna povezanost sa susjednim područjima, broj energetskih tržišta unutar područja, geografska raspodjela promjenjivih OIE, fleksibilnost elektrana s brzim puštanjem u rad i jačina mreže. Područja koja imaju visok udio instaliranih proizvodnih kapaciteta imat će i veća vršna opterećenja, time i veći broj elektrana koje sudjeluju u opskrbi energijom i veću raznolikost opskrbe. Potrošnja će manje oscilirati u područjima koja se protežu na više vremenski zona. Bolja povezanost sa susjednim sustavima omogućuje i korištenje izvora fleksibilnosti susjednog sustava kod upravljanja promjenjivim OIE. Velika područja imaju mali potencijal u međusobnoj povezanosti sa susjednim sustavima dok otoci nemaju tu mogućnost. Bolju poziciju ima ono tržište koje je dio jednog velikog tržišta, nego jedno od više manjih povezanih tržišta. Dobra raspodjela promjenjivih OIE na širem području imat će uglađeniju proizvodnju nego u slučaju kad su elektrane izgrađene u neposrednoj blizini jedna drugoj. Snažna elektroenergetska mreža je vrlo bitan faktor i to ona mreža s dovoljnom količinom kapaciteta. Takva mreža može osigurati raspoloživost izvora fleksibilnosti za uravnoteženje promjenjivosti i nesigurnosti, čak i pod teškim okolnostima i unutar prihvatljivih razina rizika.

U današnjim energetskim sustavima izvori fleksibilnosti podijeljeni su u četiri dijela: elektrane s brzim puštanjem u rad, ES, povezanost sa susjednim tržištima energije i mogućnost upravljanja potražnjom električne energije. Najveći izvor fleksibilnosti u energetskom sustavu predstavljaju elektrane s brzim puštanjem u rad koje imaju mogućnost povećanja i smanjenja proizvodnje na zatjev. Za njih je karakteristično da su u mogućnosti odgovoriti na zahtjeve operatora sustava i da u bilo koje vrijeme povećaju ili smanje proizvodnju u određenom

vremenskom razdoblju. Između njih postoje razlike u brzini odziva pa tako imamo podjelu na bazne i vršne elektrane, te elektrane koje pokrivanju srednje opterećenje. Vršne elektrane imaju jako brz odziv i mogućnost pokretanja i zaustavljanja proizvodnje iz minute u minutu. Elektrane sa srednjim odzivom sporije reagiraju na potrebe sustava i mogu pružiti značajnu fleksibilnost unutar jednoga sata. Bazne elektrane su one s najslabijim odzivom. Obično zatjevaju obavijest najmanje šest sati unaprijed kako bi pružile značajnu fleksibilnost.

Električna energija iz skladišta može se brzo otpremiti, što ih čini potencijalno važnim izvorom fleksibilnosti, s odzivom u najkraćem vremenskom roku (minute), za uravnoteženje nesigurnosti i kratkotrajne promjenjivosti. Međupovezanost sa susjednim energetskim tržištima omogućuje dijeljenje izvora fleksibilnosti u svrhu upravljanja promjenjivošću između susjednih područja. Raspoloživi kapacitet međupovezanosti kao izvora fleksibilnosti ovisi o položaju određenog područja i povijesnoj društveno-ekonomskoj povezanosti susjednih područja. Kod izvora fleksibilnosti, na strani potrošnje električne energije, razlikujemo izvore upravljanja potrošnjom i izvore odziva potrošnje. Upravljanje potrošnjom se odnosi na izvore koji su unaprijed dogovoreni od strane operatora sustava. Oni se odnose na smanjenje potrošnje na određeni broj sati godišnje ili odgoda potrošnje bez ekonomskih poteškoća. Obično se to odnosi na industrijsku i komercijalnu potrošnju. Mnoge države danas koriste razne programe upravljanja potrošnjom primjenom različitih tarifa električne energije za dan i noć i drugi modeli. Onaj udio potražnje za električnom energijom, koji ima mogućnost dinamičkog odziva u vremenskom okviru uravnoteženja manjka i viška električne energije. smanjenjem i povećanjem potrošnje, bez prethodnog dogovora, spada u izvor odziva potrošnje. U tu kategoriju možemo svrstati EV i sustave električnog grijanja i hlađenja. Međupovezanost sa susjednim tržištima, kao kapaciteti izvora fleksibilnosti, mogu biti dogovoreni unaprijed na godišnjoj, mjesečnoj, tjednoj ili dnevnoj osnovi. Uobičajen je dogovor za dan unaprijed, što može ozbiljno ograničiti raspoloživost za uravnoteženje. Međupovezanost i dalje biti korisna u odnosu na vremensku prognozu predviđenu za dan ili dane koji slijede.

Energetski sustavi s visokim udjelom promjenjivih OIE zahtijevaju i povećan broj izvora fleksibilnosti. Međutim, napore bi ipak bilo bolje usmjeriti u smanjenje potreba za fleksibilnošću. Tri su načina da se to postigne:

- smanjenje vršnog opterećenja proizvodnje energije iz promjenjivih OIE,
- raspodjela elektrana na najvećoj mogućoj međusobnoj udaljenosti,
- integracija više različitih vrsta postrojenja na promjenjive OIE u sustavu.

Ako u sustavu dođe do nepoželjnog naglog porasta opterećenja proizvodnjom, on se može smanjiti smanjivanjem učinka postrojenja. Kod dobivanja električne energije iz vjetra, primjerice, to se postiže okretanjem lopatica vjetroturbina od vjetra. To pridonosi uravnoteženju sustava i ako se događa nekoliko puta godišnje ne nanosi ekonomsku štetu operatoru postrojenja. U slučaju korištenja sunčeve energije u proizvodnji električne energije, u pravilu nema znatnih odstupanja od planirane proizvodnje, pa tu nisu potrebne trenutna smanjenja opterećenja. Međutim, kada se različite vrste postrojenja s promjenjivom proizvodnjom nalaze na istom području, smanjuje se vjerojatnost izolacije zbog zagušenja prijenosa. Ako se njihova proizvodnja nadopunjuje i postoji komplementarnost proizvodnje različitih postrojenja, bolje će se iskoristiti postojeći prijenosni kapacitet.

Energetski sustav nekog područja sastoji se od tri osnovna elementa: elektrane, sve vrste potrošača i mreže za prijenos električne energije koja ih povezuje. Čitav sustav radi neprekidno i dinamično. Ako dođe do promjene kod bilo kojeg od sudionika sustava, ostvarit će se utjecaj na druge sudionike sustava, bilo pozitivan ili negativan. Stoga se ni jedan od elemenata ne bi trebalo promatrati zasebno jer su svi usko međusobno povezani. Primjerice, ako neka elektrana radi neprekidno punim kapacitetom, najvjerojatnije će doći do povećanja viška proizvodnje u sustavu tijekom noći kada je potrošnja minimalna [70].

1.4 Električna vozila

Korištenje EV bilježi znatan porast posljednjih godina. U Europi je tako zabilježen broj od milijun EV u 2020. godini, s predviđenim porastom korištenja u EU i svijetu [71]. Relativno visoki početni troškovi kupnje EV i dalje su prepreka na putu usvajanja EV [72], iako su se EV pokazala efikasnijim od KV i imaju niže troškove rada [73]. Novija tehnologija, poznata kao brzo punjenje, zahtjeva manje od 15 minuta za punjenje baterije [73]. Brzo punjenje može potaknuti korištenje EV i učiniti ih konkurentnijim KV. Današnje brze punionice od 50 kW mogu napuniti 70% kapaciteta baterije u manje od 30 minuta [74]. Donja granica stanja napunjenosti (SOC, *"state of charge"*), od 10%, postavljena je kako bi se izbjegla anksioznost potrošača. Gornja granica napunjenosti, od 80%, postavljena kako bi se ublažilo ubrzano trošenje i osigurala sigurnost tokom brzog punjenja. Postoje i primjeri brzog punjenja u trajanju od 8 do 10 minuta, koje je još poznato kao izuzetno brzo punjenje [75]. Današnje tehnologije punjenja EV razlikuju tri razine punjenja BEV. Kod razina 1 i 2 koriste se punjači na izmjeničnu struju, koji se većinom koriste kod kuće i zahtijevaju punjenje baterije u trajanju od 6 do 8 sati. Kod razine 3 koriste se punjači na istosmjernu struju za brzo punjenje u trajanju manje od 30 minuta s mogućnošću punjenja baterije do 80% stanja punjenja [76].

U radu [77] analizirala se veza dnevne duljine vožnje i standardnog i brzog punjenja. Rezultati su pokazali da brzi punjači daju bolji poticaj za porast korištenja EV. Oni omogućuju korištenje EV na putovanjima koji zahtijevaju više od jednog punjenja, što EV čini privlačnijima za buduće korisnike. Rezultati su pokazali da političke odluke i poticaji imaju veliko značenje u poticanju razvoja infrastrukture s brzim punjačima. Negativan utjecaj na postojeći rad mreže može se dogoditi u slučaju brzog punjenja EV na distribucijskoj mreži niskog napona za vrijeme vršnih opterećenja. Kao jedno od rješenja ovog problema predstavlja dvosmjerna punionica na brzo punjenje i istosmjernu struju. Ona ima novu upravljačku topologiju kojom se predlaže rješenje pada napona. Punionica održava napon istosmjerne struje na 800 V [78].

Druge studije su predložile rješenje u obliku tehnologija skladišta energije. Cilj im je postići smanjenja vršnih opterećenja, omogućavajući istovremeno punjenje nekoliko EV bez potrebe za visokim troškovima dostupne energije [3]. U radu [77] napravljena je analiza veličine i položaja brzih punionica. Potrebne su opsežne studije na polju planiranja infrastrukture za brzo punjenje, kako bi se omogućilo i potaklo korištenje EV i brzih punionica. Neke studije bavile su se analizom buduće infrastrukture. Istaknule su nekoliko mjesta poželjnih za smještaj punionica za EV, poput zgrada javnih tijela, medicinskih centara ili rekreacijskih objekata, radnih mjesta i benzinskih postaja. Studija je dala rezultate ankete o poželjnim lokacijama za smještaj punionica, a ispunjali su je vlasnici vozila. Analize infrastrukture brzih punionica rađene su još za slučaj Južne Karoline [79], otoka Irske [80] i cestovne mreže oko Washingtona, D. C., New Yorka i Bostona [81].

U radu [82] su prikazani rezultati usporedbe troškova modela poslovanja za KV i EV. Rezultati su pokazali da su ukupni troškovi za postavljanje privatne kućne punionice za EV 84,5% niži od onih za KV, kako je navedeno u [Tablica 1]. Napravljena je i usporedba kupovne cijene vozila za tri države: Španjolska, Njemačka i Nizozemska, gdje su rezultati pokazali da je cijena EV od 16,4% do 45,5% veća u usporedbi s KV, kao što je prikazano u [Tablica 1]. Kod usporedbe troškova za infrastrukturu brzog punjenja i standardnog punjenja kod kuće, prednost ima standardno punjenje, kako stoji u [Tablica 1] [83]. Investicijski trošak brzih punionica može povećati postojeće troškove mreže do 15%, kako bi se osigurala potrebna opskrba električnom energijom u slučaju visokog porasta broja EV na mreži [78]. Najmanja snaga za punjenje EV, potrebna da se dosegne stanje punjenja baterije od 80%, nelinearno se povećava sa 77 kW za 60 minuta punjenja na 461 kW za 10 minuta punjenja. Kao rezultat toga, cijena ćelije se naglo poveća do 196 USD/kWh. Dodatni trošak uslijed smanjenja trajanja punjenja baterije s 55 na 10 minuta iznosi 126 USD/kWh [75].

Tablica 1. Usporedba KV s EV, te usporedba različitih vrsta EV i punionica na temelju tehničkih i financijski aspekata prema prethodnim studijama.

Financijski i tehnički aspekti	**KV**	**EV**
Troškovi instalacije punionice	30225 EUR	4675 EUR (kućna punionica)
Cijena vozila	12000–18550 EUR	16500–27150 EUR
	EV	
	Brza punionica	**Kućna punionica**
Investicijski trošak	1370–1800 EUR/kW	
Sposobnost punjenja	75 EV/dan (1500 kWh)	4 EV/dan (86 kWh)
	'Super-brza' javna punionica na istosmjernu struju	**Kućna punionica**
	20 kWh; 20–80% SOC	
Investicijski trošak	125000 EUR	1000 EUR
Potrebno vrijeme punjenja	5 min	5,6 h
	Brzo punjenje na istosmjernu struju	
Trošak instaliranja 111 punionica na istosmjernu struju	22600 USD	
Trošak instaliranja transformatora	18000 USD	
Trošak za opreme s dva priključka za punjač snage 50-60 kW	20000–36000 USD	
Snaga punjenja	145 kW (Tesla) - 225 kW (Porsche)	
	Brze punionice na istosmjernu struju	**Iznimno brze punionice**
Trošak instalacije	32600–34700 USD	40300–42000 USD
Trošak opreme	30000 USD	245000 USD
Trošak goriva	6000 USD manje od KV; 1000 USD manje od HEV	3000 USD više od KV

U [Tablica 1] prikazani su detalji o troškovima i karakteristikama brzog punjenja na istosmjernu struju i njihova usporedba s izuzetno brzim punjenjem, detaljnije opisana u studiji [84]. Rezultati usporedbe pokazuju da su troškovi izuzetno brzog punjenja mnogo veći. Ova analiza također je pokazala da se troškovi vozila na izuzetno brzo punjenje, kao i troškovi goriva, moraju smanjiti kako bi bili konkurentni KV i hibridnim električnim vozilima (HEV). Ušteda vrijednosti vremenskog trajanja putovanja također se mora uzeti u obzir, s obzirom da izuzetno brzo punjenje zahtjeva dosta manje vremena za punjenje vozila od brzog punjenja na istosmjernu struju. Procijenjena srednja vrijednost uštede vremenskog trajanja putovanja iznosi 16 USD po satu. Izuzetno brzo punjenje će zahtijevati 900 h manje za punjenje EV nego brzo punjenje na istosmjernu struju, što iznosi oko 15000 USD u vrijednosti uštede vremenskog trajanja putovanja [84]. U studiji [85] je izvedena usporedba različitih razina punjenja EV, od standardnog punjenja kod kuće do "super brzog" javnog punjenja na istosmjernu struju. Rezultati su pokazali da kućna punionica ima najniži ukupni investicijski trošak i zahtjeva najduže vremena za punjenje. Punionica na "super brzo" javno punjenje na istosmjernu struju ima najviši investicijski trošak i najkraće vrijeme punjenja.

1.5 Dizalice topline

Daljinsko grijanje (DG) se trenutno razvija prema primjeni najnovijeg koncepta nazvanog daljinsko grijanje 4. generacije (4GDG - *"4th generation district heating"*), koji će se izgrađivati tijekom razdoblja 2020. - 2050. godine. 4GDG sustavi se mogu koristiti za stabilizaciju EEM, zbog povećanog udjela promjenjivih OIE u EES, pružanjem mogućnosti integracije većeg broja energetskih sustava [86]. Neka od nedavnih istraživanja raspravljala su o tehnologiji DT kao ključnoj komponenti 4GDG sustava. DT poboljšava integraciju OIE [87], utječe na smanjenje emisija [88] i privlači korist od niskih cijena električne energije za vrijeme visoke proizvodnje električne energije iz OIE [9], [89]. Pokazalo se da je DT ekonomski povoljnija proizvodna jedinica od kogeneracijskog postrojenja toplinske i električne energije [90]. Oko 800000 električno pogonjenih DT je godišnje prodano u EU u razdoblju od 2010. – 2015. godine [91]. DT se pokazala kao bolja opcija u pogledu isplativosti i uštede emisije u usporedbi sa solarnim kolektorima (SK) [9]. S druge strane, integracija DT u solarne sustave DG poboljšava njihovu energetsku učinkovitost, kako je to pokazano u [92] i [93]. Ono također rezultira smanjenjem troškova životnog vijeka i uštedom primarne energije [94]. Pametnim upravljanjem takvim sustavima može se postići dodatno smanjenje troškova [95], [96], kao i smanjenje emisija [97].

Vremenska prognoza, vlastita potrošnja i upravljanje skladištem toplinske energije također rezultiraju dodatnom dobiti energije [98]. Volumen značajno utječe na svojstva sustava [99], dok je uporaba TES presudna za smanjenje potrebe za fosilnim gorivima u grijanju [92]. DT se predlažu kao najbolje rješenje za snižavanje razine temperature DG, kao i potrošnje primarne energije [100]. Analize različitih sustava DT rezultirale su neusklađenošću opterećenja tijekom ljetnih i zimskih mjeseci u međudjelovanju s mrežom, kao što je prikazano u [89] i [101]. U studiji [102] su prikazane mogućnosti DT kod poravnavanja opterećenja, kao i njihovi utjecajni i ograničavajući čimbenici. U [103] izvršena je satna analiza uloge RES u integraciji OIE i smanjenju vršnih opterećenja na razini zgrade, dok su u [104] analizirane uloge različitih spremnika na razini grada/države. Rezultati u [105] pokazali su da potrošnja električne energije DT može pratiti dostupnost energije vjetra po satima, dok TES može ponuditi malu fleksibilnost mreži ako se kontrolira na inteligentan način.

Prethodne studije većinom su analizirale potencijal DT u integraciji proizvodnje električne energije iz vjetra i Sunca pojedinačno. Većina studija rađena je za sustave mikromreža, kao što su zgrade, gdje je morska voda, kao izvor topline za DT, slabo zastupljena. U usporedbi s prethodnim studijama, ovaj rad pruža neke nove pristupe koji se tiču proizvodnje električne energije iz OIE. Koristi proračune koji se baziraju na kratkoročnom vremenskom

koraku, povećanju veličine sustava i otvaranjem mogućnosti za primjenu električnih baterija. U ovom radu dat će se pregled analiza potencijala DT s izvorom morske vode (DTMV) za iskorištavanje proizvodnje energije iz vjetra i Sunca, pojedinačno i u kombinaciji.

1.5.1 Dizalica topline s izvorom morske vode

Sustav DG s DTMV je sustav koji koristi obnovljivu energiju jer iskorištava osjetnu toplinsku energiju sadržanu u morskoj vodi. Predstavlja dobro rješenje za pokrivanje potreba za grijanjem i hlađenjem zgrada u obalnim područjima. Morska voda ima vrlo dobra svojstva kao izvor topline za DT. Ima niže sezonske promjene temperature i nižu temperaturu smrzavanja (oko –2 ° C) od riječne vode. Održava temperaturnu razliku od 5-10 ° C u odnosu na atmosferu, što je idealno za grijanje i hlađenje [106]. DT se ljeti koristi kao rashladni uređaj, s morskom vodom kao ponorom topline, a zimi se morska voda koristi kao izvor topline. U usporedbi s kotlovima na ugljen, sustav DTMV ima općenito veći investicijski trošak i manji trošak rada [107].

Korištenje klimatizacijskih uređaja u stambenom sektoru povećava se zbog prosječnog rasta dohotka i toplinske udobnosti u stanovima. Uložen je veliki napor u proučavanju i uvođenju tehnologija koje pokreću OIE, posebno u Europi i Kini [108], [109], [110]. Zemlje sjeverne Europe, poput Norveške i Švedske, vodeće su u inženjerskoj primjeni DTMV kao sustava grijanja i hlađenja, koristeći toplinu morske vode kao izvor topline za DG od 1982. godine [106], [111]. Najveće postrojenje DTMV je Värtan Ropsten u Švedskoj s ukupnim kapacitetom od 180 MW [107]. Područja u Japanu također koriste DTMV za daljinsko grijanje i hlađenje (DGH) od 1993. godine. U Koreji je bilo nekoliko povezanih primjera istraživanja i primjene [106]. U Kini se morska voda koristi kao izvor topline za DG od početka 2000. godine, a DTMV dosta je popularna i korisna u hladnim područjima [112]. Studija [33] pokazala je da će morska voda najvjerojatnije imati značajnu ulogu kao izvor topline u budućim energetskim sustavima u Danskoj. Potencijal za uštedu energije sustava DG s DTMV znatno je podcijenjen u usporedbi s konvencionalnim sustavom DG s kotlovnicom [113]. Analiza sustava DTMV u Koreji pokazala je napredak u godišnjem učinku grijanja od 8-14% [106]. Studije [112] i [114] su pokazale da bunari učinkovito poboljšavaju stabilnost, pouzdanost i energetsku učinkovitost sustava DTMV.

1.6 Skladištenje energije

U ovom radu razmatrat će se nekoliko vrsta skladištenja energije kao izvora fleksibilnosti u sustavu. Među njima su baterije kao energetski spremnici (BES), u koje spadaju baterije u EV i stacionarni BES. U odabranom su sustavu stacionarni BES sastavljeni od baterija iz EV,

koje su završile svoj životni vijek u vozilu i mogu se iskoristiti u sekundarnoj upotrebi, takozvana baterijska sekundarna upotreba (B2U – "*battery second use"*). Od stacionarnih spremnika odabrani su i sustavi spremnika energije vodika (SEV), te TES i RES u sustavu DTMV.

1.6.1 Baterije EV i model V2G – mobilni energetski spremnik

Jedna od najvećih prepreka široj upotrebi EV je brzina punjenja baterije i mali domet vožnje. Trenutna brzina punjenja EV iznosi 30 minuta do 80% stanja napunjenosti baterije [115]. Kompetitivnost EV na tržištu mogla bi se povećati s dometom vožnje od 500 km i većom brzinom punjenja EV od sadašnje brzine. Ta poboljšanja zahtijevaju veću gustoću BEV od one trenutno dostupne, a to je gustoća veća od 280 Wh/kg. Brzo i izuzetno brzo punjenje uzrokuje porast temperature prilikom punjenja što utječe na trajnost, pouzdanost i sigurnost baterija. Brzo punjenje zahtjeva snagu punjenja veću od 250 kW, pa do izuzetno brzog punjenja do 400 kW snage punjača. Različite brzine punjenja označavaju se sa C-stopom punjenja, koja označava vrijeme potrebno da se baterija napuni u potpunosti. Stopa punjenja od 1 C definirana je kao brzina punjenja BEV u trajanju od 1 sat do potpune napunjenosti. Trenutno su najbrže stope do 3 C, što bi značilo vrijeme punjenja od 20 do 30 minuta. Sve iznad 3 C može značajno utjecat na sigurnost i trajnost baterije. Brzinu punjenja vozila stopom od 4 C, 15 minuta, nije moguće koristit s trenutno dostupnim baterijama. Izuzetno brzo punjenje bi bila brzina punjenja stopom od 6 C, 10 minuta. Iznimno brzo punjenje u literaturi je definirano kao punjenje u trajanju od 10 minuta do stanja napunjenosti baterije od 80%, ili stanja napunjenosti od 80-90% i dometa vožnje od 153 km ili punjenje EV snagom većom od 350 kW, [116], [115].

U studijama [75] i [117] su se ispitivala svojstva različitih baterija EV prilikom brzog i izuzetno brzog punjenja. Pokazalo se da litij-ionske baterije imaju najbolja svojstva s obzirom na visoku energetsku učinkovitost do 99,5% [117], gustoću snage, kompaktne su i imaju manju težinu [118]. Koriste se kada je potrebna visoka gustoća energije i snage [100]. Trenutna gustoća litij-ionskih baterija iznosi oko 240 Wh/kg, dok bi do 2025. godine ona mogla doseći i 400 Wh/kg. Gustoća ćelije baterije Teslina EV, koja se sastoji od trostrukog materijala s visokim udjelom nikla ($LiNiCoAlO_2$), iznosi 300 Wh/kg. To je trenutno najveća razina gustoće energije za litij-ionske baterije. Litij-ionske baterije imaju široku primjenu kod osobnih vozila zbog svoje visoke gustoće i dobre značajke u radu pri niskim temperaturama. Efikasnost električnog motora bi do 2025. mogla doseći 97% a invertera 98% [119]. Zalihe litija su najveće u Južnoj Americi i iznose 69% ukupnih svjetskih zaliha. Kobalt, kao drugi najznačajniji materijal litij ionskih baterija, najveće zalihe ima Demokratskoj Republici Kongo,

što iznosi 65% globalnih zaliha. Iako, većina većih proizvođača je kobalt uklonila iz baterija ili to planira učiniti. Litij-ionske baterije za EV postigle su značajno smanjenje troškova posljednjih godina, pa je cijena baterija u 2021. godini iznosila u prosjeku 132 USD/kWh i previđa se pad cijene na 72 USD/kWh do 2030. godine [120].

U literaturi su ponuđena i druga rješenja u cilju poticanja korištenja EV. Neke od njih su i različite tehnologije skladištenja energije. U radu [3] razmatra se upotreba brzih punionica za EV u kombinaciji s vanadij-redoks protočnim baterijama. U [121] analizira se sustav mikromreže s brzim punionicama koji se sastoji od FN sustava i litij-ionskih baterija za skladištenje energije. Dodatne studije koje analiziraju baterije za pohranu energije nalaze se u [122] za punjenje EV i u [123] za brzo punjenje autobusa. Rezultati u [124] i [125] pokazuju da baterije mogu poboljšati poravnanje vršnih opterećenja. Druge tehnologije su također obrađivane u studijama, kao što je punjenje EV tokom vožnje [126], [127], zamjena praznih baterija [128] i punjenje i pražnjenje vozila primjenom tehnologije V2G [129].

Tehnologija V2G pruža EV mogućnost da budu izvor fleksibilnosti u energetskom sustav. Vozila se pune u vrijeme niske potrošnje električne energije ili visoke proizvodnje iz OIE. Prazne se kada je u sustavu manjak proizvodnje električne energije iz OIE ili u vrijeme povećane potrošnje. Time predstavljaju mobilni spremnik električne energije. Može se očekivati da će prilikom visoke proizvodnje električne energije iz OIE cijena energije biti niska, dok će u vrijeme manjka proizvodnje cijena biti visoka. U tom slučaju bi, korištenjem modela V2G, korisnici EV mogli smanjiti trošak punjenja EV i ostvariti dodatne prihode. To se i pokazalo u studiji, gdje su se ispitivao optimalni plan punjenja i pražnjenja EV uz ponudu cijena dan unaprijed i trgovanjem na tržištu energije [28]. Studija [130] je pokazala da V2G može smanjiti prosječni trošak za električnu energiju za punjenje EV za 28-67% u usporedbi s jedinstvenom tarifom. U studiji [28] se pokazalo da se optimizacijom modela V2G mogu ostvariti prihodi od 38% u ljetnom periodu i 12 % u zimskom periodu. V2G mogu utjecati na veće korištenje modela dijeljenja vozila. Studija [131] je pokazala da V2G može potaknuti veću atraktivnost korištenja modela dijeljenja vozila. Međutim, V2G tehnologija postavlja veće zahtjeve na značajke ugrađenih baterije i utječe na njihovu gustoću, sigurnost i životni vijek, kao i samog vozila [119].

U ovom radu će se analizirati energetski sustav šireg gradskog područja koji uključuje 100% proizvodnju električne energije iz OIE, skladišta električne energije te potpunu zamjenu KV s EV do 2050. godine. Razmatrat će se uvođenje modela V2G s regulacijom punjenja i pražnjenja EV i stacionarnih spremnika varijabilnim cijenama električne energije prema tržišnim cijenama i povezanost sustava sa susjednim tržištima. Sličan energetski sustav za

područje jedne regije opisan je u studiji [132]. Studija je analizirala sustav sa 100% proizvodnjom električne energije iz OIE, integracijom s toplinskim sektorom i regulacijom punjenja EV cijenama električne energije. Sustav je uključivao proizvodnju iz HE, VE i SE. Razmatrala se mogućnost priključka 100% EV na mrežu u jednome satu koje je uređeno i regulirano kao pametno punjenje uz visoku razvijenu infrastrukturu za EV. Rezultati su pokazali smanjenje emisija CO_2 za 74,2% uvođenjem EV u sustav u odnosu na KV. Također, uvođenje pametnog punjenja i regulacija punjenja EV pridonijela je uštedi od 201 USD godišnje po jednom EV u odnosu na neregulirano punjenje. Samo uvođenje pametnog punjenja u sustav iznosilo je 18 USD po EV. U obzir su uzeta samo osobna vozila jer se smatra da ona predstavljaju najbolji izvor fleksibilnosti kod pametnog punjenja. U radu [133] se također pokazalo da uvođenje regulacije punjenja smanjuje troškove za 100-300 USD po EV godišnje. Kada se uzme u obzir bihevioralni realizam, kao što je potrošački izbor i dodavanje proizvodnih kapaciteta, ušteda je manja i iznosi od 60-70 USD po EV godišnje.

U ovom radu napravljen je iskorak u odnosu na prethodnu literaturu uvođenjem reguliranog modela V2G i varijabilnih cijena električne energije. Analiziran je model sustava za vremenski korak od 10 minuta koji uključuje iznimno brzo punjenje i pražnjenje EV.

1.6.2 Baterije EV i B2U – stacionarni energetski spremnik

Baterije u EV imaju svoj vijek trajanja koji je određen sigurnosti u vožnji i komplikacijama koje mogu nastati nakon prelaska životnog vijeka. Dosadašnja literatura navodi da životni vijek baterije u EV iznosi od 8-10 godina [134], [135]. U tom razdoblju baterija izgubi 20-30% svog početnog kapaciteta, to jest dođe do 70-80% ukupnog kapaciteta, što je otprilike prijeđenih 160000 km [136]. Nakon završetka svog životnog vijeka u EV, baterijama bi trebala slijediti reciklaža, dok se u vozilo može staviti nova baterija. Međutim, baterijama se može produžiti vijek trajanja do konačne reciklaže uvođenjem B2U, koja općenito može trajati dok baterija ne dosegne 50% svog početnoga kapaciteta. B2U može produljiti životni vijek od dodatnih 3,6 do 29 godina, ovisno o uvjetima u kojima radi [137]. Obično se uzima da je njen vijek u B2U od 8 do maksimalno 12 godina, pa bi ukupni životni vijek baterije u EV i kao B2U bio 20 godina [138]. Općenito, recikliranje baterije se može podijeliti u četiri stupnja. Prvi stupanj je upotreba u EV s kapacitetom od 100-80%. Drugi stupanj je B2U kao stacionarni spremnik energije u energetskom sustavu s kapacitetom od 80-50%. Treći stupanj je primjena na korisnike niže razine s kapacitetom od 50-40%. Četvrti stupanj je reciklaža baterije kada ona dosegne kapacitet niži od 40% od početnog kapaciteta

[139]. Studija [140] je pokazala da B2U u zgradama može povećati životni vijek baterija za 35%, što može utjecati na smanjenje stvarne cijene EV.

Trošak same baterije inače obuhvaća 50% cijene EV [139]. B2U bi mogla značiti smanjenje cijene proizvodnje nove baterije za EV za 30-70% [141]. Kapitalni trošak od 132 USD/kWh pretpostavlja se za rabljene baterije i 440 USD/kWh za nove baterije za 2030. godinu. Faktori raspodjele temeljeni na ovoj tržišnoj cijeni su 80% za prvi životni vijek i 20% za drugi životni vijek [138]. Rezultati studije [142] pokazuju da bi EV baterija mogla postići vrijednost drugog životnog vijeka od 116 USD/kWh ako se kupi s preostalim kapacitetom od 80% i reciklira se kada kapacitet dosegne 50% sa životnim vijekom B2U od 4,5 godina. Ova potencijalna vrijednost koja se stvara drugom uporabom iznosi oko 1/3 cijene nove baterije (2015.). U radu su modelirana četiri scenarija, s baterijama uklonjenim iz EV nakon što je ostalo 90%, 80%, 70% i 65% izvornog kapaciteta. Baterije se zatim koriste u stacionarnom sustavu za pohranu energije, B2U, gdje nastavljaju gubiti kapacitet. Kada se baterija povuče iz EV s preostalim kapacitetom od 65-90% i napusti s preostalim kapacitetom od 50%, mogla bi postići vrijednost od 56-155 USD/kWh s radnim vijekom od 2,8-5,3 godine. Ako preostali kapacitet u napuštenom stanju može biti manji, na primjer do 20%, potencijalna vrijednost za skladištenje energije mogla bi se povećati na 167-255 USD/kWh. U stvarnosti nema uvjerljivih dokaza da se baterije drugog životnog vijeka s 20% preostalog kapaciteta i dalje mogu koristiti kao pohrana energije. Ipak je to scenarij koji treba uzeti u obzir pri donošenju odluka o ulaganju.

U ovom radu će se također BEV razmatrati za B2U kao stacionarni spremnici električne energije u sustavu, što će pružiti dodatni izvor fleksibilnosti u sustavu i ujedno smanjiti cijenu EV i baterija kao spremnika energije.

1.6.3 Vodik

Energija vodika je izvor energije koji je posljednjih godina sve popularniji. Vodik (H_2) se može koristiti umjesto fosilnih goriva zbog većeg sadržaja energije i manjeg utjecaja na okoliš. Općenito, atom vodika sastoji se od elektrona i protona, te je bez boje i mirisa. Gustoća vodika manja je od gustoće zraka. Gravimetrijska gustoća energije vodika općenito je oko sedam puta veća od gustoće fosilnih goriva [143]. Vodik je atraktivna opcija za skladištenje energije s visokim specifičnim energetskim kapacitetom od 120 MJ/kg i čistim produktom izgaranja. Vodik se smatra prijenosnikom energije budući da je energija oslobođena proizvodnjom jedinice vodika manja od potrošene [144].

Vodik je jedna od najčešćih tvari u prirodi. Većina nije u čistom obliku. Vodik se mora proizvoditi iz spojeva koji sadrže vodik. Može se proizvesti iz fosilnih goriva, prirodnog plina. U proizvodnji vodika koristi se i električna energija dobivena iz geotermalne energije, energije biomase, vjetra ili Sunca. Vodik nije energija dobivena iz prirodnih rezervi poput ugljena, nafte i prirodnog plina, već je izvor energije dobiven proizvodnjom. Cijena proizvodnje vodikove energije trenutno je i dalje vrlo visoka. Cilj u proizvodnji je zadržati troškove i emisije na najnižoj razini. Elektroliza vode i parno-metanski reformer (PMR) (SMR – *"steam-methane reformer"*) uobičajene su metode za proizvodnju vodika. Metodom reforme vodik se dobiva iz fosilnih goriva korištenjem toplinske energije. Približno tri četvrtine proizvodnje vodika proizvodi se iz plinsko-parne reforme, približno jedna trećina reformom nafte, jedna petina reformom ugljena i približno 4% elektrolizom vode [143]. Kod PMR metode koriste se sirovine za fosilna goriva (plavi i sivi vodik) s energetskom učinkovitošću od 65-85% i niskim troškom proizvodnje. Kod elektrolize vode koriste se OIE (tj. energije u plin) s energetskom učinkovitošću od 50%–75% na temelju kapaciteta elektrolizatora (zeleni vodik) [144]. Shodno tome, vodik ima relativno nisku učinkovitost za skladištenje električne energije.

U literaturi [145] se navodi i veća efikasnost elektrolize vode u procesu visokotemperaturne elektrolize krutog oksida za pretvaranje vode u vodik i kisik kroz proces elektrokemijske reakcije na visokoj temperaturi, s učinkovitošću pretvorbe energije do 90%. Metoda parne reforme metana za proizvodnju plavog vodika smatra se čistom budući da se proizvedeni CO_2 može izdvojiti. Drugi proces parne reforme metana, što dovodi do proizvodnje sivog vodika, nije ekološki prihvatljiv jer često sadrži nečistoće kao što su CH_4, Ar, CO, CO_2 i N_2. Ako se vodik proizvodi iz OIE, kao što je elektroliza vode, onda je proces ekološki prihvatljiv, obnovljiv i održiv i rezultira proizvodnjom zelenog vodika [144]. Elektrolizom vode vodik se proizvodi pretvorbom električne energije u vodik. Pohranjeni vodik može se lako ponovno pretvoriti u električnu energiju u gorivnim člancima ili sagorjeti u plinskim energetskim ciklusima [146]. Na primjer, elektrolizom 1 m^3 vode može se dobiti 108,7 kg vodika, a energija te količine jednaka je 422 L benzina [147]. Vodik, kao nositelj energije, ima nisku gustoću od 0,089 kg/m^3 u standardnim uvjetima. Stoga su potrebne velike količine vodika kako bi se učinkovito uravnotežila potražnja i ponuda potrošača tijekom vršnih razdoblja [144].

Od skladišta vodika možemo izdvojiti podzemna skladišta grupirana u konvencionalna (slane kaverne, vodonosnici i osiromašeni rezervoari ugljikovodika) i nekonvencionalna (napušteni rudnici ugljena, obložene kaverne u tvrdim stijenama i rashlađene iskopane kaverne) [144], te visokotlačna i niskotlačna skladišta stlačenog plinovitog vodika i nosači i

skladišta tekućeg organskog vodika (LOHC – *"liquid organic hydrogen carriers"*) [143]. Jasno je da podzemna skladišta imaju prednost u smislu sigurnosnog zadržavanja, kapaciteta, trajanja i visoke ekonomske isplativosti. Međutim, financijski aspekt obuhvaća troškove hvatanja, transporta, skladištenja/povlačenja i praćenja koji, ako se pažljivo ne odrede, mogu utjecati na ukupni proces skladištenja. Kaverne se smatraju najboljom opcijom zbog lakog pristupa, relativnog odsustva mikrobnih aktivnosti i sposobnosti da izdrže visoke uvjete ležišta (tlak i temperatura), te su ograničene u broju. Osiromašena ležišta ugljikovodika (nafte i plina) su druga. Vodonosnik je treći zbog neidentificiranih izazova svojstvenih ležištima vodonosnika u usporedbi s iscrpljenim ležištima koja su već testirana i istražena [144]. Za skladištenje stlačenog plinovitog vodika, troškovi ulaganja visokotlačnih plinskih spremnika su visoki i potrebni su posebni zahtjevi za te spremnike. Također čak i niskotlačne primjene zahtijevaju približno 850 USD kapitalnih troškova za pohranjivanje 1 kg vodika. Nosači i skladišta tekućeg organskog vodika procjenjuju se na 50 EUR/kgH_2 uključujući materijal za nosače (15,2 kgLOHC/kgH_2 s 2,5 EUR/kgLOHC) i dva spremnika (5 EUR/kg H_2 po spremniku). Takvi sustavi skladištenja isplativiji su od skladištenja u kaverni. Trošak opskrbe vodikom za nosače i skladišta tekućeg organskog vodika je u rasponu od 5-10 EUR/kg H_2 [143].

Energija vodika nedvojbeno će biti jedan od glavnih izvora energije u budućnosti. Probleme poput transporta i skladištenja treba poboljšati. U budućnosti će se energija vodika koristiti umjesto nafte za transportna vozila kao što su automobili, avioni, željeznice i brodovi. Predviđa se da će 35% vozila u Europi 2040. godine pokretati vodikova energija. Osim u SAD-u, u svijetu postoji 401 postaja za gorivo za vodik, a planira se izgradnja još 159 postaja za gorivo. U SAD-u postoji 46 benzinskih postaja za vodik. U Hrvatskoj je također instalirana jedna punionica na vodik 2019. godine. Literatura navodi da će 11% ukupnih energetskih potreba biti zadovoljeno energijom vodika 2025. godine, a 34% 2050. Navodi se da će se, ovisno o proizvodnji vodikove energije, 2030. godine uporaba ugljena smanjiti za 36,7%, a uporaba nafte za 40,5%. Godišnje se u svijetu proizvede više od 50 milijuna tona vodika. Prema podacima Međunarodne agencije za energiju, navodi se da će do 2030. godine energija vodika dobivena iz vjetra i elektrolize biti jeftinija od prirodnog plina. Otprilike 90% proizvedenog vodika danas se koristi u sintezi amonijaka, rafinerijama i proizvodnji metanola. Ova stopa će se smanjivati u nadolazećim godinama [143].

Integracija sustava SEV s BES sustavima temeljito je istražena. Ovom bi se hibridizacijom postigli razumni troškovi uz dobra svojstva, posebno za sezonsko skladištenje energije. Hibridna baterija/SEV je prevladala ograničenja upotrebe jedne baterije kao što su cijena, kapacitet punjenja/pražnjenja i ekološka pitanja [146]. Kombinacijom skladišnih

sustava SEV i BES u energetskim sustavima može se postići bolja iskoristivost proizvodnje energije iz OIE od sustava pojedinačno [148]. U literaturi [149] je dana usporedba BES, SEV i reverzibilne HE. Kada je u pitanju tehnička usporedba različitih tehnologija skladištenja, uočeno je da litij-ionske baterije imaju gustoću snage u rasponu od 1300-10000 kW/m^3, dok reverzibilne HE imaju raspon od 0,01-0,2 kW/m^3, a vodikov gorivni članak ima gustoću snage >500 kW/m^3. Što se tiče gustoće energije, uočeno je da litij-ionska baterija ima 90–750 kWh/m^3, reverzibilna HE 0,2-2 kWh/m^3 i vodikov gorivni članak 500-3000 kWh/m^3 . Također, učinkovitost ciklusa BES (Li-ion) (80-95%) i reverzibilne HE (65-85%) veća je u usporedbi s vodikovim gorivnim članakom (20-50%). Životni vijek vodikova gorivnog članaka je duži nego BES (Li-ion) i usporediv s reverzibilnom HE. U smislu kapitalnih troškova u USD/kW utvrđeno je da reverzibilna HE košta između 500-4600, Li-ion BES između 1200-4000 i vodikov gorivni članak 500-10000.

U odabranom energetskom sustavu šireg gradskog područja u ovom radu će se u sustav dodati SEV, kao stacionarni spremnik, kako bi se poboljšala iskoristivost proizvodnje energije iz OIE te povećala fleksibilnost u sustavu. Vodik će se koristiti u spremnicima za vodik kao skladište viškova proizvedene energije iz OIE. Proizvodit će se elektrolizom vode i skladištiti u vrijeme viška proizvodnje električne energije. U vrijeme manjka proizvodnje energije će u gorivnim člancima izgarati i služiti u opskrbi električne energije.

1.6.4 Toplinski i rashladni spremnici energije

U radu se razmatra integracija transportnog i toplinskog sektora odabranog područja u cilju bolje iskoristivosti proizvodnje električne energije iz OIE. Kako bi se to ostvarilo, potrebno je uvesti potpunu elektrifikaciju transportnog i toplinskog sektora. Transportni sektor je planiran na način da se sva KV zamijene EV do 2050. godine, dok će se u toplinskom sektoru fosilna goriva zamijeniti DTMV i zadržati uređaje za grijanje i hlađenje pogonjene električnom energijom, kao što su klimatizacijski uređaji. Kako bi se poboljšala fleksibilnost energetskog sustava, u toplinski sektor će se uvesti dodatni izvori fleksibilnosti, kao što su TES i RES. Sustavi ES će pružiti bolju iskoristivost energije i samih DTMV punjenjem spremnika u vrijeme viška proizvodnje električne energije iz OIE i pražnjenjem spremnika u vrijeme manjka proizvodnje energije, kako bi se smanjile potrebe za uvozom energije. TES će se usporediti s BES u sustavu DTMV, a razmatrat će se i kombinacija svih spremnika u odabranom energetskom sustavu u programu Calliope. To će pružiti dodatne izvore fleksibilnosti, poboljšati integraciju OIE u sustav i smanjiti potrebe za uvozom i izvozom.

1.7 Tržište električnom energijom

Proizvođači, dobavljači, veliki potrošači i trgovci energijom predaju anonimne naloge za kupnju ili prodaju, na osnovu kojih se izračunava tržišna cijena za svaki sat sljedećeg dana. Odvojeno označeno tržište, koje se uglavnom koristi za uravnoteženje sustava, djeluje bliže vremenu rada sustava. Na britanskoj burzi, većinom električne energije, trguje se na vremenskoj skali dan unaprijed, preko dražbe na slijepo (*"blind auction"*). Važne burze, kojima upravljaju neovisni operateri sustava (NOS) u Sjedinjenim Državama, uključuju međupovezanost Pennsylvania-New Jersey-Maryland (PJM međupovezanost) i NOS u državi New York, Kalifornija, Srednji zapad i Nova Engleska. Na nordijskom tržištu električne energije, Nord Pool Spot tržište je najveće na svijetu. Trguje sa 70% ukupne potrošnje električne energije u nordijskim zemljama (Danska, Finska, Švedska i Norveška). Pojava promjenjive cijene električne energije može olakšati primjenu više fleksibilnih izvora energije. Ako potrošači imaju pristup i mogu odgovoriti na tržišne cijene, imat će više poticaja za promjenu potrošnje električne energije nego u normalnim uvjetima.

Skladišta, od kojih mnogi svoj glavni prihod vide iskorištavanjem razlika između niski i maksimalnih cijena električne energije, mogla bi se puniti u vrijeme niske cijene. Na ovaj način bi se mogla proširiti mogućnost profitiranja za koordinirana međusobno povezana susjedna tržišta. Stoga je moguće da veća promjenjivost cijena električne energije, koja proizlazi iz implementacije varijabilnih OIE, može potaknuti povećanje dostupnosti najfleksibilnijih izvora energija. Ostaje pitanje hoće li to povećanje biti dovoljno za zadovoljavanje rastućih potreba. Potrebno je izvršiti kvantitativnu analizu opsega promjenjivosti cijena i trajanja ekstremnih (visokih ili niskih) cijena i potencijalnih koristi koje bi mogle predstavljati vlasnicima fleksibilnih izvora energije.

Potrebno je provjeriti i nudi li tržište dovoljno poticaja da postojeći izvor fleksibilnosti bude dostupan za pokrivanje povećanih odstupanja neto opterećenja koja proizlaze iz implementacije promjenjivih OIE. Ostaje i pitanje postoji li dovoljan poticaj za vlasnike/investitore da nastave voditi/graditi bazne elektrane u vrijeme njihovih smanjenih prihoda, a koje su važne za održavanje ravnoteže energetskog sustava za vremenski period dan ili dani unaprijed. Drugim riječima, mogu li tržišne snage same potaknuti vlasnike i ulagače da se ponašaju na način koji će jamčiti fleksibilnost i pouzdanost; ili vlade trebaju osigurati dodatne poticaje kako bi osigurale fleksibilan rad postojećih postrojenja i kontinuirano ulaganje u nova, ako i kada su potrebni? Najviše iskustva sa skladištenjem energije za uravnoteženje promjenjivosti i nesigurnosti u energetskom sustavu ima s reverzibilnim hidroelektranama. Utjecaj promjenjivosti opterećenja je mali u sustavima gdje postoji dovoljan broj skladišta

energije, jer skladišta imaju mogućnost brzog odziva. Iznos dodatnog troška za uravnoteženje sustava bit će nazivni trošak dok god se proizvodi dovoljno električne energije koja se može pohraniti kako bi se zadovoljile potrebe potrošnje energije. Izvori fleksibilnosti na strani potražnje mogu biti jeftini izvori fleksibilnosti. Veće upravljanje potražnjom moglo bi smanjiti troškove uravnoteženja sustava budući da je jedinični marginalni trošak upravljanja potražnjom vjerojatno niži od troškova pričuve.

Neka tržišta električne energije uređena su na način da dozvoljavaju trgovanje do jedan sat unaprijed (*"gate closure time"*), a manji broj njih dozvoljava trgovanje unutar jednoga sata. Troškovi uravnoteženja sustava obično se smanjuju bliže vremenu isporuke. Studija o vjetru Avistaje, primjerice, procijenila je 40% do 60% uštede na troškovima uravnoteženja sustava prelaskom sa satnog na 10 minutno tržište električnom energijom. Precizno predviđanje proizvodnje električne energije iz promjenjivih OIE, u kombinaciji s dinamičnijim trgovanjem električnom energijom i planiranjem rada energetskog sustava, može učiniti izvore fleksibilnosti efikasnijima. Redovito ažurirane prognoze, posebice one proizvodnje iz promjenjivih OIE, snažan su signal za razvoj potreba za fleksibilnošću na tržištu. Pri zatvaranju dradžbe (*"gate closure"*) (kada se ponude na tržištu električne energije zatvore) proizvođači električne energije obvezuju se isporučiti fiksnu količinu električne energije. Nakon tog trenutka, na operatoru sustava ostaje da uravnoteži bilo koje odstupanje između isporuke koja je trebala biti i one koja je stvarno isporučena, korištenjem izvora fleksibilnosti koji su za tu svrhu izdvojeni kao rezerva. Zatvaranje dražbe na mnogim tržištima se odvija dan prije isporuke, što u praksi može predstavljati 36 sati unaprijed ili više. Pogreška u prognozama proizvodnje iz promjenjivih OIE se smanjuje kako se približava vrijeme rada. Dakle, ako se zatvaranje dradžbe dogodi samo sat vremena prije vremena isporuke energije, umjesto 36 sati, ili čak unutar sata unaprijed, proizvođači imaju priliku unaprijed ažurirati svoje ponude na temelju najnovijeg ažuriranja prognoze. Kao rezultat proizlazi da operator sustava mora unaprijed ugovoriti manje "rezervi". Operatori sustava bi trebali koristiti najbolje dostupne alata za predviđanje proizvodnje električne energije iz promjenjivih OIE. Te bi prognoze trebali uzeti u obzir prilikom planiranja rada energetskog sustava. Političari bi trebali poduzeti mjere za uklanjanje (nepotrebnih) zapreka koje ograničavaju dostupnost izvora fleksibilnosti [70].

Dosadašnji dvotarifni model cijena električne energije će se u ovom radu zamijeniti tržišnim cijenama električne energije po uzoru na tržišta u EU i Sjedinjenim Američkim Državama. Dat će se usporedba modela energetskog sustava za satni vremenski korak i vremenski korak od 10 minuta. Hrvatska ima svoju burzu električne energije – Hrvatska burza električne energije d.o.o. (CROPEX) i pripada jugoistočnom europskom tržištu električne

energije zajedno s Bugarskom, Grčkom i Srbijom. Za potrebe proračuna preuzete su cijene električne energije s Hrvatske burze CROPEX za 2018. godinu koje su opisane u izvješćima za četiri godišnja kvartala 2018. godine [150], [151], [152], [153].

1.8 Cilj i hipoteze istraživanja

Cilj rada je usporedba modela EnergyPLAN, koji radi na satnoj bazi unosa podataka, s novim modelom na 10-minutnoj bazi. Analize će pokazati da novi model ima manje zahtjeve za dodatnom fleksibilnošću unutar sustava te pruža više detalja za razvoj tržišta električnom energijom. Upravljanje energetskim sustavom primjenom IKT tehnologije osigurat će potrebnu komunikaciju i integraciju svih sudionika energetskog sustava što će im omogućiti ekonomično sudjelovanje u sustavu.

Hipoteza je da će se samodostatnost energetskog sustava šireg gradskog područja ostvariti primjenom naprednog planiranja kroz razvoj pametnog energetskog sustava te povezivanjem sa susjednim tržištima električnom energijom.

1.9 Očekivani znanstveni doprinos

Izrada algoritma na 10-minutnoj bazi unosa podataka na temelju satnog modela EnergyPLAN rezultirat će smanjenjem potreba za dodatnom fleksibilnošću u sustavu i pružiti više mogućnosti za sigurniju integraciju 100% udjela OIE u sustavu.

Sadašnji dvotarifni model cijena električne energije zamijenit će se integriranim tržišnim modelom s 10-minutnim periodom trgovanja što će osigurati stabilnost sustava i regulaciju energetskih tokova, te omogućiti tržišno vrednovanje izvora fleksibilnosti u sustavu.

2 METODE I PODACI

Šire gradsko područje Dubrovnika obiluje potencijalom vjetroenergije, hidroenergije i sunčeve energije za proizvodnju električne energije odabranog energetskog sustava. Teritorij se proteže obalnim područjem uz more čime obiluje i potencijalom morske energije. U radu se teži ostvarenju samodostatnog energetskog sustava šireg gradskog područja s proizvodnjom električne energija iz 100% OIE, zamjenom KV s EV kao i zamjenom uređaja za grijanje i hlađenje na fosilna goriva s DTMV do 2050. godine. Cilj rada je usporedba modela EnergyPLAN, baziranog na satnom unosu podataka, s novim modelom na 10-minutnoj bazi.

Analize usporedbi modela i scenarija rezultiraju manjim zahtjevima za dodatnom fleksibilnošću unutar sustava. Pružaju više detalja za razvoj tržišta električnom energijom kod sustava s kratkoročnim periodom trgovanja električnom energijom. Za izradu modela i analiza potrebno je prvenstveno definirati i odrediti granice sustava šireg gradskog područja. U radu je odabran manji energetski sustav koji, kao što je prethodno u radu navedeno, ima veće zahtjeve za fleksibilnošću od većeg energetskog sustava, primjerice države. Jedan od razloga je manjak prostora koji sustav obuhvaća što smanjuje raznovrsniju i količinski manju raspodjelu proizvodnih jedinica električne energije, kao i potrošača i skladišta energije. Kratkoročno trgovanje električnom energijom i model energetskog sustava, baziran na vremenskom koraku od 10 minuta, omogućit će manjim energetskim sustavima smanjenje zahtjeva za fleksibilnošću i povećanje izvora fleksibilnosti. Sadašnji dvotarifni model cijena električne energije zamijenit će se varijabilnim cijenama električne energije s periodom trgovanja od 10 minuta. Povezivanjem sa susjednim energetskim sustavima kroz otvoreno tržište električnom energijom, te primjenom naprednog planiranja razvojem pametnog energetskog sustava, ostvarit će se samodostatnost energetskog sustava šireg gradskog područja.

Plan energetskog sustava za odabrano područje napravljen je do 2050. godine s osvrtom i na 2030. godinu. Upravljanje energetskim sustavom primjenom IKT tehnologije osigurat će potrebnu komunikaciju i integraciju svih sudionika, što će im omogućiti ekonomično sudjelovanje u sustavu. Unutar granica odabranog sustava potrebno je definirati sve sudionike i odrediti njihove uloge. Svaki energetski sustav sastoji se od potrošača, proizvođača i skladišta električne energije. U ovom poglavlju predstavit će se metode koje su korištene kao i podaci za potrebe proračuna. 2014. godina je odabrana kao bazna godina prema kojoj se izradio plan do 2050. godine. Podaci o proizvodnji električne energije sadržavaju podatke o potencijalu i proizvodnji hidroenergije, energije vjetra i sunčeve energije iz 2014. koja se planirala do 2050. godine. Potrošnja električne energije odnosi se na opterećenje općom potrošnjom iz 2014. za odabrano područje i također je planirana do 2050. godine. EV u 2014. godini nisu zastupljena

u odabranom energetskom sustavu, stoga je napravljen plan porasta udjela EV u sustavu i definirane su karakteristike BEV. EV u sustavu mogu spadati u sve tri kategorije sudionika sustava. U određenom trenutku mogu biti potrošači i izvor električne energije u vidu skladišta električne energije. Regulacija sustava ostvarit će se integracijom svih sudionika u sustavu, s naglaskom na sektor transporta i toplinski sektor, uz model varijabilnih cijena na otvorenom tržištu električne energije. [Slika 2] prikazuje dijagram toka za planiranje energetski samodostatnog šireg gradskog područja s potrebnim koracima i korištenim metodama.

Kao izvor fleksibilnosti u sustavu predstavit će se model izuzetno brzog punjenja i pražnjenja EV po modelu V2G i sustav DTMV sa skladištima energije. Model brzog punjenja EV u trajanju od 10 minuta, uz regulaciju punjenja i pražnjenja EV varijabilnim cijenama električne energije, koje ovise o proizvodnji električne energije, pružit će više mogućnosti za integraciju OIE u sustav. Izrađen je novi model, koji se bazira na kratkoročnom vremenskom koraku, po uzoru na EnergyPLAN. Novi algoritam izrađen je za 10-minutni i satni vremenski korak unosa podataka. U njemu su se izradile analize elektrifikacije transportnog sektora prema 4 odabrana slučaja. Dana je usporedba novog modela s EnergyPLAN-om u svrhu validacije novog modela, te usporedba 10-minutnog modela sa satnim modelom. Novi model nadogradio se modelom u programu Calliope. U Calliope-u se izradio model plana energetskog sustava šireg gradskog područja do 2050. godine, kroz integraciju transporta, toplinskog sektora i tržišta električnom energijom u dodatna energetska skladišta. Pomoću Calliope modela ispitala se samodostatnost energetsko sustava odabranog područja za plan do 2050. godine. Slijed razvoja i nadogradnju novog modela prikazuje [Slika 3].

U radu se dodatno izradila i analiza sustav DGH s DTMV i baterijama i TES za područje Starog grada Dubrovnika, kao jedne cjeline unutar odabranog područja. Svrha analize je detaljnije ispitivanje elektrifikacija toplinskog sektora. Rezultati će pokazati da potencijal takvog sustava može pruži bolje mogućnosti za integraciju OIE širom primjenom u energetskom sustav odabranog područja. U radu je prezentirana i analiza linearne korelacije i regresije proizvodnih potencijala vjetra i Sunca, te potrošnje električne energije i vanjske temperature zraka. Dana je usporedba rezultata za dugoročni vremenski korak, srednje mjesečne vrijednosti i kratkoročni vremenski korak od 10 minuta. Linearna korelacija i regresija daje detaljniji uvid u opis veza između energetskih tokova u odabranom sustavu, te uvid u trenutne zahtjeve za fleksibilnošću i moguće izvore fleksibilnosti. Analize i rezultati mogu biti korisni u energetskom planiranju, posebice za modele sustava bazirane na vremenskom koraku od 10 minuta.

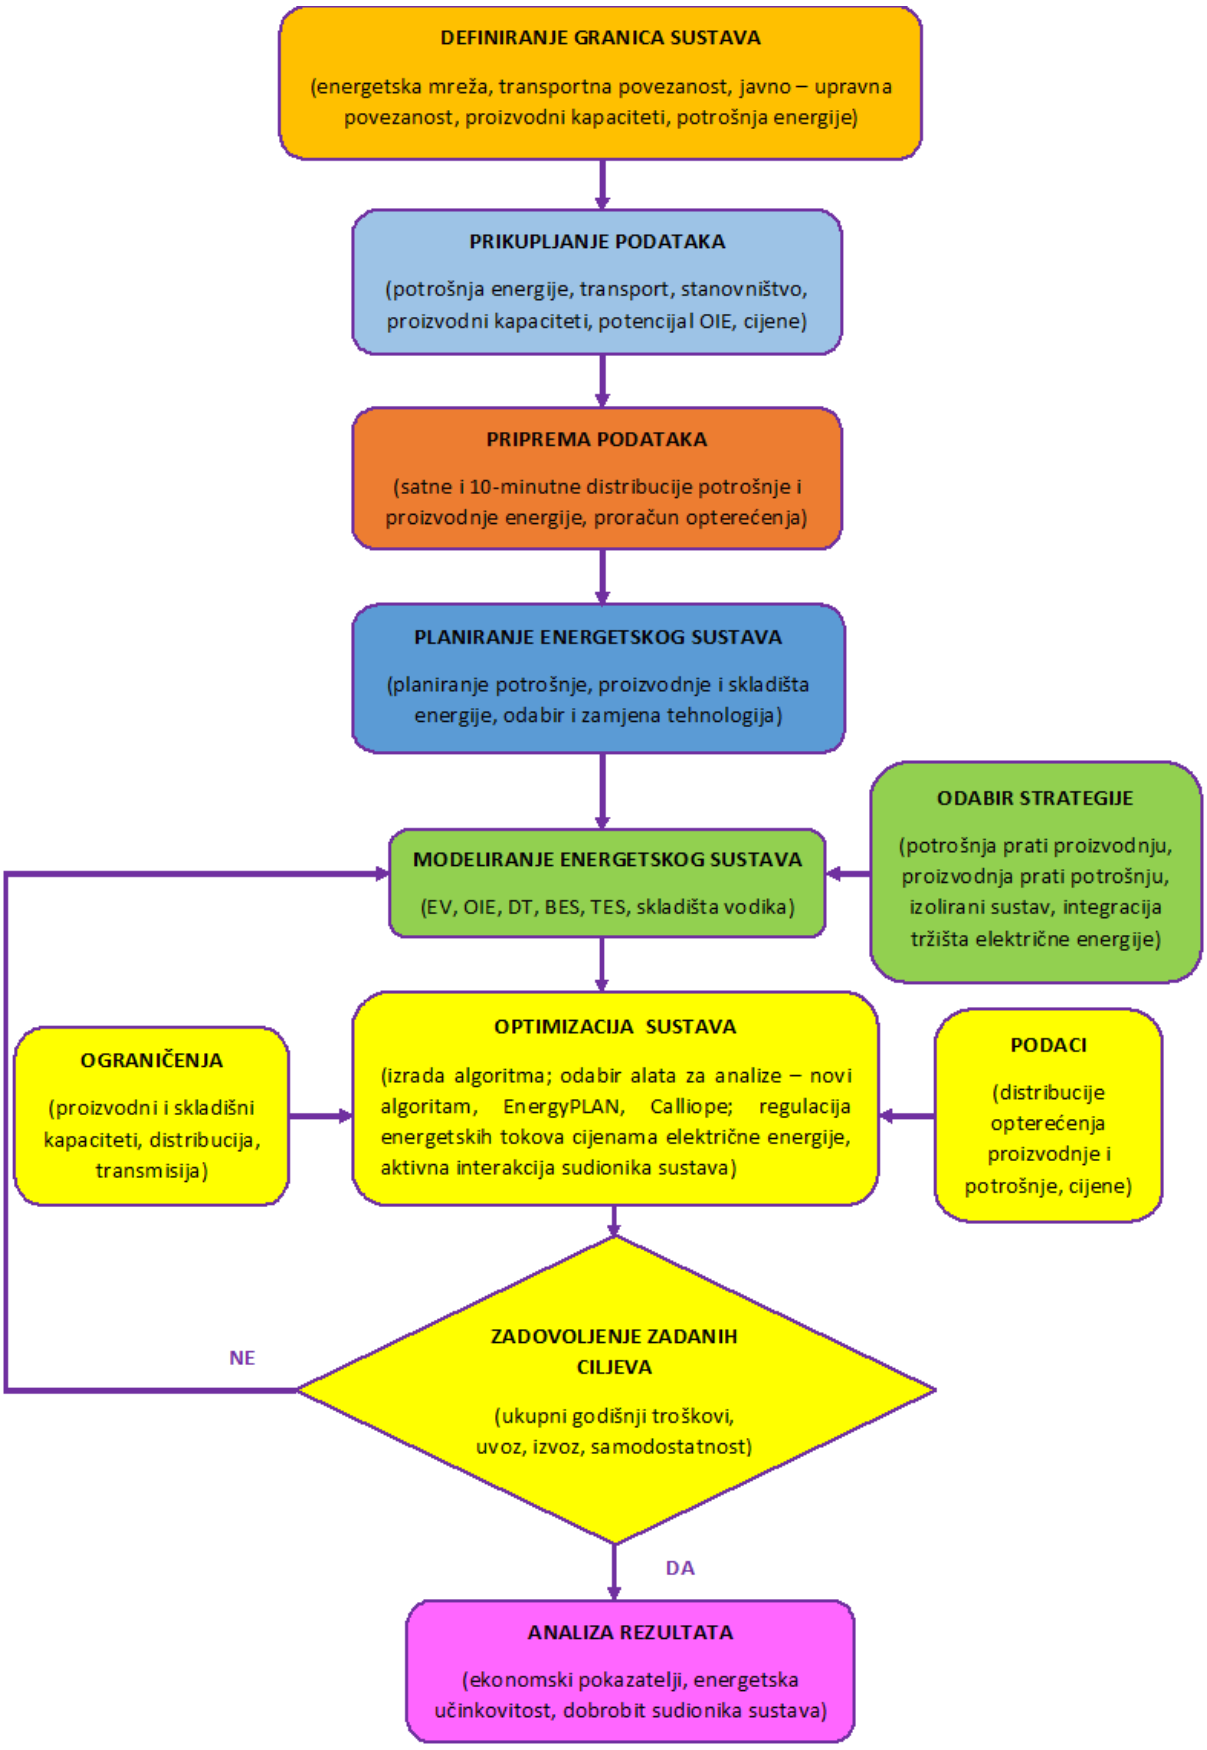

Slika 2. Koraci i metode u planiranju energetski samodostatnog šireg gradskog područja

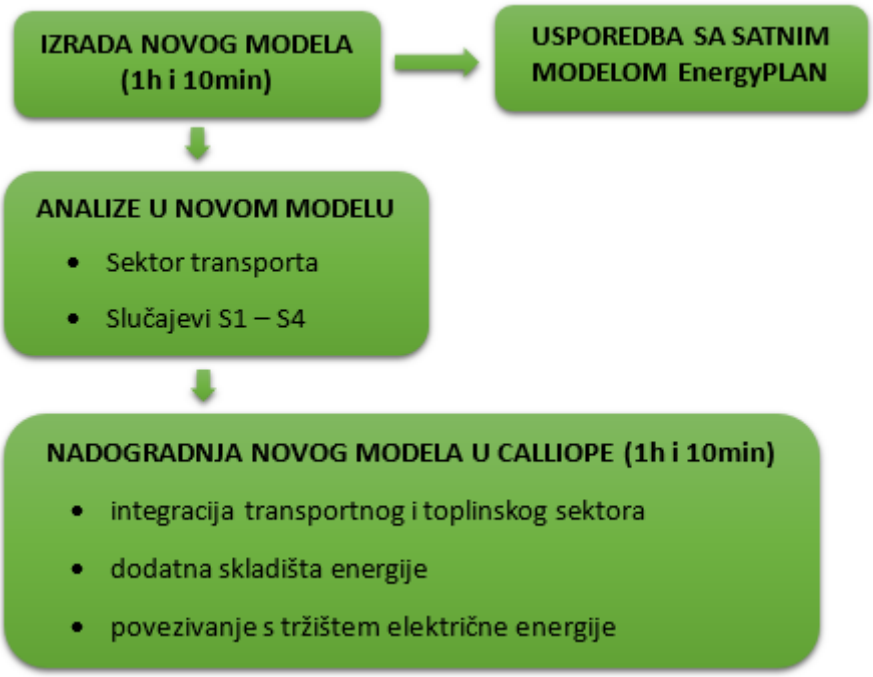

Slika 3. Tok razvoja novog modela, validacija i nadogradnja

2.1 Definiranje granica sustava

Rad se bavi analizom naprednog planiranja energetski samodostatnih širih gradski područja, a kao primjer uzeto je šire gradsko područje grada Dubrovnika. Grad Dubrovnik i njegova šira okolica nalazi se na samom jugu RH sa zemljopisnim koordinatama 42°38'26" s.z.š., 18°06'35" i.z.d. Za izradu energetskog plana potrebno je prvo odrediti granice sustava i dati opću definiciju šireg gradskog područja. U radu je odabrano šire gradsko područje jer je njime moguće obuhvatiti sve sudionike naprednog energetskog sustava u jednu zaokruženu cjelinu. Primjerice, elektrane za proizvodnju električne energije su u većini slučajeve smještene izvan gradske jezgre, u okolici grada, što bi ih prilikom odabira područja grada smjestilo izvan granica sustava.

Grad po definiciji predstavlja veće nastanjeno i gušće sagrađeno naselje s istaknutom starom gradskom jezgrom, razvijenim poslovnim središtem i drugim dijelovima kao što su proizvodni, uslužni, rekreacijski, stambeni, prometni i drugi dijelovi. U njemu prevladavaju neagrarne proizvodne i uslužne funkcije. Infrastrukturno je opremljen i u njemu se ističe "gradski način života". Okolica grada je područje koje okružuje gradsko naselje, a s njim je prostorno, demografski, funkcionalno i prometno usko povezano. Ranije su u njoj prevladavala ruralna naselja i agrarne djelatnosti. U novije doba dio okolice grada se suburbanizira i tako dolazi do njezine preobrazbe. Najbliži dijelovi okolice, pod utjecajem širenja gradskog naselja, postaju sastavni dijelovi gradske aglomeracije. U drugim užim dijelovima okolice, naselja se

jače ili slabije urbaniziraju i tek počinje njihova postupna preobrazba, kao sastavnih dijelova gradske regije. Na ostalom širem području okolice, koja je također funkcionalno povezana s gradom, i dalje se većinom ističu ruralna naselja s prevladavajućom agrarnom kao glavnom ili dopunskom djelatnošću, te se mogu razvijati i druge funkcije [154]. Šire gradsko područje, koje je odabrano za analizu u ovom radu, može se definirati kao područje grada s okolicom koja ga okružuje, a s njim je prostorno, demografski, funkcionalno i prometno usko povezana. U okolicu spadaju područja gradske aglomeracije, gradske regije a i šireg područja okolice koji je funkcionalno povezan s gradom. Granice EES šireg gradskog područja trebaju obuhvaćati sve sudionike energetskog sustava u jednu zatvorenu (zaokruženu) cjelinu. Pod sudionike EES spadaju svi potrošači i proizvođači energije kao i skladišta energije.

Granice sustava šireg gradskog područja grada Dubrovnika određene su prema distribuciji električne energije. Podaci o potrošnji električne energije za odabrano područje preuzeti su sa trafostanice (TS) Komolac. Ona napaja područje od Prevlake do Slanoga pa je to područje definirano kao šire gradsko područje Dubrovnika. Iako bi, geografski, područje sjeverozapadno od Slanoga, poluotok Pelješac, i Elafitski otoci trebali pripadati unutar granica ovog sustava, u ovom radu su oni izuzeti. Razlog tome je pojednostavljenje proračuna i ulaznih podataka. Oni su, za potrošnju električne energije, preuzeti sa TS Komolac koja distribucijom pokriva odabrani EES. Shema distribucijske mreže prikazana je na [Slika 4].

Grad Dubrovnik predstavlja urbano središte s kojim je njegova okolica povezana i uvelike njemu teži. Okolica je s Dubrovnikom prometno povezana javnim prigradskim prijevozom autobusnim linijama. Autobusne linije povezuju i poluotok Pelješac s Dubrovnikom, sve do Orebića, međutim, zbog jednostavnosti je područje označeno do Slanoga. Jedinice za proizvodnju električne energije za odabrani sustav proizvode električnu energiju u potpunosti iz OIE, u koje spadaju energija iz vjera, Sunca i hidroenergija. Postojeći i planirani proizvodni kapaciteti se nalaze u granicama sustava i smješteni su izvan gradskog naselja. Postojeće HE nalaze se u jugoistočnom dijelu odabranog područja u Župi dubrovačkoj. HE Dubrovnik nalazi se u mjestu Plat, a HE Zavrelje u mjestu Mlini. S obzirom da HE Zavrelje ima mali instalirani kapacitet od 2 MW, ona u proračunima nije uzeta u obzir u planiranju energetskog sustava odabranog područja. Od VE u obzir će se uzeti planirane VE Mravinjac i Konavoska brda. Ostatak proizvodnje električne energije iz OIE za odabrano područje planiran je iz proizvodnje električne energije iz FN sustava na krovovima objekata koji spadaju u granice sustava, kao i planiranih lokacija za SE na tlu. U granice sustava će biti smješteni planirani skladišni kapaciteti. Položaj i određene granice odabranog šireg gradskog područja prikazane su na [Slika 5], dobivenoj korištenjem Hotmaps-a [155].

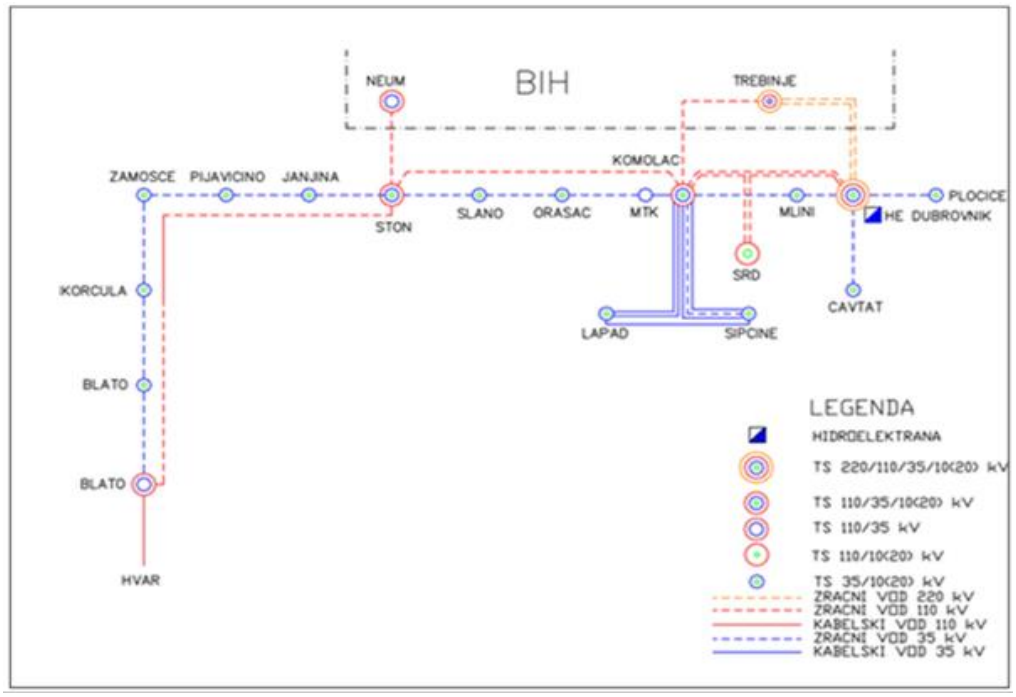

Slika 4. Shema distribucijske mreže, [156]

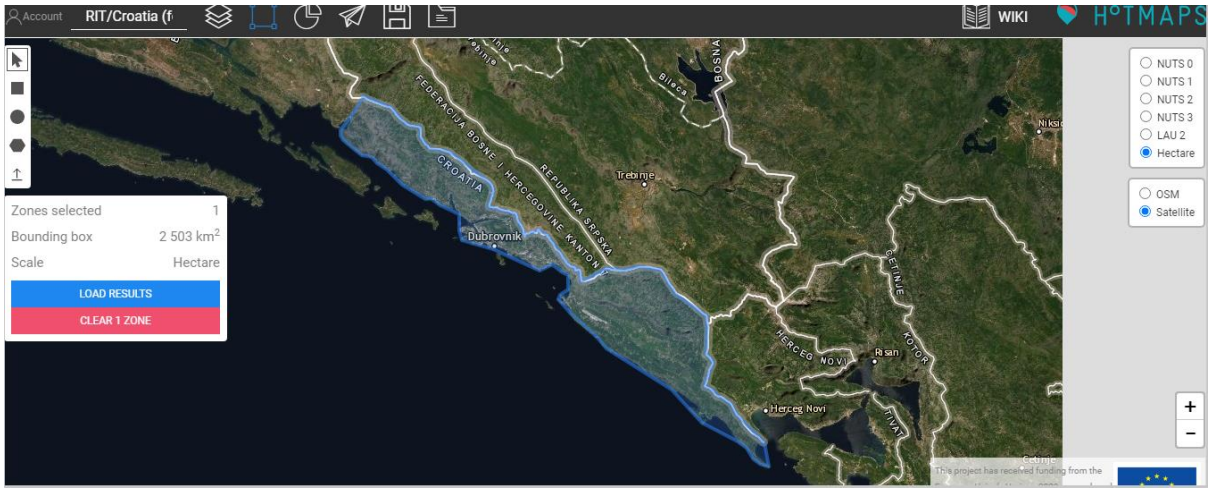

Slika 5. Lokacija i granice odabranog šireg gradskog područja

2.2 Fleksibilnost odabranog elektroenergetskog sustava šireg gradskog područja

Potrebe za fleksibilnošću u energetskom sustavu rastu što sustav obuhvaća manje područje. U velikim sustavima je i veća mogućnost za uvođenje većeg broja izvora fleksibilnosti. EES šireg gradskog područja Dubrovnika spada u manje sustave, što znači da su mu i potrebe za fleksibilnošću veće. Ukoliko se želi postići 100% obnovljiv i samodostatan energetski sustav, potrebno je pomno isplanirat izvore fleksibilnosti koji će to i omogućiti. [Slika 6] prikazuje planiranu fleksibilnost odabranog EES šireg gradskog područja s detaljima potreba i izvora fleksibilnosti.

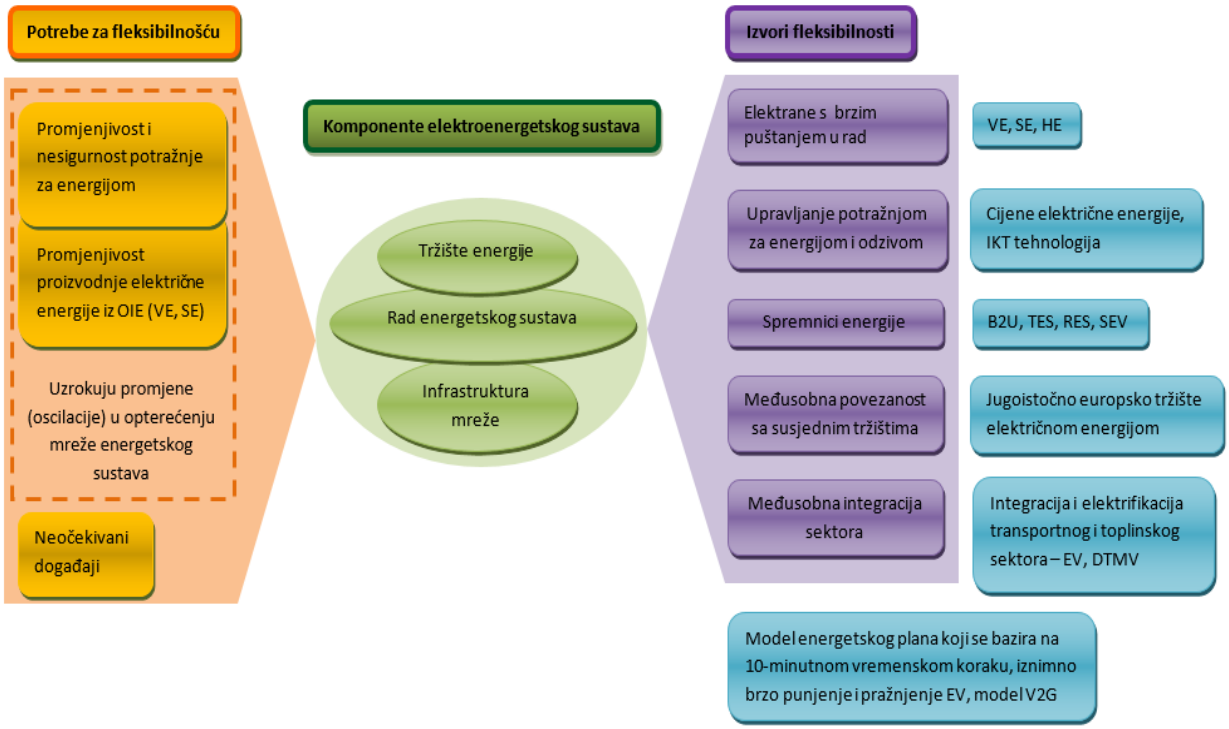

Slika 6. Fleksibilnost elektroenergetskog sustava odabranog šireg gradskog područja

Potrebe za fleksibilnošću proizlaze iz 100% obnovljive, promjenjive i nestalne proizvodnje električne energije, kao i promjenjive i nesigurne potražnje za električnom energijom. Proizvodnja se sastoji od VE i SE, koje se planiraju instalirati unutar granica odabranog sustava, uz postojeću HE Dubrovnik. Potrošnja ovisi o navikama i potrebama potrošača unutar energetskog sustava. Stoga, proizvodnja i potrošnja električne energije uzrokuju promjene u opterećenju mreže. Kao izvori fleksibilnosti u sustavu mogu ujedno biti i VE, SE i HE, jer spadaju u elektrane s brzim puštanjem u rad. Potrošnja, odnosno potražnja za električnom energijom također se može regulirati. To se može postići uvođenjem upravljanja potrošnjom električne energije, koje je stimulirano cijenama električne energije, uz primjenu IKT tehnologije. Spremnici energije vrlo su bitan izvor fleksibilnosti u sustavu. Od spremnika u ovom sustavu odabrane su BEV, kao mobilni spremnici, te stacionarni spremnici B2U, TES, RES i SEV.

Međusobna povezanost sa susjednim tržištima električnom energijom pruža mogućnost uvoza i izvoza električne energije. U ovom radu će se razmatrati jugoistočno europsko tržište električnom energijom s varijabilnim cijenama električne energije. Kao dodatni izvori fleksibilnost u sustavu, analizirat će se model energetskog sustava za vremenski korak od 10 minuta u cilju uvođenja modela V2G i iznimno brzog punjenja i pražnjenja EV. Kraći vremenski korak proračuna modela ima veće zahtjeve za fleksibilnošću jer su i veća odstupanja

opterećenja u sustavu. Međutim, model V2G i iznimno brzo punjenje i pražnjenje EV pružaju dodatne izvore fleksibilnosti kao i bolju mogućnost integracije EV a i OIE u sustav i čine iskorak u ovom radu.

2.3 Potencijal OIE za proizvodnju električne energije na odabranom području

Ovo poglavlje dat će pregled potencijala OIE odabranog područja, kao i podatke o postojećim instaliranim sustavima za proizvodnju električne energije koji pripadaju odabranom energetskom sustavu. U radu je dan pregled trenutne situacije s proizvodnjom električne energije iz OIE i budućim planiranim kapacitetima prema Planu korištenja OIE na području Dubrovačko-neretvanske županije (DNŽ) [36] i Strateškoj studiji [37] izrađenoj na temelju Plana. Plan korištenja OIE na području DNŽ sastoji se od četiri cjeline. Podijeljeno je prema izvorima energije:

- energija vjetra
- energija Sunca
- energija biomase
- geotermalna energija i energija mora
- hidroenergija (peta cjelina koja je dodana u ovom radu).

2.3.1 Energija iz Sunca

Dubrovnik i njegova okolica imaju značajan potencijal u iskorištavanju sunčeve energije za proizvodnju električne energije. Broj sunčanih sati u godini za Dubrovnik iznosi oko 2600 i spada među najozračenija područja na teritoriju RH. U većini kopnenog dijela DNŽ može se računati sa srednjom godišnjom ozračenosti između 1,50 i 1,55 MWh/m^2 [37]. [Slika 7] prikazuje prostornu raspodjelu srednje godišnje ozračenosti vodoravne plohe na području DNŽ.

Unatoč dobrom potencijalu, energija Sunca je i dalje slabo iskorištena na ovom području, ali je u porastu. Fotonaponske panele i kolektore, većinom u malom broju, posjeduju pojedini privatni objekti, dok su u većem broju zastupljeni na većim objektima poput hotela i javnih objekata. Sve to još nije od velikog značaja. U ovom radu će se uzeti u obzir instaliranje FN sustava na objektima i iskorištavanje raspoloživih kapaciteta.

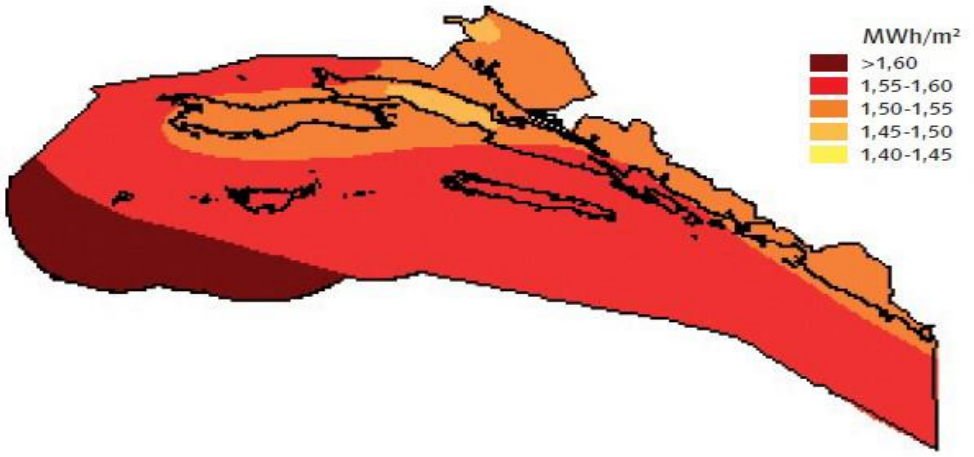

Slika 7. Karta srednje godišnje ozračenosti na području Dubrovačko-neretvanske županije, [37]

Podaci o potencijalu sunčeve energije dobiveni su iz podataka o sunčevom zračenju za 2014. godinu, koje je ustupio Državni hidrometeorološki zavod (DHMZ). Zračenje Sunca mjereno je svakih 10 minuta, a maksimalno zračenje za 2014. iznosilo je 703 J/cm^2. S obzirom da su neki podaci u 2014. nedostajali, oni su nadomješteni podacima iz 2013. za isto razdoblje u godini. Satne vrijednosti sunčeva zračenja dobivene su osrednjavanjem 10-minutnih vrijednosti zračenja unutar svakog sata. Dobivene 10-minutne i satne vrijednosti sunčeva zračenja korištene su za računanje proizvodnje električne energije iz Sunca u satnom i 10-minutnom modelu. [Tablica 2] prikazuje je validaciju podataka sunčeva zračenja gdje se može primijetit značajnije odstupanje vršnog opterećenja. Ono je za vremenski korak od 1 h smanjeno za 11,24% zbog osrednjavanja 10-minutnih vrijednosti sunčeva zračenja unutar svakog sata. Iz tog razloga je u manjoj mjeri smanjeno i ukupno godišnje sunčevo zračenje.

Tablica 2. Validacija podataka sunčeva zračenja za 2014. godinu za vremenski korak od 1 sata i 10 minuta

Vremenski korak	**1 h**	**10 min**
Maksimalno zračenje, [J/cm^2]	624	703
Validacija podataka	11,24%	
Ukupno zračenje, [kJ/cm^2/god.]	946,67	948,095
Validacija podataka	0,15%	

Prema Planu korištenja OIE na području DNŽ [36] i Strateškoj studiji [37], među većim brojem lokacija za postavljanje FN sustava, izdvaja se šest lokacija koje su odobrene za instalaciju SE na odabranom području, a prikazane su na [Slika 8] i navedene u [Tablica 3].

Tablica 3. Popis potencijalnih lokacija za SE odobrenih Planom [36] *za odabrano područje*

LOKACIJA		Površina, [ha]
A17	**Dubrovačko Primorje - Zadubravica**	8,3
A18	**Dubravica / Brsečine - Ravne glavice**	11
A19	**Konavle - Mokri Do**	8
A20	**Konavle - Dubok dol**	5
A21	**Konavle - Dugažica**	6
A22	**Konavle - Čulev dol**	5,4

Slika 8. Prikaz karte s označenim potencijalnim lokacijama za odabrano području, [36]

2.3.2 Energija iz vjetra

Okolno područje grada Dubrovnika ističe se i po dobrom potencijalu za iskorištavanje energije vjetra na kopnu. Najbolji potencijal ističe se za brda iznad Konavala, te na povišenim predjelima iznad Zatona i Slanoga. U najvećem dijelu DNŽ prevladavaju vjetrovi jugo do 30%, bura do 29%, maestral do 24% te levant do 15%. Snaga stalnih i umjerenih vjetrova najpovoljnija je za iskorištavanje energije vjetra. Lokalna obalna cirkulacija pokreće upravo takve vjetrove koji noću pušu s kopna prema moru, a danju s mora prema kopnu. U DNŽ se takav povoljan utjecaj može očekivati za lokacije koje se nalaze u široj okolici obalne linije. [Slika 9] prikazuje kartu vjetra za područje DNŽ, unutar kojeg spada i odabrano područje u radu. Takve lokacije moraju zadovoljavati niz zahtjeva od kojih su najvažniji: vjetropotencijal,

mogućnost transporta energije, prihvatljivost s obzirom na utjecaje na okoliš, zaštita prirode, pristupna infrastruktura i drugi [37]. Na tom području već postoje i u pogonu su VE Rudine i VE Ponikve, dok su VE Mravinjac i VE Konavoska brda u planu za izgradnju. VE Rudine i Ponikve ne spadaju u granice odabranog sustava pa su izuzete iz proračuna. Planirane VE Mravinjac i Konavoska brda spadaju unutar granica sustava i uzete su u obzir u proračunima kao OIE za proizvodnju električne energije. [Slika 10] prikazuje lokacije VE.

Prema Planu [36] u DNŽ nema mogućnosti za razvoj pučinskih VE u kojima bi se stupovi vjetroagregata temeljili na morskome dnu. Razlog tome je što na južnom Jadranu, uz otoke i obalu, dubina mora općenito raste brzo s udaljavanjem od obale. U tom bi se slučaju VE nalazile preblizu obale kako bi se zadovoljile dovoljno male dubine za ovaj tip VE. Preostaje mogućnost izgradnje pučinskih plutajućih VE usidrenih na morskom dnu, međutim, ta tehnologija je još u fazi razvoja. Plan ipak predlaže da se cjelokupni dio maritorija DNŽ, na kojemu je procijenjen vjetropotencijal sa srednjom godišnjom brzinom vjetra većom od 6 m/s, uvrsti u županijski Prostorni plan kao "*šire područje potencijalno prikladno za izgradnju plutajućih pučinskih vjetroelektrana usidrenih na morskom dnu*", uz naglasak da je potrebno provesti dodatna istraživanja [36].

Planirana VE Mravinjac će ukupno imati instaliranu snagu do 87 MW, u DNŽ, na području općine Dubrovačko primorje i grada Dubrovnika. Planirana je izgradnja 29 vjetroagregata, svaki do 3 MW. Prostor planiranog zahvata se nalazi u zaleđu Općine Dubrovačko primorje, uz lokalnu cestu koja od Slanog vodi prema Orašcu, između mjesta Riđica i Mrčevo. Od mjesta Slanoga lokacija je udaljena 7 – 8 km zapadno, a od Dubrovnika oko 50 km u smjeru sjeverozapada. Položaj se nalazi na području katastarskih općina Majkovi gornji, Majkovi donji i Mravinjac [157], [36].

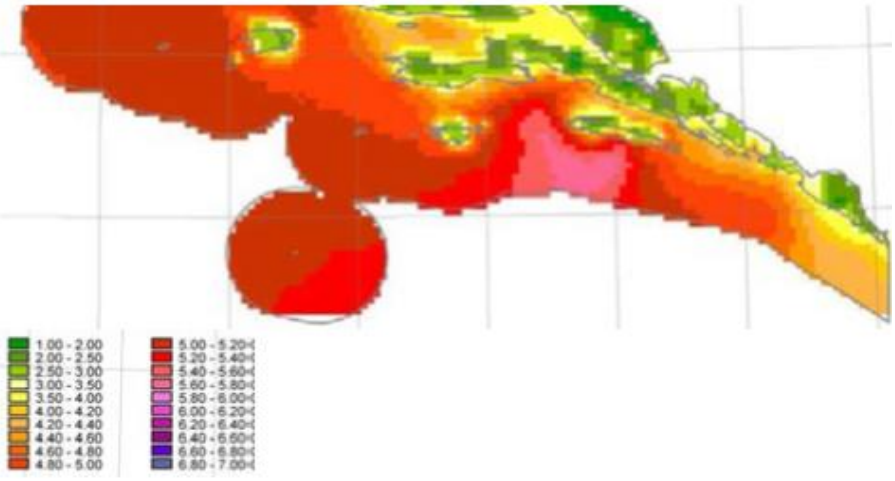

Slika 9. Karta vjetra za područje Dubrovačko-neretvanske županije, [37]

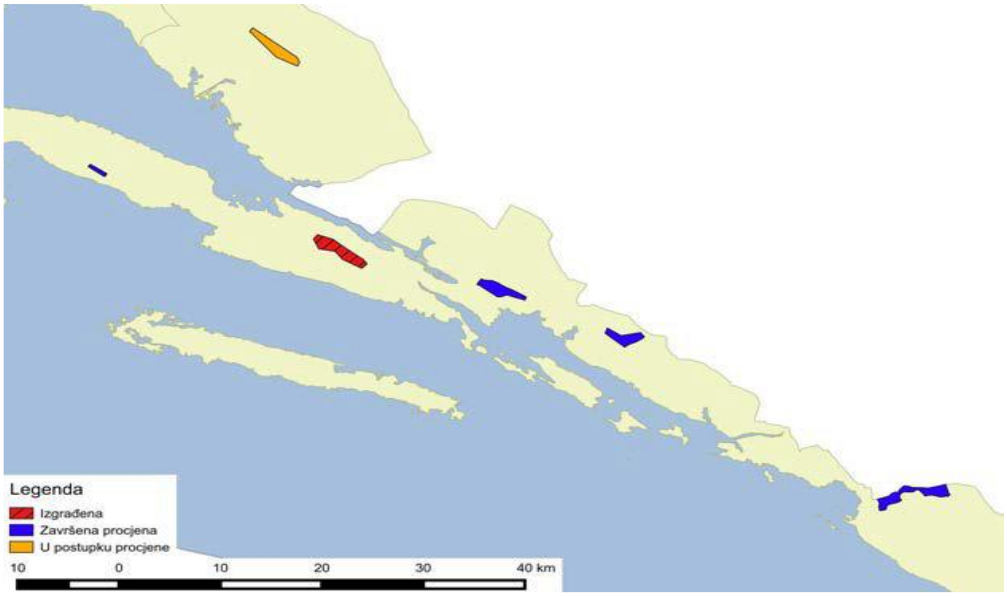

Slika 10. Trenutno stanje korištenja vjetropotencijala na području DNŽ, [37]

Lokacija VE Konavoska brda planirana je neposredno uz državnu granicu s BiH, povrh Cavtata i administrativno pripada teritoriju Općine Konavle. Prostornim planom DNŽ definirana je kao potencijalna makrolokacija za VE. 2012. godine je završen postupak procjene utjecaja na okoliš za projekt VE Konavoska brda s 44 vjetroagregata, svaki snage 3 MW, što je ukupno 132 MW instalirane snage. Na temelju procjene je izdano rješenje o prihvatljivosti zahvata na okoliš i ishođena je lokacijska dozvola [36]. Građevinska dozvola je izdana 2014. godine za 117 MW instalirane snage (39 x 3 MW). 2019. godine zatražena je izmjena zahvata na 150 MW instalirane snage (30 x 5 MW), međutim, za izmjenu je potrebno napraviti studiju utjecaja na okoliš i ishoditi rješenje o povoljnom utjecaju na okoliš [158].

Plan korištenja OIE na području DNŽ [36] predviđa i još dvije lokacije za izgradnju VE koje bi također ulazile u odabrano područje. To je lokacija Glave koja se djelomično preklapa s VE Mravinjac i lokacija Snježnica u Konavlima. Također, neke od SE poklapaju se s lokacijama VE pa postoji i mogućnost kombinacije tih elektrana na pojedinom području, kao što je lokacija za VE Mravinjac. Plan također predlaže i neke dodatne mikrolokacije SE na području DNŽ. [Slika 11] prikazuje raspored mogućih lokacija za elektrane na odabranom području predložene planom.

Podatke o potencijalu vjetra, korištene u ovom radu za proračune, za odabrano područje ustupio je DHMZ. Podaci se odnose na 10-minutne mjerne vrijednosti brzina vjetra u 2014. godini. S obzirom da dobiveni podaci za 2014. nisu bili kompletni, oni podaci koji su nedostajali nadopunjeni su podacima iz 2013. godine za isto razdoblje u godini. Time se dobila kompletna krivulja brzina vjetra s vremenskim korakom od 10 minuta. Maksimalna brzina

vjera iznosila je 21,3 m/s. Podaci o satnim brzinama vjetra za 2014. godinu dobiveni su računanjem srednje satne vrijednosti mjerenih 10-minutnih podataka unutar svakog sata. Dobivene krivulje korištene su u proračunima za proizvodnju električne energije iz vjetra za satni i 10-minutni vremenski korak. [Tablica 4] prikazuje validaciju podataka brzina vjetra za 2014. godinu između izvornih 10-minutnih podataka i dobivenih satnih vrijednosti. Ukupna suma svih podataka je jednaka, dok maksimalna vrijednost odstupa za 11,21% zbog osrednjavanja 10-minutni vrijednosti brzina vjetra unutar svakog sata.

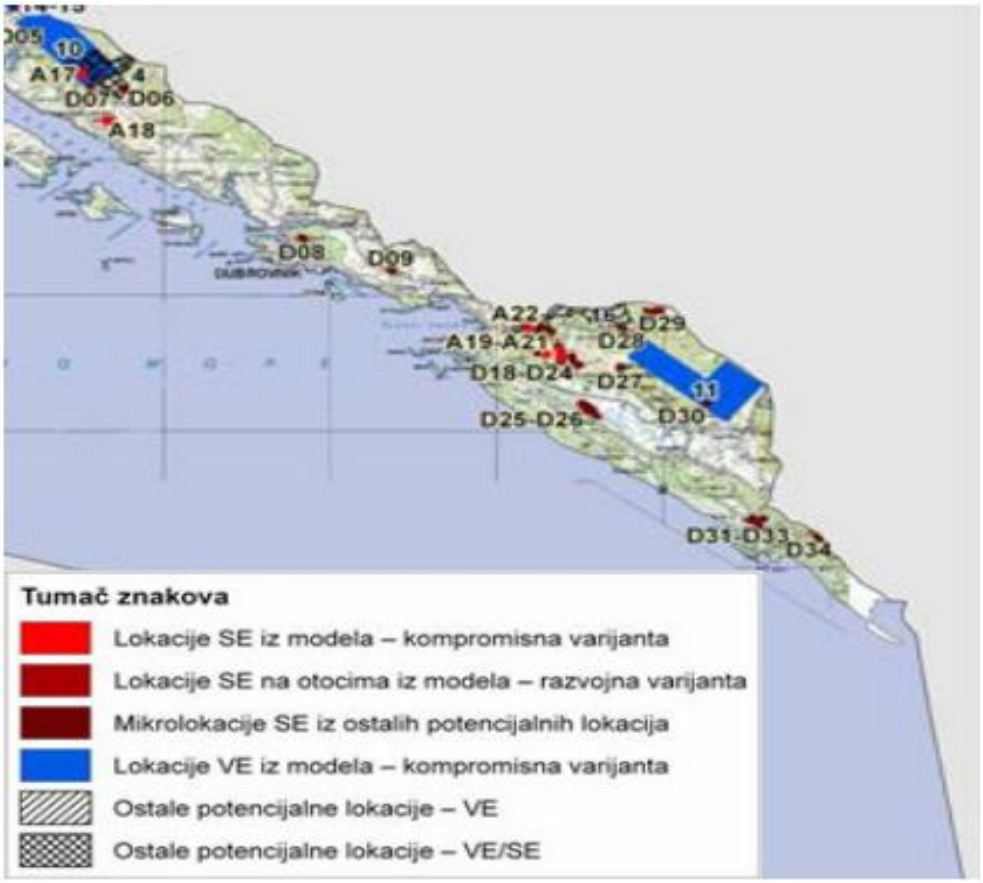

Slika 11. Prikaz prijedloga lokacija za izgradnju SE i VE, [36]

Tablica 4. Validacija podataka brzina vjetra za 2014. godinu za vremenski korak od 1 sat i 10 minuta

Vremenski korak	**1 h**	**10 min**
Maksimalna brzina vjetra, [m/s]	19,8	22,3
Validacija podataka	11,21%	
Zbroj svih podataka, [m/s/god.]	33762,63	33762,63
Validacija podataka	0%	

2.3.3 Hidroenergija

HE Dubrovnik je akumulacijska visokotlačna derivacijska HE s dva agregata. Strojarnica se nalazi u mjestu Plat, između Dubrovnika i Cavtata, u Dubrovačko-neretvanskoj županiji i u vlasništvu je Hrvatske elektroprivrede (HEP). HE Dubrovnik koristi vode koja pripadaju slivu rijeke Trebišnjice. Objekti HE Dubrovnik su smješteni u dvije države: brana Gorica, s kompenzacijskim bazenom, i ulazna građevina je u Federaciji Bosne i Hercegovine (FBiH), dovodni tunel s armiranobetonskim cjevovodom je dijelom u FBiH, a dijelom u RH, dok su vodna komora, tlačni cjevovod, strojarnica, odvodni tuneli i lukobran u RH. Strojarnica je smještena u podzemlju i predviđena je za četiri proizvodne jedinice. Za sada je realizirana I. faza 1969. godine sa dvije proizvodne jedinice (A i B) s Francis turbinama koje su prvotno imale svaka po 108 MW. Revitalizacijom HE Dubrovnik 2013.-2015. godine ugrađene su dvije Francis turbine instaliranog protoka 2x55 m^3/s i nazivnog pada 269,52 m. Raspoloživa snaga HE Dubrovnik je 2x126 MW (2x117,5 MW ako rade oba agregata). Agregat A radi za EES RH, a agregat B za elektroenergetski sustav FBiH. Uz glavne agregate, u elektrani rade i dva kućna agregata s Pelton turbinama snage po 1 MW. HE Dubrovnik elektroenergetskom sustavu RH može pružiti pomoćne usluge. Energetska veza elektrane s elektroenergetskim sustavom RH izvedena je kabelskom vezom od rasklopnog postrojenja (RP) 110 kV i 220 kV HE Dubrovnik do TS Plat u duljini 950 m. S elektroenergetskim sustavom FBiH povezana je dalekovodnom vezom od RP 110 kV i 220 kV HE Dubrovnik do RP Mokro polje, u duljini 12 km. Stoga, dio proizvodnje HE Dubrovnik se DV prenosi na ostatak RH kao i u FBiH, ovisno o potrebama. HE Dubrovnik organizacijski je povezana s HE Zavrelje koja je smještena nedaleko od strojarnice. HE Dubrovnik je zbog specifičnog značaja organizacijski samostalan pogon koji izravno pripada Sektoru za hidroelektrane [159]. HE Dubrovnik ustupila je mjerne podatke o proizvodnji električne energije za 2014. godinu. Podaci su mjereni za svaki sat u godini i dobila se krivulja godišnje proizvodnje električne energije za svaki pojedini sat. Iz satne krivulje dobila se krivulja proizvodnje za 10-minutni vremenski korak na način da se opterećenje u svakom satu razdijelilo se na šest 10-minutnih opterećenja. Ona su iznosom bila međusobno jednaka i jednaka proizvodnji za odgovarajući sat. S obzirom da je u 2014. godini HE Dubrovnik radila s instaliranom snagom od 108 MW, prije revitalizacije, dobiveni podaci o proizvodnji su se skalirali na snagu od 126 MW, koja je postignuta revitalizacijom HE. Iz dijagrama na [Slika 12] može se zaključiti da je HE Dubrovnik veći dio godine u funkciji i većinom radi pri maksimalnom opterećenju, osim u periodu od 26. rujna do 04. listopada, koji je predviđen za remont. Validacija podataka u [Tablica 5] pokazuje da nema razlike u podacima za vršno opterećenje niti ukupnu proizvodnju električne energije za različiti vremenski korak.

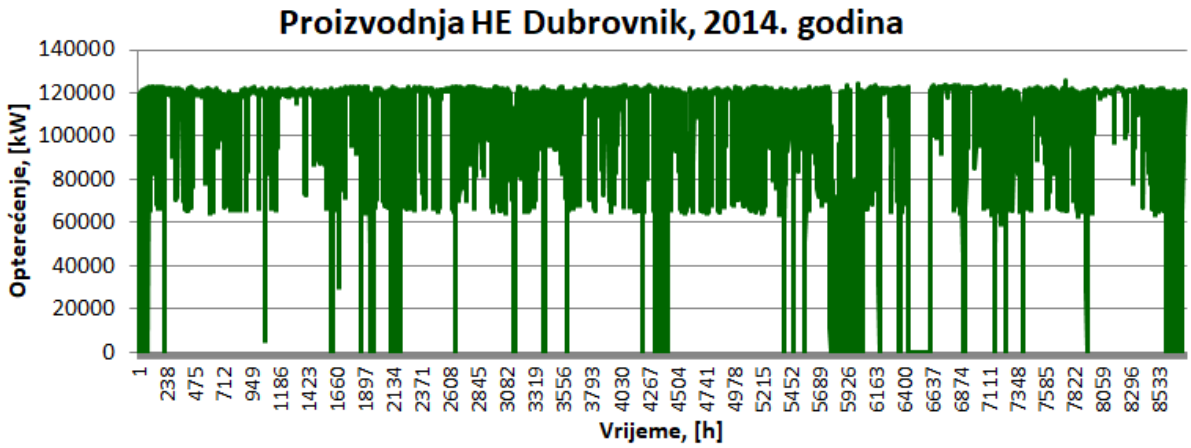

Slika 12. Proizvodnja električne energije HE Dubrovnik za 2014. godinu

Tablica 5. Validacija podataka proizvodnje električne energije iz HE Dubrovnik za vremenski korak od 1 sata i 10 minuta

Vremenski korak	**1 h**	**10 min**
Vršno opterećenje, [MW]	125,51	125,51
Ukupna proizvodnja, [GWh/god.]	893,74	893,74
Validacija podataka	0,0%	

HE Zavrelje u Mlinima u Župi Dubrovačkoj, 10 km jugoistočno od Dubrovnika. Izgrađena je 1952. godine i njenom izgradnjom započelo je iskorištavanje hidropotencijala u Dubrovačkom području. Puštena je u pogon 1953. godine. HE Zavrelje iskorištava vodu iz izvora Zavrelje u Župi Dubrovačkoj. Izvor je smješten na visini između 75,6 i 82,8 m n.v. Strojarnica HE Zavrelje smještena je na obali mora. Sadrži jednu proizvodnu jedinicu koja se sastoji od generatora i dvojne Francis turbine, nazivne snage 1,9 MW i ukupne godišnje proizvodnje od 4,6 GWh. Projektom su bile predviđene dvije proizvodne grupe, međutim, samo jedna je dovršena i u funkciji. Voda se ispušta u more odvodnim kanalom, gdje je izgrađen lukobran koji utječe na smanjenje valova koji mogu izazvati oscilacije donje vode HE. Električna energije za vlastitu potrošnju strojarnice HE Zavrelje preuzima se s mreže i/ili s izvoda generatora. Generator je direktno priključen na postrojenje 10 kV koje je u nadležnosti distributivnog poduzeća HEP ODS d.o.o. Elektrojug iz Dubrovnika [160]. HE Zavrelje u proračunima nije uzeta u obzir zbog svoje niske instalirane snage. Također su, prema Strateškoj studiji [37], navedene dvije potencijalne lokacije za male HE. HE Ljuta 1 i 2 na vodotoku rijeke Ljute na području Konavala. One su također niske instalirane snage, od 2 i 3 MW pa nisu uzete u obzir u planiranju energetskog sustava. Planirana HE Ombla, s instaliranom snagom od 68

MW, također nije uzeta u obzir u proračunima jer je njena realizacija upitna. Razlog tome je što je riječ o projektu koji je štetan, ekološki neprihvatljiv te ugrožava glavni izvor vode za grad Dubrovnik.

2.3.4 Energija biomase

Na temelju procijenjenog teoretskog energetskog potencijala raspoložive biomase dana je ocjena o mogućnosti korištenja biomase u energetske svrhe na području DNŽ. Prema Planu za OIE [36] postoje značajni, ograničeni resursi korištenja biomase za proizvodnju energije na području DNŽ. S obzirom da Planom nisu predviđene lokacije za preradu prikupljene biomase, Strateškom studijom [37] nisu vršene procjene o mogućnosti korištenja biomase kao OIE, odnosno nije vršena procjena utjecaja na sastavnice okoliša. Prema klimatološkim i pedološkim karakteristikama, kao i prema načinu korištenja zemljišta, mogućnosti DNŽ u smislu proizvodnje biomase su male i vjerojatno neisplative, odnosno potencijali dobivanja energije od biomase drveta na području DNŽ iznimno su niski. Uloga šuma na području DNŽ ima značajniju ekološku važnost od proizvodnje energije iz drvne biomase. Stoga se ni u ovom radu biomasa neće razmatrati kao potencijalni OIE.

2.3.5 Geotermalna energija

RH se može, s obzirom na geotermalni gradijent, podijeliti na tri osnovna područja: panonsko, centralno i područje Dinarida. DNŽ pripada području jadranskog priobalja i otoka (području Dinarida). Karakterizira ga niski geotermalni gradijent i niska vrijednost gustoće toplinskog toka. Pronalazak ležišta potencijalne termalne vode, kao osnovnog geotermalnog resursa, ograničen je kompleksnim tektonskim odnosima. Prevladavajući krški reljef, koji se odlikuje poroznošću, pogoduje otjecanju vode s tog prostora. Geotermalna energija se u DNŽ može koristiti putem DT koje su pogodne za niskotemperaturne sustave grijanja i/ili hlađenja te zagrijavanja potrošne tople vode (PTV). Moguća je njihova primjena za manje i veće objekte. Dizalice topline koriste stalnu temperaturu tla na dubini od oko 2 m ili iz podzemne vode. Koriste ju za potrebno dogrijavanje prostora (zimi), odnosno hlađenje (ljeti) i/ili za pripremu PTV. Dizalice topline mogu se postavljati i u plitkim bušotinama sa sondom, najčešće na dubini od 60 do 150 m. Korištenje dizalica topline bilo bi pogodno i vjerojatno isplativo za turističke kapacitete (hoteli, turističke zone i dr.). Na području DNŽ, do izrade Strateške studije [37], nisu vršena sustavna istraživanja ovog potencijala, pa u studiji nisu vršene daljnje procjene o mogućnosti korištenja geotermalne energije kao OIE. Također, ni u ovom radu se geotermalna energija neće uzeti u obzir u proračunima ni u planiranju energetskog sustava odabranog područja.

2.3.6 Energija mora – DTMV

Područje DNŽ ima dobar potencijal u iskorištavanju energije mora putem DTMV. Poslovni prostori, koji se griju i hlade samo tijekom dana i gdje nema izražene potrebe za pripremom PTV, mogu za potrebe toplinske energije koristiti sustave DT na zrak. Oni su ekonomičniji, uz vrlo male razlike energetske učinkovitosti, u odnosu na vodeni sustav. Međutim, hotelski a i stambeni objekti zahtijevaju viši stupanj dnevne primjene energije grijanja i hlađenja kao i značajnije potrebe za PTV i DTMV su idealan termotehički sustav za toplinske i rashladne potrebe. Upravo područje DNŽ, koje je orijentirano prvenstveno na turistički sektor, ima značajan broj hotela koji se mogu smatrati potencijalnim korisnikom DTMV. Stimuliranjem ugradnje sustava DTMV od strane županije u lokalnih jedinica, mogu se postići značajne uštede u potrošnji električne energije i zamijeniti skupe energente kao što je ukapljeni naftni plin (UNP), koji se često koristi za grijanje. Uštede iznose i do 50%, ovisno o sustavu grijanja i hlađenja koji se prethodno koristio. To bi značajno utjecalo na smanjenje potrošnje električne energije za hlađenje na razini županije, koja trenutno predstavlja problem zbog nedostatnih kapaciteta. U dokumentu Plana [36] su i navedene hotelske jedinice koje bi imale mogućnost korištenja sustava DTMV.

Ovaj rad analizira centralizirani sustav DTMV za područje Staroga grada Dubrovnika, kao i zamjenu dosadašnjih sustava za grijanje i hlađenje na odabranom području sa sustavima DT. DTMV u Starom gradu i nije novost s obzirom da se taj sustav u Kneževom dvoru koristi od 1980. godine, a 2019. godine izvršena je i zamjena starog sustava DTMV s novim.

2.4 Potrošnja energije na odabranom području

Potrošnja energije obuhvaća potrebe svih sudionika odabranog energetskog sustava za energijom. Podaci o općoj potrošnji električne energije za odabrano područje za 2014. godinu preuzeti su sa TS Komolac, koja snabdijeva odabrano područje od mjesta Slano do Prevlake. Veliki dio te potrošnje odnosi se na potrebe za grijanjem i hlađenjem jer većina objekata na tom području koristi električnu energiju za potrebe grijanja i hlađenja. Dio potreba grijanja i hlađenja snabdijeva se iz drugih, fosilnih izvora energije. U modelima energetskog plana u ovom radu planirana je zamjena svih fosilnih goriva s OIE do 2050. godine. Tako će se KV zamijeniti s EV, dok će toplinski sektor koristiti sustave DT pa će se samim time i potrošnja električne energije povećati za te potrebe.

2.4.1 Opća potrošnja električne energije – opterećenje TS Komolac

Podatke opće potrošnje električne energije ustupio je Elektrojug Dubrovnik, HEP ODS d.o.o., za 2014. godinu. Dobiveni podaci su 15-minutne mjerene vrijednosti potrošnje

električne energije kroz godinu. Podatke je bilo potrebno svesti na 10-minutne i satne vrijednosti kako bi ih prilagodili modelima proračuna. 10-minutne vrijednosti dobivene su interpolacijom vrijednosti 15-minutnih podataka. Satne vrijednosti za 2014. godinu dobivene su računanjem prosječnih vrijednosti 15-minutnih podataka unutar jednog sata za svaki sat. Validacija podataka dobivenih iz 15-minutne krivulje prikazana je u [Tablica 6].

Tablica 6. Validacija podataka o potrošnji električne energije na TS Komolac

Opća potrošnja električne energije – TS Komolac, 2014. godina			
Vremenski korak	**10 min**	**15 min**	**1 h**
Vršno opterećenje, kW	54086,6667	54096	53984
Validacija podataka	0,017%		0,207%
Ukupna potrošnja, MWh/god.	249433,7	249432,6	249432,6
Validacija podataka	0,00046%		0%

2.4.2 Konvencionalna i električna vozila

U 2014. godini, koja je odabrana za baznu godinu, dubrovačko područje ne bilježi ni jednu instaliranu električnu punionicu za EV. Prva punionica instalirana je 2017. godine, nakon čega je uslijedio i porast broja punionica. 2019. godine Dubrovnik uvodi i *"car sharing"* princip sukorištenja vozila (dijeljenje vozila) s 30 EV. KV su i dalje zastupljena kod osobnih vozila, poglavito zbog nesređene infrastrukture i nedovoljnog broja punionica, a i cijene EV na tržištu. Vjerojatno je da će se u budućnosti i to mijenjati jer grad Dubrovnik razvija i realizira plan pametnog grada planiranjem održive urbane mobilnosti [161].

Do 2050. godine vjerojatno će doći do velikog broja EV koja će skoro u potpunosti zamijeniti KV u cilju smanjenja ispuštanja stakleničkih plinova u atmosferu. Ovaj rad će u energetskom planu do 2050. uzeti u obzir porast udjela EV i to do 100%. Predviđanje povećanja udjela EV do 2050. za šire gradsko područje Dubrovnika prethodno je izvedena u diplomskom radu [162] i [2], koja je preuzeta i u ovom radu. Za proračun broja EV na odabranom području korišteni su podaci o broju vozila u Hrvatskoj [163]. Na temelju broja osobnih vozila u 2010. godini u Hrvatskoj i na odabranom području, dobiven je udio osobnih vozila na odabranom području u ukupnom broju osobnih vozila u Hrvatskoj i prikazan u [Tablica 7]. Iako je udio osobnih vozila izračunat na temelju broja vozila iz 2010., u ovom radu se također uzeo taj podatak jer je porast udjela EV za Hrvatsku rađena na temelju 2010. godine. Prema [Tablica 8] se vidi da se broj osobnih KV za 2010. ne razlikuje puno od broja vozila u 2014. Podatak o broju vozila obuhvaća područje od Brsečina do Župe Dubrovačke i podatak je ustupio je MUP – Ministarstvo unutarnjih poslova RH.

Tablica 7. Broj osobnih vozila u Hrvatskoj i Dubrovniku u 2010. godini

Godina	**2010.**
Broj osobnih vozila u Hrvatskoj	1220302
Broj osobnih vozila u Dubrovniku	16617
Postotak osobnih vozila u Dubrovniku u ukupnom broju osobnih vozila u Hrvatskoj (%)	1,362

Tablica 8. Validacija podataka o broju vozila za 2010. i 2014. godinu

Godina	**2010.**	**2014.**
Broj osobnih KV	16617	16747
Validacija podataka	0,78%	

2.4.3 Potrošnja energije za grijanje i hlađenje

Najveći dio potrošnje energije za grijanje i hlađenje na odabranom širem gradskom području odnosi se na potrošnju električne energije, od čega grijanje i hlađenje zauzima većinski udio u ukupnoj potrošnji električne energije. Hlađenje je u potpunosti pokriveno uređajima koji koriste električnu energiju, dok se na grijanje, osim električne energije, koristi UNP, loživo ulje i biomasa. U sklopu projekta JointSECAP izrađen je Zajednički akcijski plan energetskog razvitka i klimatskih promjena za područje Grada Dubrovnika, Općine Konavle, Općine Župa dubrovačka, Općine Dubrovačko primorje i Općine Ston [164]. Za to odabrano područje od četiri općine i grada analizirana je neposredna potrošnja finalne energije u sektoru zgrada. Zgrade su podijeljene na sektor javnih zgrada, sektor stambenih zgrada (kućanstava) i sektor zgrada komercijalnog i uslužnog sektora (tercijarni sektor). Podaci iz tog plana korišteni su za procjenu potrošnje energije na grijanje i hlađenje odabranog područja u radu. Područje analizirano u planu ne poklapa se s granicama odabranog šireg gradskom područja, gdje bi se trebale izdvojiti Općina Ston i Općina Dubrovačko primorje. S obzirom da se korišteni podaci iz plana odnose na postotke udjela električne energije u neposrednoj finalnoj potrošnji i da najvećim dijelom u ukupnoj potrošnji sudjeluje Grad Dubrovnik, može se smatrati da je razlika u postocima zanemariva. Također, podaci preuzeti iz plana, kao baznu godinu koristili su 2015. godinu. Kako se radi o potrošnji energije koja se iz godine u godinu ne mijenja mnogo, te se podatke može koristiti kao relevantne.

Potrošnja električne energije u neposrednoj potrošnji finalne energije 2015. godini u sektoru kućanstva iznosila je 56%, u tercijarnom sektoru 86% i u sektoru javnih zgrada 53%. Od toga najveći dio potrošnje električne energije zauzima grijanje i hlađenje te PTV. Iz toga

proizlazi da potrošnja električne energije u ukupnoj neposrednoj potrošnji finalne energije zauzima 68%. Ostala potrošnja odnosi se na UNP, biomasu i loživo ulje koji se koriste za grijanje. Udio potrošnje električne energije u neposrednoj potrošnji finalne energije za tri sektora dobiven je prema jednadžbi (1):

$$e_{el.en.} = \frac{E_K \cdot e_{el.en.,K} + E_T \cdot e_{el.en.,T} + E_{JZ} \cdot e_{el.en.,JZ}}{\left(E_K + E_T + E_{JZ}\right)} \quad (1)$$

Za određivanje ukupnih toplinskih potreba korišten je internetski program Hotmaps [155]. Za označeno područje odabranog šireg gradskog područja, korištenjem Hotmaps-a, dobiven je podatak o ukupnoj potrebnoj godišnjoj energiji za grijanje i hlađenje i PTV u 2014. godini. Hotmaps također daje i zasebno podatke o potrebama grijanja za stambeni i nestambeni sektor. [Tablica 9] prikazuje podatke dobivene korištenjem Hotmaps-a za odabrano područje .

Hotmaps nudi opciju za predviđanje potreba daljinskog grijanja, odnosno za koji se dio odabranog područja može koristiti daljinsko grijanje. Ispada da, od ukupne potrebne energije za grijanje prostora i PTV, 29% može biti pokriveno daljinskim grijanjem. U ovom slučaju je to 69,12 GWh/god. [Slika 13] prikazuje odabrano šire gradsko područje i dijelove područja na kojima je moguće primijeniti daljinsko grijanje. Iz slike se vidi da grad Dubrovnik i naselje Mokošica imaju značajan potencijal za primjenu daljinskog grijanja. Potencijal je nešto manji za područje Župe Dubrovačke i vrlo mali potencijal mjesta i naselja uz obalu na području Konavala i sjeverozapadno od Dubrovnika, mjesta kao Trsteno i Zaton. Razlog manjem potencijalu je što ta mjesta nisu gusto naseljena kao što je to sam grad Dubrovnik i naselje Mokošica.

Tablica 9. Toplinske i rashladne potrebe odabranog šireg gradskog područja gada Dubrovnika za 2014. godinu

Toplinske i rashladne potrebe	2014. godina, [GWh/god.]
Stambeni sektor - grijanje prostora	160
Stambeni sektor - PTV	33
Nestambeni sektor - grijanje prostora	42
Nestambeni - PTV	3,83
Ukupne toplinske potrebe	239,83
Rashladne potrebe	77,37

Slika 13. Potencijal primjene daljinskog grijanja za odabrano šire gradsko područje [155]

2.5 Energetski sustav – prijenos prekograničnih dalekovoda i distribucija i opskrba

Šire gradsko područje Dubrovnika napaja se električnom energijom preko TS 110/35/10 kV Komolac. [Slika 14] prikazuje shemu EES koju je ustupio Hrvatski operator distribucijskog sustava (HOPS) [165]. Iz slike se vidi da su DNŽ, kao i odabrano područje u radu, povezani s EES RH na naponskoj razini 110 kV vezama Makarska-Opuzen, Čapljina-Ston, s ogrankom za TS 110 kV "Opuzen" i tzv. otočnom vezom Zakučac-Brač-Hvar-Korčula-Ston. Odabrano šire gradsko područje povezano je DV i sa susjednim EES FBiH preko TS Trebinje. Dva su prekogranična dalekovoda tranzitna i jedan proizvodni/spojni. Realan mogući prijenos prekograničnih dalekovoda prema TS Trebinje su:

- Tranzitni:

  a) DV 220 kV (D221) Plat - Trebinje 1:

  274 MVA (720 A; 20 s);

  ograničenje: SMT (600 A)

  b) DV 110 kV (D138) Trebinje - Komolac:

  89 MVA (468 A; 20 min);

  ograničenje: DV (440 A)

- Proizvodni / spojni:

  a) DV 220 kV (D236) HE Dubrovnik AG-1 - Trebinje 2:

  137 MVA (360 A; 4 s);

  ograničenje #1: SMT (300 A)

  ograničenje #2: HE DUB AG-2 Smax = 130 MVA

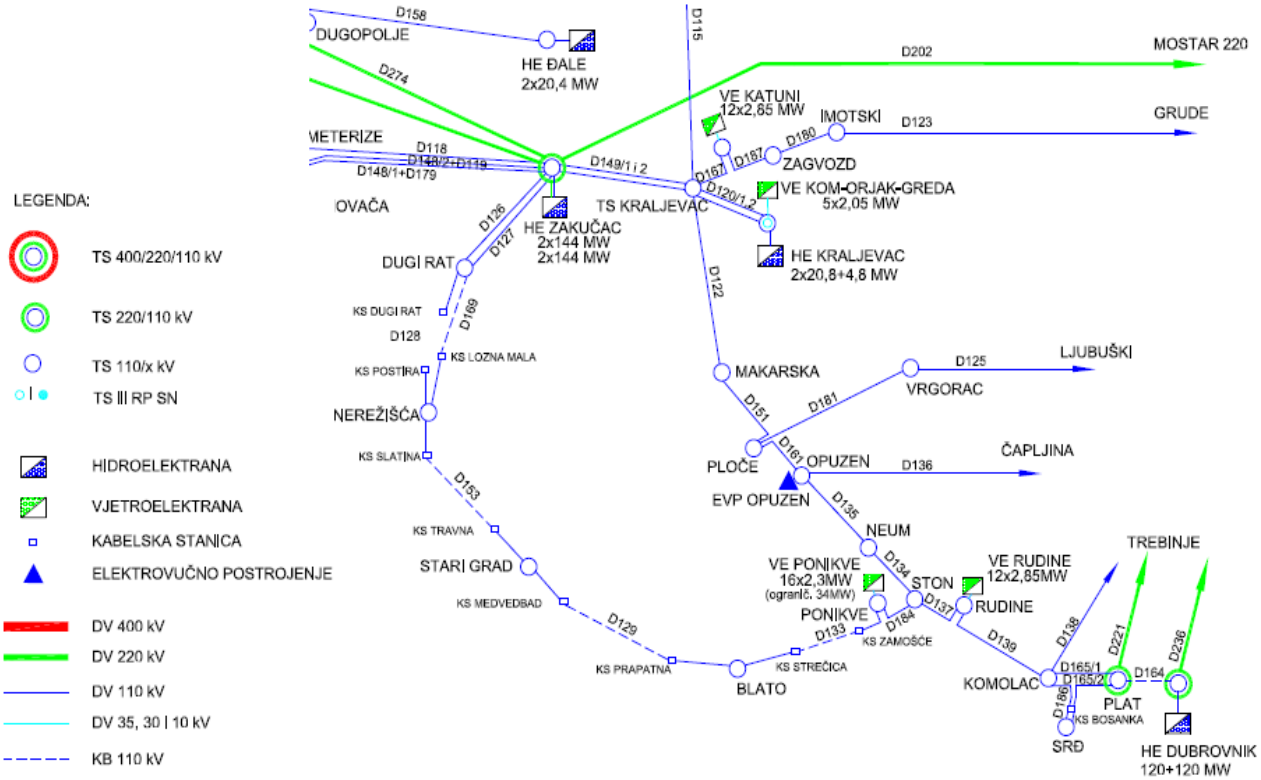

Slika 14. Shema EES – šire gradsko područje Dubrovnika i veza s ostatkom Hrvatske i susjednim EES - izvor HOPS

Podatke o DV ustupio je HOPS [165]. Prve vrijednosti označavaju teoretski mogući prijenos DV. Trenutni mogući prijenos je ograničen ugrađenim strujnim mjernim transformatorima. Iz toga proizlazi da se trenutno sa D221 može prenijeti 229 MVA, sa D138 84 MVA a sa D236 114 MVA. Stoga bi ukupan realan mogući prijenos DV na susjedni EES iznosio 427 MW. U proračunima u programu Calliope, prilikom razrade odabranog EES, potrebno je odrediti prijenosne kapacitete DV kako bi se odredio njihov mogući prijenos za uvoz i izvoz. S obzirom da je HE Dubrovnik povezana posebnim DV sa TS Trebinje, ona je u proračunima uzeta kao spojena zasebno sa susjednim EES s realnim mogućim prijenosom od D236 114 MW. D221 s prijenosom 229 MW i D138 s prijenosom 84 MW promatrani su kao jedna veza kojoj je još dodana i veza prema ostatku EES RH u iznosu od 87 MW, što skupa čini 400 MW mogućeg prijenosa prema susjednim sustavima. Radi jednostavnosti proračuna, sve spojne točke su se

razmatrale kao jedna točka koja je predstavljala realan mogući prijenos od ukupno dva prekogranična DV i jedan prema RH i iznosi 400 MW.

2.6 Skladištenje energije

Za vrste skladišta u odabranom energetskom sustavu, kao izvori fleksibilnosti, uzete su mobilne baterije u EV i stacionarne baterije EV u obliku B2U, SEV sustavi na principu dobivanja vodika elektrolizom vode i TES i RES za toplinske i rashladne potrebe u sustavu DTMV. Sustavi skladištenja energije detaljnije su opisani u narednim poglavljima.

2.6.1 Baterije EV – mobilni i stacionarni spremnici energije

U zamjeni KV s EV koristit će se EV s litij-ionskim baterijama čije su karakteristike i broj vozila u sustavu opisani u poglavljima 2.9.2.3 i 2.9.2.4. Prikazat će se usporedba standardnog punjenja u trajanju od 5 sati za vremenski korak proračuna od 1 sat i iznimno brzog punjenja u trajanju od 10 minuta za vremenski korak proračuna od 10 minuta u analizama utjecaja na integraciju OIE u sustav. Usporedit će se i neregulirano punjenje s reguliranim punjenjem i pražnjenjem koje uključuje model V2G. Regulacija punjenja i pražnjenja EV će se vršiti cijenama električne energije prema različitim scenarijima. Rezultati proračuna će pokazati koji scenarij pruža veću fleksibilnost sustavu u cilju bolje integracije OIE i smanjenja uvoza i izvoza električne energije.

U 2050. godini uzet će se u obzir i mogućnost uvođenja modela B2U nakon što baterije EV završe svoj životni vijek u vozilu. U radu je odabrano da će baterije ići u B2U nakon 10 godina upotrebe i kada dosegnu 80% ukupnog kapaciteta. U tom će se modelu koristiti idućih 10 godina dok ne spadnu na 50% ukupnog kapaciteta. Stoga je određen broj EV u 2040. godini, kao srednja vrijednost broja vozila između 2030. i 2050. godine. Broj vozila iz 2040. godine će u 2050. godini imati zamjenu svojih baterija radi sigurnosti vožnje, dok će stare baterije ići u B2U kao stacionarni spremnik energije. Ovi parametri su odabrani radi jednostavnosti proračuna prema prethodno izloženoj literaturi. Nije realno za očekivati da će sva EV iz 2040. godine trebati zamjenu baterija i da će sve baterije ići u B2U s 80% početnog kapaciteta. U radu je, radi jednostavnosti proračuna, tako određeno. Baterije u B2U imaju jednake karakteristike kao i baterije EV samo sadrže 80% ukupnog kapaciteta.

2.6.2 SEV – stacionarni spremnici energije

Kao dodatni izvor fleksibilnosti u energetskom sustavu šireg gradskog područja, odabrani su stacionarni SEV koji rade na principu elektrolize vode. Spremnici rade na principu korištenja električne energije u vrijeme viška proizvodnje električne energije iz OIE, koja ide u elektrolizator u kojem se vrši elektroliza vode, odnosno pretvorba vode u vodik i kisik.

Dobiveni vodik se skladišti u SEV i u vrijeme manjka proizvodnje električne energije, ponovnom pretvorbom vodika u električnu energiju u gorivnom članku, opskrbljuje sustav električnom energijom i pridonosi smanjenju uvoza i izvoza kao i boljoj integraciji OIE u sustav. [Slika 15] prikazuje princip rada SEV sustava. Sustav SEV sastoji se od elektrolizatora, spremnika plinovitog vodika i gorivnog članka. U elektrolizator se dovodi električna energija iz mreže koja daje energiju za elektrolizu vode. Plin vodik dobiven elektrolizom skladišti se u spremnik. U gorivnom članku vodik se ponovno pretvara u električnu energiju i koristi u energetskom sustavu kao izvor energije u vrijeme manjka proizvodnje električne energije. Učinkovitosti sustava SEV dane su u [Tablica 10]. Kapacitet SEV nije određen, već će se proračunima odrediti kapacitet spremnika ovisno o potrebama sustava i cijenama električne energije kao i samog spremnika.

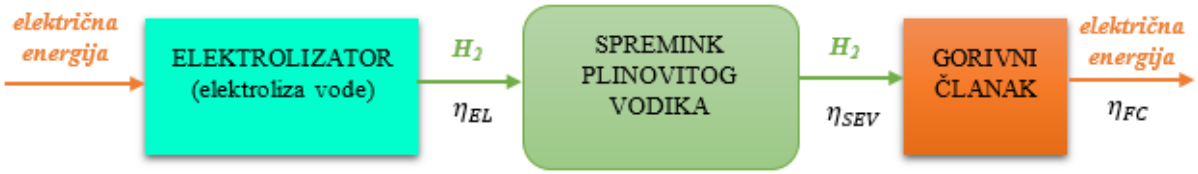

Slika 15. Princip rada i energetski tokovi u sustavu SEV

Tablica 10. Učinkovitosti sustava SEV, [149]

SEV sustav	Učinkovitost, [%]	Povratna učinkovitost, [%]
Elektrolizator, η_{EL}	80	54
Spremnik plina, η_{SEV}	97	
Gorivni članak, η_{FC}	70	

2.6.3 TES i RES – stacionarni spremnici energije

Sustavima DTMV dodani su TES i RES za opskrbu toplinskih i rashladnih potreba. Sustav DTMV opisan je u poglavlju 2.8 sa svim bitnim karakteristikama. Primjer sustava DGH s DTMV uz BES i TES i njihovom usporedbom detaljnije je analiziran za područje Staroga grada u cilju bolje integracije OIE u sustav. Radi jednostavnosti proračuna, za sustave DTMV na širem gradskom području odabrani su sustavi s jednakim radnim karakteristikama, a uz TES dodan je i RES sustav za rashladne potrebe. Efikasnost TES i RES uzeta je 99%, dok je za pohranu toplinske energije primijenjen SCOP (*"Seasonal Coefficient Of Performance"*) i za rashladnu SEER (*"Seasonal Energy Efficiency Ratio"*), kako je to određeno za sustav DTMV. [Slika 16] prikazuje energetske tokove i pretvorbu električne energije u toplinsku i rashladnu energiju. Električna energija dovodi se iz mreže za rad DTMV, koja pretvorbom električne

energije u toplinsku i rashladnu, zadovoljava toplinske i rashladne potrebe unutar sustava. U vrijeme viška proizvodnje električne energije iz OIE i manjka potreba za toplinskom i rashladnom energijom, DTMV koristi električnu energiju koju pretvara u toplinsku i rashladnu i skladišti u TES i RES. Uskladištena energija se koristi u vrijeme povećanih potreba za toplinskom i rashladnom energijom kada je u sustavu manjak proizvodnje električne energije iz OIE.

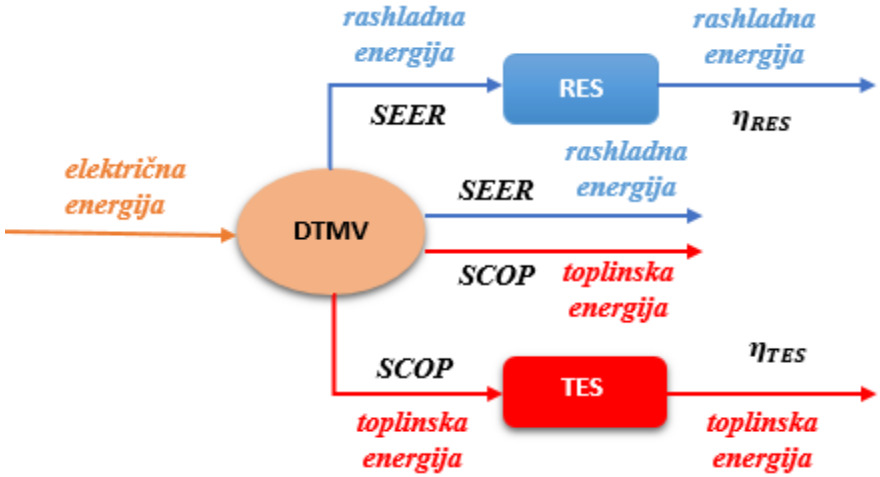

Slika 16. Prikaz energetskih tokova u sustavu DTMV s TES i RES

2.7 Linearna korelacija i regresija

Analize linearne korelacije i regresije napravljene su u sklopu ovog rada za odabrane grupe podataka sunčeva zračenja, brzina vjetra, potrošnje električne energije i vanjske temperature zraka za tri uzastopne godine, 2012., 2013. i 2014. godinu. Cilj analize jest ustanoviti linearnu vezu između potencijala OIE, potrošnje električne energije i vanjske temperature zraka za odabrano šire gradsko područje. Rezultati analiza mogu biti od pomoći u dugoročnom i kratkoročnom planiranju energetskog sustava odabrane regije, a i šire. Korelacijska veza sunčeva zračenja i brzine vjetra daje uvid u komplementarnost ova dva izvora energije i pruža dodatne korisne podatke kod planiranja budućih proizvodni kapaciteta u energetskom sustavu. Korelacijska veza između potencijala OIE i potrošnje električne energije također daje dobar uvid za sastavljanje energetskog plana. Ispitivanje korelacijske veze između vanjske temperature zraka, potencijala OIE i potrošnje električne energije također može biti od pomoći u planiranju energetskog sustava kao i u prognozama buduće proizvodnje i potrošnje električne energije. Ukoliko postoji dobra korelacijska veza vanjske temperature i potencijala OIE i potrošnje električne energije, ona se može koristiti kao parametar za predviđanje proizvodnje i potrošnje električne energije u sustavu. Rezultati korelacijske i

regresijske analize između pojedinih parametara zasebno, za uzastopne tri godine, dat će sliku o promjenama i odstupanjima u raspodjeli pojedinih podataka između odabranih godina.

Prethodne studije, navedene u odjeljku 1.2.3, bavile su se analizama korelacije i regresije podataka o potencijalu OIE i proizvodnji i potrošnji električne energije koje su se temeljile na satnom i mjesečnom vremenskom koraku. Međutim, analize koje se rade na kratkoročnom vremenskom koraku mogu pružiti vjerodostojnije rezultate. Studije su također pokazale da su rezultati korelacijskih analiza lošiji što se vremenski korak smanjuje. U ovom radu, uz dugoročni vremenski korak koji se temelji na srednjim vrijednostima mjesečnih podataka, analizirat će se korelacijska i regresijska veza za kratkoročni vremenski korak od 10 minuta. Rezultati tih analiza pružit će vjerodostojniju sliku o vezama među podacima. Oni mogu biti korisni za energetske sustave koji se planiraju i modeliraju za vremenski korak od 10 minuta, kao što je planiranje energetskog šireg gradskog područja. Također, mogu imati značajnu ulogu za buduće otvoreno tržište električnom energijom koje bi trgovalo na 10-minutnom vremenskom koraku.

Analiza linearne korelacije i regresije napravljena je za 4 grupe odabranih podataka:

1. korelacija i regresija između podataka za uzastopne tri godine za svaki od parametara zasebno za vremenski korak t = 10 min,
2. korelacija i regresija između parametara za tri uzastopne godine temeljena na srednjim mjesečnim vrijednostima,
3. korelacija i regresija između parametara za tri uzastopne godine temeljena na
    A. vremenskom koraku od t = 10 min,
    B. vremenskom koraku od t = 10 min uključujući odgodu u sustavu (*"system time delay"*) između proizvodnje i potrošnje električne energije, (potrošnja električne energije i temperatura zraka uzete su za vremenski korak t = 10 min, a sunčevo zračenje i brzina vjetra za vremenski korak $t_1 = t + 4$ h)
4. korelacija i regresija između parametara za tri uzastopne godine temeljena na 10 min vremenskom koraku za:
    A. zimski period
    B. ljetni period.

Ljetno razdoblje za svaku godinu odabrano je s obzirom na najveću temperaturu i najveće opterećenje potrošnjom električne energije za tri uzastopna mjeseca. Zimsko razdoblje za svaku godinu odabrano je s obzirom na najmanju temperaturu i najveće opterećenje električnom energijom za tri uzastopna mjeseca.

Analize se temelje na modelu jednostavne regresije i korelacije. Daju rezultate koeficijenata korelacije, koeficijenata determinacije i linearne regresijske linije između odabranih parametara. Izrađene u računalnom programu STATISTICA [166]. STATISTICA je opsežan alat za analitičku, istraživačku i poslovnu inteligenciju. To je integrirani sustav upravljanja podacima, analize, istraživanja, vizualizacije i prilagođenog razvoja aplikacija. Sadrži širok izbor osnovnih i naprednih analitičkih postupaka za poslovne, istraživačke, znanstvene i inženjerske primjene. STATISTICA uključuje ne samo analitičke, grafičke i postupke upravljanja bazama podataka opće namjene, već i sveobuhvatnu implementaciju specijaliziranih metoda za analizu podataka (npr. predviđeno istraživanje podataka (*"predictive data mining"*); poslovna, društvena i biomedicinska istraživanja; ili inženjerske primjene). Svi analitički alati ponuđeni u liniji softvera STATISTICA dostupni su kao dio integriranog paketa. Ovim se alatima može upravljati izborom alternativnih korisničkih sučelja, uključujući:

- visoko optimizirano interaktivno korisničko sučelje (s opcijama za upravljanjem STATISTICA-e unutar Microsoft Office-a i drugih aplikacija),
- cjelovito korisničko sučelje temeljeno na tankom klijentu i pregledniku (u STATISTICA Enterprise Server-u) koje omogućuje da se na poslužitelj prebace vremenski zahtjevni zadaci i rad u suradnji, i
- sveobuhvatno, industrijsko standardno programsko sučelje kompatibilno s .NET-om (uključujući ugrađeni Visual Basic kompatibilan s .NET-om), nudeći pristup više od 14000 funkcija koje se mogu pozivati izvana.

Ugrađeno razvojno okruženje može se koristiti za povezivanje STATISTICE s drugim aplikacijama i širokom poduzetnom infrastrukturom (*"enterprise-wide infrastructures"*). Koristi se za izgradnju prilagođenih proširenja bilo koje složenosti, od jednostavnih prečaca do naprednih, velikih razvojnih projekata [166]. Proračuni u STATISTICI, u ovom radu, temelje se na osnovnim formulama za linearnu korelaciju. [Slika 17] prikazuje dijagram toka koji predstavlja metodu korištenu u ovom radu. Jednadžba na slici predstavlja osnovnu jednadžbu linearne regresije dobivenu izračunom linearne korelacije gdje je:

$\widehat{y_i}$ – zavisna varijabla,

$\widehat{x_i}$ – nezavisna varijabla,

a – konstanta, očekivana vrijednost zavisne varijable kada je nezavisna varijabla nula, i

b – koeficijent regresije koji pokazuje prosječnu promjenu zavisne varijable uzrokovanu promjenom nezavisne varijable.

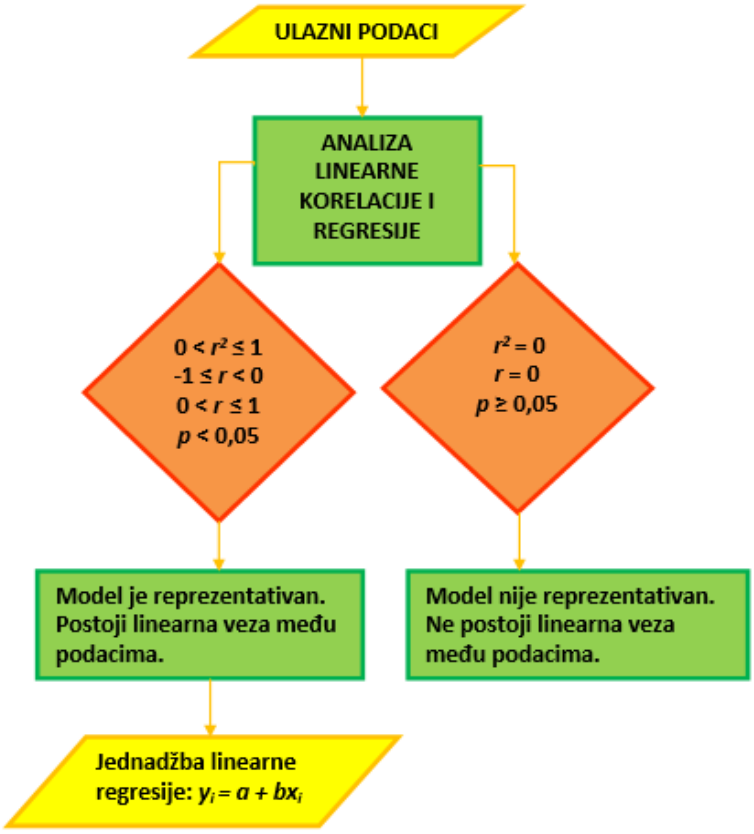

Slika 17. Dijagram toka za ispitivanje linearne i regresijske veze među podacima

Zavisna varijabla se može u drugom slučaju također promatrati kao nezavisna varijabla i vrijednosti *a* i *b* će biti drugačije za tu regresijsku liniju. Koeficijent determinacije, r^2, je ključni rezultat regresijske analize. Tumači se kao udio varijance u zavisnoj varijabli koji se može predvidjeti iz nezavisne varijable. Pearsonov koeficijent korelacije proizvoda-trenutka, *r*, predstavlja kvantitativnu mjeru neke vrste korelacije i ovisnosti. Označava statistički odnos između dvije ili više slučajnih varijabli ili promatranih vrijednosti podataka. Korelacija predstavlja sukladnost u variranju vrijednosti dvije ili više varijabli te označava povezanost između varijabli. Ona je pokazatelj zavisnosti (veze) među ispitivanim pojavama, a određena je smjerom i jačinom veze. Metoda korelacije prati odstupanja i uspoređuje varijacije dvaju ili više varijabli te mjeri odnose među varijacijama. Na osnovu same veličine korelacije ne može se zaključivati o uzročno-posljedičnom odnosu među varijablama. Koeficijent korelacije (r) pokazuje stupanj i smjer korelacije:

- $r < 0$ definira negativnu korelaciju
- $r = 0$ nema korelacije
- $r > 0$ definira pozitivnu korelaciju

Pozitivan smjer znači da porast jedne varijable prati porast druge varijable dok negativan smjer znači da porast jedne varijable prati pad druge varijable.

Postupak računanja korelacije:

$$r = \frac{SS_{xy}}{\sqrt{SS_{xx}SS_{yy}}} \tag{2}$$

$$SS_{xy} = \sum (x_i - \bar{x})(y_i - \bar{y}) \tag{3}$$

$$SS_{xx} = \sum (x_i - \bar{x})^2 \tag{4}$$

$$SS_{yy} = \sum (y_i - \bar{y})^2 \tag{5}$$

Koeficijent determinacije ($R = r^2$) je pokazatelj zajedničkih faktora, odnosno udjela kod dva obilježja uključena u korelacijsku analizu. Ovim koeficijentom se utvrđuje koliko je promjene zavisne varijable objašnjeno promjenom nezavisne varijable. O jačini veze nikako se ne može govoriti samo na temelju koeficijenta korelacije bez razmatranja koeficijenta determinacije. Regresijska analiza koristi se kada se želi istražiti mogućnost procjene vrijednosti jedne varijable na temelju poznate vrijednosti druge varijable. Regresijskom analizom utvrđuje se oblik krivulje koja najbolje opisuje zadane podatke. Krivulja se provlači tako da suma kvadrata odstupanja procijenjenih i originalnih vrijednosti bude minimalna. Regresijom se omogućuje promatranje očekivane vrijednosti zavisno promjenjive veličine na osnovu vrijednosti nezavisno promjenjive veličine. [Tablica 11] daje objašnjenje iznosa koeficijenta regresije i korelacije, a jednadžba (6) prikazuje regresijsku funkciju.

Tablica 11. Koeficijent regresije

R^2	**r**	**Objašnjenje**
0	0	Odsutnost veze
0,00 – 0,0,25	0,00 – 0,50	Slaba veza
0,25 – 0,64	0,50 – 0,80	Veza srednje jakosti
0,64 – 1	0,80 – 1	Čvrsta veza
1	1	Potpuna veza

$$Y = a + bX \tag{6}$$

Y – zavisna varijabla

X – nezavisna varijabla.

2.7.1 Ulazni podaci za statističke analize

Godišnje podatke sunčevog zračenja, brzine vjetra i temperature zraka ustupio je DHMZ RH za 2012., 2013. i 2014. godinu za vremenski korak od 10 minuta [167]. Mjerni podaci su dobiveni s mjerne postaje u Dubrovniku. Uređaj za mjerenje brzine vjetra je anemometar sa svojstvima hemisfere i točnosti od ±5% (5-75 m/s), s dometom od 0,5-75 m/s. Oprema za mjerenje sunčeva zračenja sastoji se od piranometra CMP21, jedinice za ventilaciju CVF4 za mjerenje globalnog zračenja i prsten sjene CM121 za mjerenje difuznog zračenja s detaljnim obilježjima opisanim u [168]. Temperatura zraka mjerena je s Campbell-Stoke heliografom i Lambrecht termografom. Heliograf mjeri zračenje veće od 0,838 J/cm^2 u minuti i u trenutku kada je Sunce tri stupnja iznad horizonta. Odstupanje mjerenja termometra iznosi oko 0,3 stupnja kod standardnih 10 stupnjeva Celzijusa. Podatke o potrošnji električne energije za odabrano područje ustupio je Elektrojug Dubrovnik – HEP ODS Ltd., operator distribucijskog sustava, za 2012., 2013. i 2014. godinu za vremenski korak od 15 minuta [169]. Linearnom interpolacijom 15-minutnih podataka su se dobili podaci za vremenski korak od 10 minuta.

Dijagrami na [Slika 18.] prikazuju godišnju raspodjelu srednjih mjesečnih vrijednosti odabranih parametara za tri odabrane godine, normalizirane na njihovu maksimalnu vrijednost. Sa A su označene krivulje u 2012. godini, sa B one u 2013. a sa C one u 2014. godini. Iz dijagrama se može zaključiti da potrošnja električne energije ovisi o temperaturi zraka. Tijekom ljetnog razdoblja, mjeseci lipanj, srpanj, kolovoz i rujan, potrošnja električne energije raste s porastom temperature zbog porasta potreba za hlađenjem. Tijekom zimskog razdoblja, mjeseci studeni, prosinac, siječanj i veljača, potrošnja električne energije se povećava sa smanjenjem temperature zraka zbog porasta potreba za grijanjem. Proizvodnja električne energije iz vjetra može se koristiti za opskrbu potreba za električnom energijom tijekom zimskog razdoblja zbog porasta vrijednosti brzina vjetra u tom razdoblju. S druge strane, proizvodnja električne energije iz Sunca može se koristiti za opskrbu potreba za električnom energijom tijekom ljetnog razdoblja kada je sunčevo zračenje visokih vrijednosti. Dijagrami na [Slika 18] ne prikazuju stvarnu situaciju odnosa krivulja zbog nedostatka mjernih podataka sunčeva zračenja, brzine vjetra i temperature zraka. Najveći nedostatka podataka je u ljetnom razdoblju u srpnju i kolovozu za sve odabrane godine. Zbog toga, primjerice, sunčevo zračenje ima svoj maksimum u svibnju i lipnju, a zapravo svoj maksimum dosegne u srpnju i kolovozu. Podaci u [Tablica 12] prikazuju maksimalne i minimalne srednje mjesečne vrijednosti za svaku godinu i za svaki od odabranih parametara.

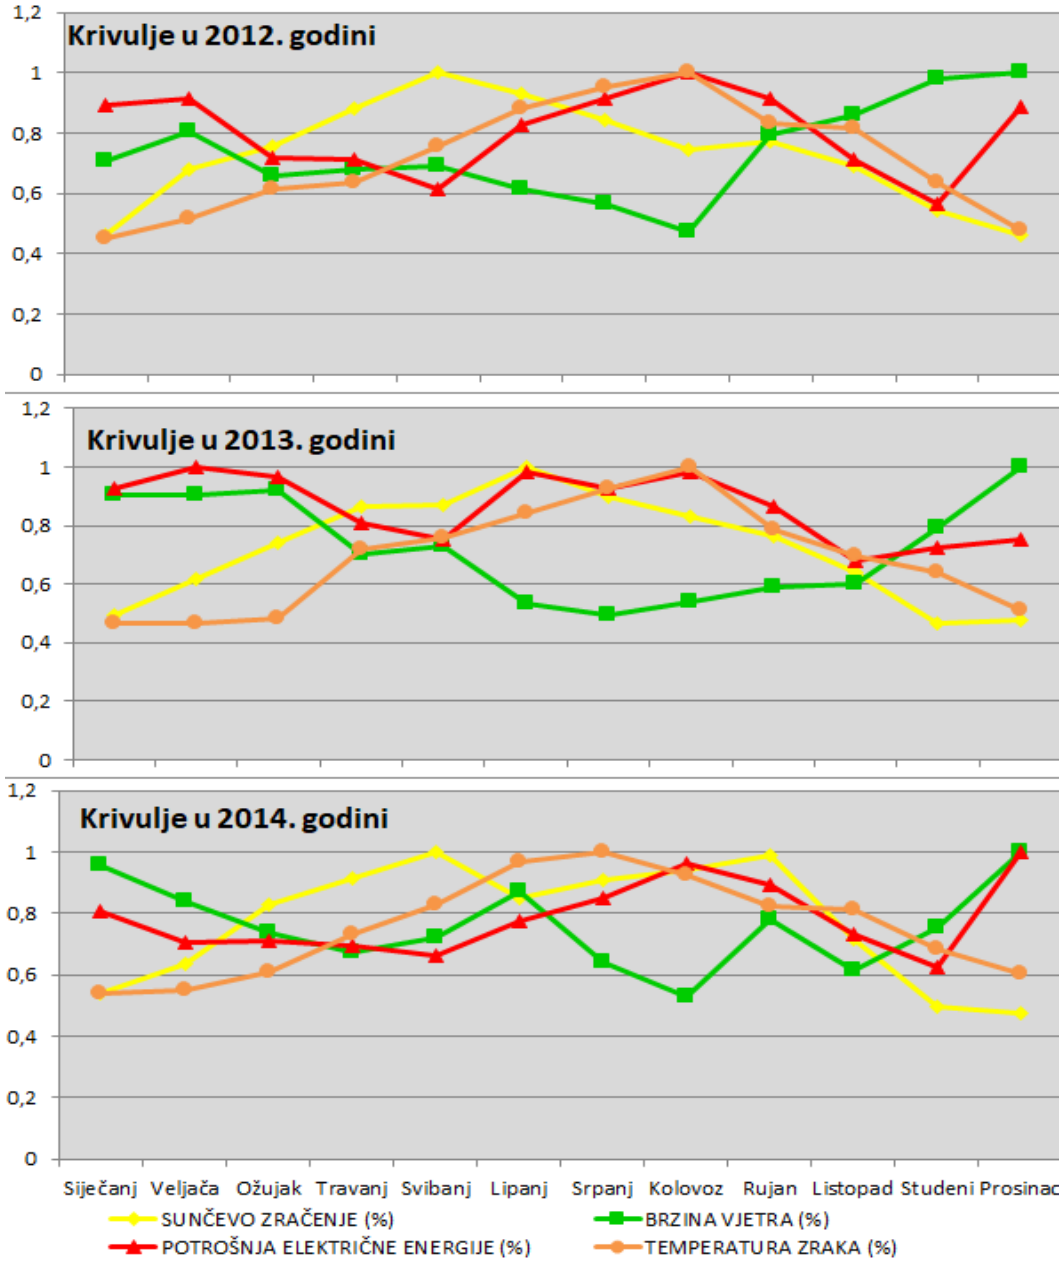

Slika 18. Godišnja raspodjela normaliziranih srednjih mjesečnih vrijednosti sunčeva zračenja, brzine vjetra, temperature zrak i potrošnje električne energije za odabrano šire gradsko područje.

Tablica 12. Godišnje maksimalne i minimalne vrijednosti analiziranih varijabli

	Potrošnja električne energije [kW]	**Temperatura zraka [°C]**	**Sunčevo zračenje [J/cm²]**	**Brzina vjetra [m/s]**
Max (2012)	48272,19	27,7	202,03	4,93
Min (2012)	28460,92	7,43	41,61	2,46
Max (2013)	39573,39	26,39	201,46	5,40
Min (2013)	24636,00	9,74	41,75	2,58
Max (2014)	36268,27	25,33	176,77	5,35
Min (2014)	23537,71	11,58	31,72	2,69

Osim srednjih mjesečnih vrijednosti, u radu su napravljene korelacijske i regresijske analize za 10-minutne vrijednosti. Sukladno tome priloženi su i sljedeći dijagrami na [Slika 19] i [Slika 20]. Oni prikazuju po jedan dan, 24 sata, u 10-minutnim vrijednostima odabrana četiri parametra, za ljetno i zimsko razdoblje za 2013. i 2014. godinu. Vrijednosti parametara su normalizirane na njihove maksimalne vrijednosti. Dani su odabrani na temelju maksimalnog opterećenja potrošnjom električne energije za te periode i to za 2013. (8.8.2013. i 11.2.2013.) i 2014. (14.8.2014. i 31.12.2014.).

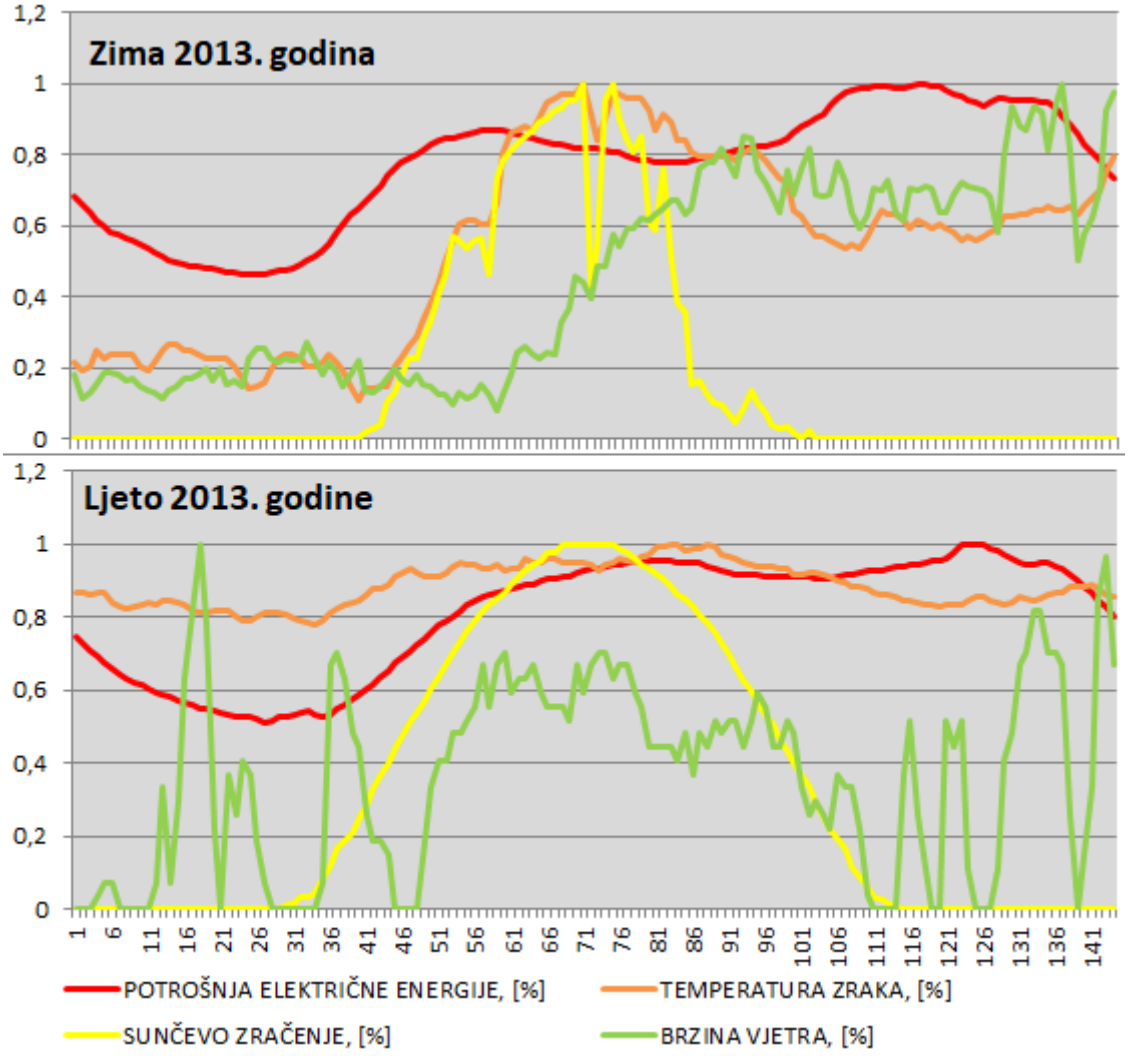

Slika 19. Dnevne 10-minutne normalizirane vrijednosti odabranih varijabli za jedan dan ljeta i zime u 2013. godini

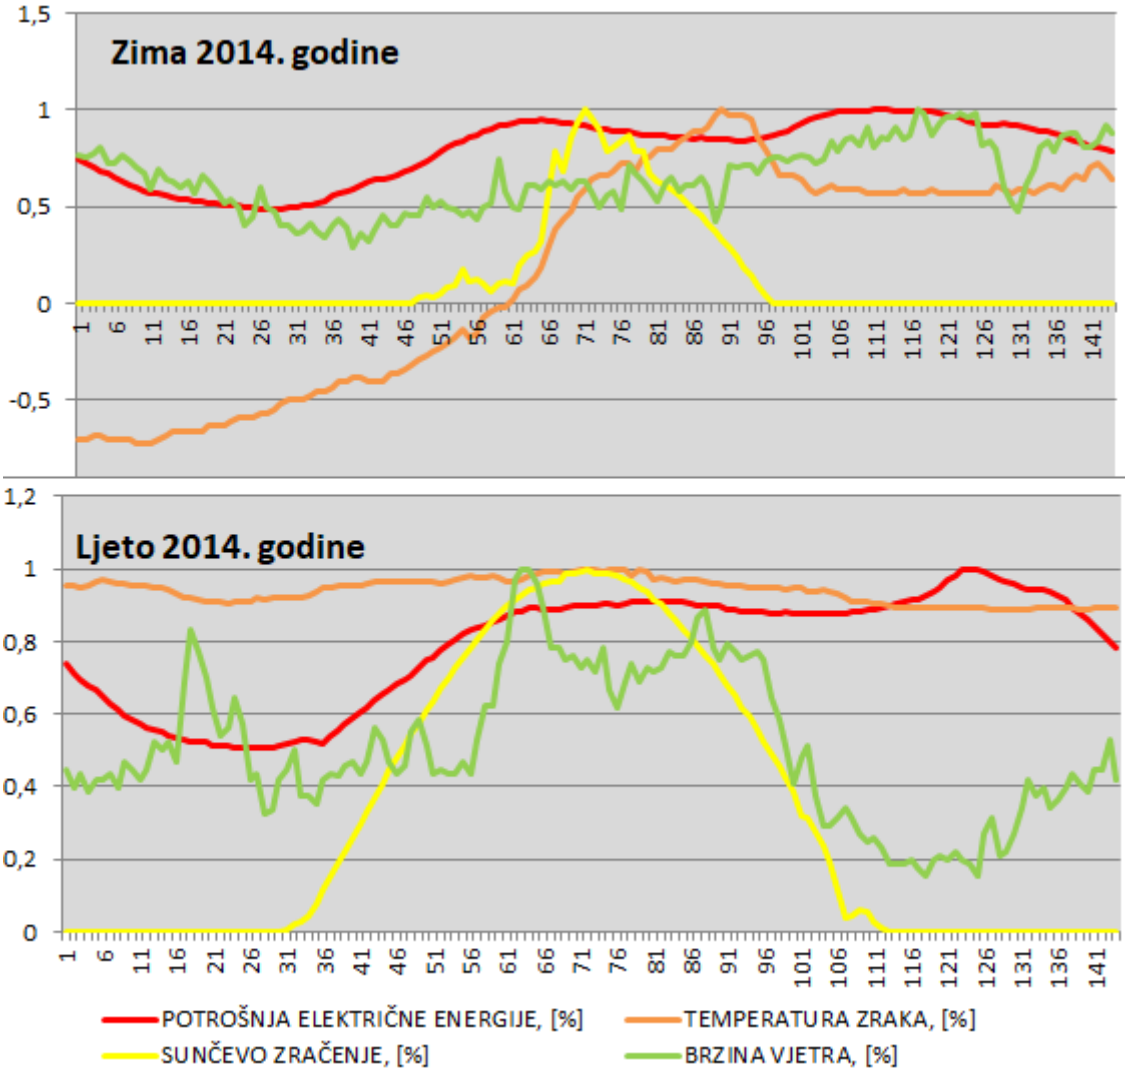

Slika 20. Dnevne 10-minutne normalizirane vrijednosti odabranih varijabli za jedan dan ljeta i zime u 2014. godini

Iz dijagrama se može uočiti da svi parametri, osim brzine vjetra, u pojedinom razdoblju imaju ponavljajući trend. Krivlja potrošnje električne energije ima jednak trend u oba razdoblja za obje godine. Ona zapravo više ovisi o navikama potrošača, dok se njen maksimum i minimum mijenjaju ovisno o vremenskim prilikama. Temperatura zraka ne varira puno u ljetnom razdoblju, dok u zimskom razdoblju prati sunčevo zračenje i to u 2014. s odmakom. S brzinom vjetra može se reći da ima negativnu korelaciju. Padom temperature zraka raste brzina vjetra i obratno. Sunčevo zračenje je prisutno samo danju i u ljetnom periodu ima ujednačen trend. Brzina vjetra nema jednak trend i nemoguće ju je predvidjeti dugoročnim prognozama kao ostale parametre. Vjetar može dobro negativno korelirati sa sunčevim zračenjem s obzirom da je učestaliji tokom noći.

2.8 Daljinsko grijanje i hlađenje sa sustavom DTMV za područje Starog grada Dubrovnika

U odjeljku 2.4.3 se dao pregled kapaciteta i potencijala za DGH na odabranom širem gradskom području. U svrhu ispitivanja DGH odabrana je jedna cjelina unutar šireg gradskog područja kako bi se napravila analiza sustava DTMV. Za ispitivanje je odabrano područje Starog grada Dubrovnika s obzirom da za to područje postoji prethodno izrađena studija za ugradnju daljinskog sustava DTMV [170]. Grad Dubrovnik je poznat kao turističko središte, smješten na jugu RH na obali Jadranskog mora. Čitav Stari grad Dubrovnik uvršten je u UNESCO-vu Svjetsku kulturnu baštinu od 1979. godine. Najveći dio potreba za grijanjem i hlađenjem pokriva se klimatizacijskim sustavima koji su rezultirali negativnim vizualnim utjecajem na fasadama zgrada. Iz tog razloga je Konzervatorski odjel grada Dubrovnika, u suradnji s Institutom Hrvoje Požar, započeo projekt s ciljem smanjenja ili potpunog uklanjanja svih vanjskih klimatizacijskih jedinica sa fasada zgrada u Starom gradu. U tu je svrhu Institut Hrvoje Požar izradio studiju [170]. Kao optimalno rješenje problema predložio je ugradnju sustav DTMV u zamjenu za klimatizacijske sustave. Daljinski sustav DTMV pokrivao bi potrebe za grijanjem i hlađenjem na području Starog grada. Time bi se riješio negativan vizualni utjecaj vanjskih klimatizacijskih jedinica na fasadama zgrada.

Od ostalih vrsta OIE, za pokrivanje potreba za grijanjem i hlađenjem, kao što su FN sustavi i solarni kolektori (SK), su za područje Starog grada zabranjeni s obzirom da Stari grad pripada UNESCO-voj Svjetskoj kulturnoj baštini. Sličan problem koji ima Stari grad ima i Venecija. U radu [171] je napravljena analiza DT spojene na vodu u laguni koja je instalirana tijekom rekonstrukcije na samostanu Crucifera, povijesnoj zgradi u Veneciji. Rezultati su pokazali značajno veću uštedu na potrošnji energije od potrebnih 20% i posljedično smanjenje emisije stakleničkih plinova u odnosu na tradicionalno postrojenje. Sustav DTMV analiziran je i za važnu luku na sjeveroistoku Kine, Dalian. Smještena je na obali Žutog mora s primorskom klimom i industrijski je, trgovački i turistički grad, sličan Dubrovniku. Rezultati studije [172] pokazali su potencijal povećanja energetske učinkovitosti jedinica DT, dok je ulaganje u sustav DTMV općenito isplativo [107].

U ovom poglavlju dan je pregled metoda i podataka korištenih za ispitivanje potencijala daljinskog sustava DTMV za grijanje i hlađenje, kao i za iskorištavanje proizvodnje električne energije iz OIE baziran na satnom i 10-minutnom vremenskom koraku. Ispitane su potrebe sustava DTMV za skladištenjem električne energije i napravljena je usporedba TES i BES. Za analize su odabrana tri scenarija:

- Scenarij 1: DTMV i proizvodnja električne energije iz OIE, proračun za vremenski korak od 1 sata i 10 minuta,
- Scenarij 2: DTMV + BES i proizvodnja električne energije iz OIE, proračun za vremenski korak od 1 sata,
- Scenarij 3: DTMV + TES i proizvodnja električne energije iz OIE, proračun za vremenski korak od 1 sata.

Scenarij 1 se sastojao od samostojećeg sustava DTMV. Druga dva scenarija su uključivala DTMV u kombinaciji s BES i TES i proračuni su rađeni na satnoj bazi. [Slika 21] prikazuje model odabranih scenarija. Isprekidana linija predstavlja model scenarija 1, zelena linija je za scenarij 2 a narančasta linija za scenarij 3.

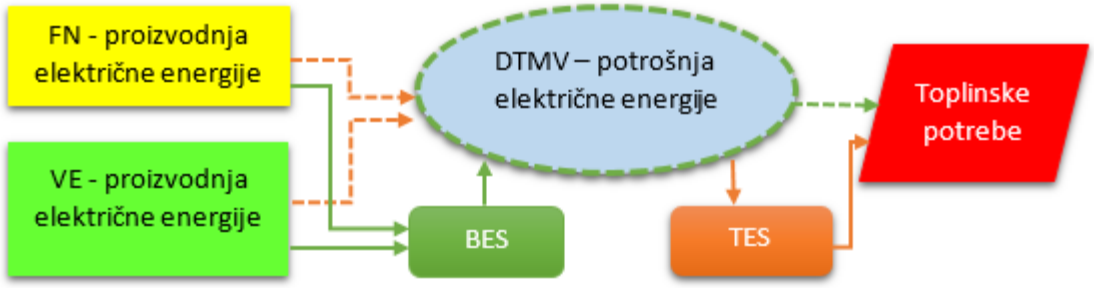

Slika 21. Model scenarija za sustav DTMV

U radu su analizirana i tri različita slučaja za svaki scenarij. Slučajevi se razlikuju prema vrsti OIE u proizvodnji električne energije:

- SLUČAJ A – proizvodnja električne energije iz FN
- SLUČAJ B – proizvodnja električne energije iz VE
- SLUČAJ C – proizvodnja električne energije iz OIE (FN + VE)

2.8.1 Sustav DTMV u Starom gradu Dubrovniku

Ulazni podaci za sustav DTMV u Starom gradu u ovom radu preuzeti su iz studije koju je izradio Institut Hrvoje Požar [170]. Trenutna situacija pokazuje da klimatizacijski uređaji pokrivaju većinu toplinskog opterećenja i u potpunosti rashladno opterećenje u Starom gradu. Potrošnja toplinske i rashladne energije se u studiji [170] računala prema normi HRN EN ISO 13790. U studiji nije u obzir uzeta PTV, samo grijanje i hlađenje prostora. Prema proračunima iz studije procijenjeno je da bi ukupni instalirani kapacitet DTMV za područje Staroga grada iznosio 11 MW. Najbolji izbor za odabrano područje bila bi dvostupanjska DT koja kao radnu tvar koristi R134a. Karakteristike DTMV preuzete su iz studije pa je uzeta u obzir radna tvar R134a, iako je njeno korištenje sada zabranjeno. Optimalno rješenje bi bilo postaviti veći broj pravilno raspoređenih jedinica, tako da pojedini agregati budu manje snage. Time bi se postigla

veća fleksibilnost sustava, pravilnija distribucija medija potrošačima i manji promjer polaznih (magistralnih) cjevovoda. Zahvat morske vode bi trebao biti na dubinama ispod 15 m. Termodinamičke veličine DTMV u Starom gradu Dubrovniku prikazane su u [Tablica 13]. [Slika 22] prikazuje shemu ogrjevnog procesa sa DTMV.

Tablica 13. Termodinamičke veličine DTMV u Starom gradu

Termodinamičke veličine	Iznos
Temperatura mora – period grijanja	13,5 °C
Temperatura mora – period hlađenja	16 °C
Temperatura isparavanja – period grijanja	7 °C
Temperatura isparavanja – period hlađenja	3 °C
Temperatura kondenzacija – period grijanja	80 °C
Temperatura kondenzacija – period hlađenja	22 °C
Temperatura polaza nosioca energije – period grijanja	75 °C
Temperatura polaza nosioca energije – period hlađenja	7 °C

Satne vrijednosti faktora grijanja COP izračunate su prema normi EN 15316-4-2:2017 sa SCOP i prikazane su u [Tablica 14]. Vrijednosti sezonskog faktora hlađenja SEER odabrane su prema dostupnim vrijednostima efikasnosti DTMV. Njih je ustupio proizvođač za režim hlađenja, jer satne vrijednosti SEER nije bilo moguće izračunati. Vrijednosti koje je ustupio proizvođač su vrijednosti s Eurovent certifikatom, a koje su u skladu s normom EN14511-3:2013.

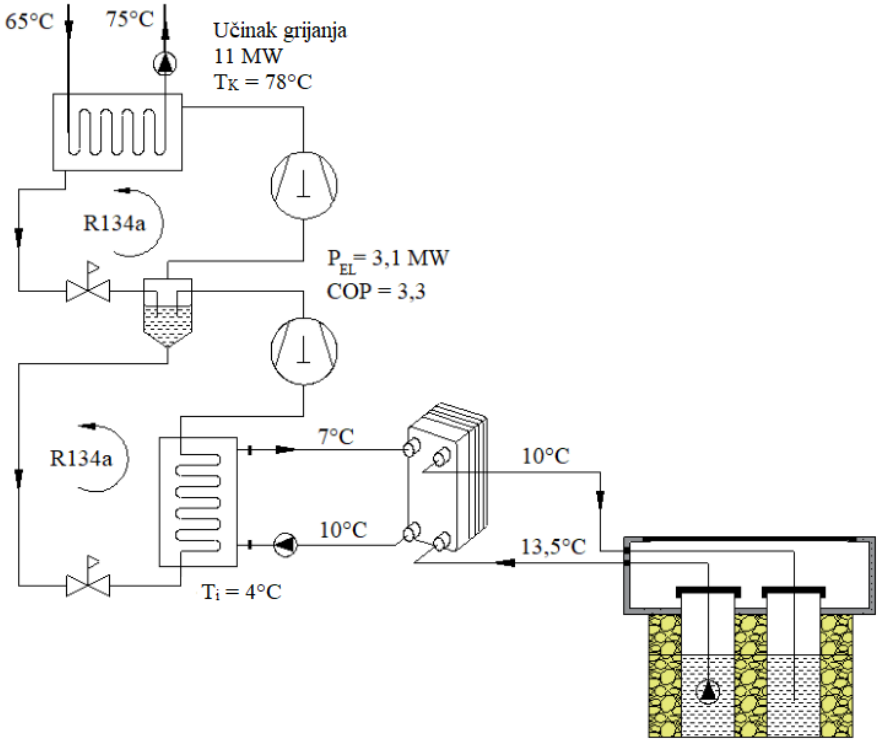

Slika 22. Shema procesa grijanja DTMV

Proračuni za analizu sustava DTMV izrađeni su na satnoj i 10-minutnoj bazi podataka. Sezona hlađenja uzeta je za period od 1. svibnja do 1. listopada, dok je ostatak godine uzet kao period grijanja. Tijekom sezone grijanja DT radi u vrijeme kada je vanjska temperatura zraka manja od 15 °C. Toplinske potrebe za grijanjem za satni i 10-minutni vremenski korak, *STP*, izračunate su prema jednadžbama (7) i (8) kako bi se dobila satna i 10-minutna godišnja raspodjela toplinskih potreba:

$$STP_i = \left(\frac{THP}{\sum_i^{8760} DD_i}\right) \cdot DD_i \tag{7}$$

$$DD_i = T_{P,i} - T_{V,i} \tag{8}$$

DD označava stupanj sat ili 10 minuta, gdje indeks *i* označava vremenski korak od 1 sat ili 10 minuta. Računa se prema jednadžbi (8), kao razlika unutarnje T_P i vanjske temperature T_V za vremenski korak od 1 sat ili 10 minuta. T_P je postavljena na 22 °C tijekom sezone grijanja a tijekom sezone hlađenja na 20 °C. Podatke o 10-minutnim vrijednostima T_V ustupio je DHMZ. Satne vrijednosti dobivene su osrednjavanjem 10-minutnih vrijednosti unutar svakog sata. Satna i 10-minutna raspodjela *DD* i ukupne toplinske potrebe za grijanjem i hlađenjem, *THP*, dane su u [Tablica 14]. Korištene su za izračun raspodjele toplinskih i rashladnih potreba za satni i 10-minutni vremenski korak, *STP*, korištenjem jednadžbe (7). Kod vremenskog koraka od 1 sata raspodjela je sadržavala 8760 podataka, dok je kod 10-minutne raspodjele sadržavala 52560 podataka.

Tablica 14. Ulazni podaci

Toplinske potrebe za grijanje	MWh/god.	10179
Toplinske potrebe za hlađenje	MWh/ god.	8107
SCOP	-	3.3
SEER	-	6.3
Potrošnja električne energije za grijanje	MWh/ god.	3089.18
Potrošnja električne energije za hlađenje	MWh/ god.	1286.83
Instalirani kapacitet PV sustava	MW	18
Instalirani kapacitet VE sustava	MW	160

Proizvodnja električne energije iz Sunca i vjetra računala se koristeći podatke sunčeva zračenja i brzine vjetra koje je ustupio DHMZ, a koje su preuzete za vremenski korak od 10 minuta. Osrednjavanjem tih vrijednosti za svaki sat dobili su se i satni podaci. Meteorološki mjerni podaci uzeti su za 2014. godinu. S obzirom da su neki od podataka nedostajali za 2014. godinu, oni su kombinirani s podacima iz 2013. kako bi se dobila kompletna krivulja. Proizvodnja električne energije iz OIE dobivena je prema radu [2] za dubrovačko područje.

Instalirani proizvodni kapaciteti određeni su u energetskom planu za 2030. godinu za dubrovačko područje, preuzeti iz [2] i prikazani u [Tablica 14]. U [Tablica 15] prikazane su srednje mjesečne vrijednosti brzine vjetra i sunčeva zračenja.

Tablica 15. Srednje mjesečne vrijednosti brzine vjetra i sunčeva zračenja za Dubrovačku regiju za 2014. godinu

2014.	**Siječanj**	**Veljača**	**Ožujak**	**Travanj**	**Svibanj**	**Lipanj**
Brzina vjetra, [m/s]	5,28	5,42	4,00	3,52	3,03	3,32
Sunčevo zračenje, [Wh/m^2]	133,12	194,55	360,72	324,83	420,60	511,35
2014.	**Srpanj**	**Kolovoz**	**Rujan**	**Listopad**	**Studeni**	**Prosinac**
Brzina vjetra, [m/s]	2,98	2,79	3,07	3,24	4,71	5,03
Sunčevo zračenje, [Wh/m^2]	482,41	544,62	369,06	273,55	199,13	165,27

Scenarij 2 i 3 u svom modelu uključuju ES pa su jednadžbe (9), (10) i (11) određene na način da definiraju potrebe za ES u slučaju BES i TES na satnoj bazi:

$$E_{ES,i} = E_{ES,i-1} - E_{SWHP,i} + E_{RES,i} \tag{9}$$

$$0 \leq E_{ES,i} \leq E_{ES,max} \tag{10}$$

$$E_{SWHP,i} \geq 0 \tag{11}$$

Uskladištena energija u svakom satu, $E_{ES,i}$, računala se prema jednadžbi (9). Ona uzima u obzir uskladištenu energiju iz prethodnog sata, $E_{ES,i-1}$, potrošnju električne energije za rad DTMV, $E_{SWHP,i}$, i proizvodnju električne energije iz OIE, $E_{RES,i}$. U obzir su uzeta i određena ograničenja za $E_{ES,i}$ i $E_{SWHP,i}$. $E_{ES,i}$ je ograničena na svoj maksimalni kapacitet, kako je to pokazano jednadžbom (10). U proračunu je uzeto u obzir da se potrebe za toplinskom energijom snabdijevaju samo korištenjem električne energije proizvedene iz OIE, direktno radom DTMV ili korištenjem energije pohranjene u ES. Taj uvjet je osiguran jednadžbom (11). Efikasnost punjenja i pražnjenja BES i TES nije uzet u obzir u proračunima u ovoj analizi, pa dobiveni rezultati mogu odstupati od realnih očekivanja. BES pohranjuje električnu energiju koja se koristi za snabdijevanje potreba DTMV za električnom energijom u periodu kada postoji manjak proizvodnje električne energije iz OIE. DTMV tu energiju koristi za proizvodnju toplinske energije za zadane potrebe. TES pohranjuje toplinsku energiju za snabdijevanje potreba za toplinskom energijom u period manjka proizvodnje električne energije iz OIE. TES se puni radom DTMV, pa je razlika između toplinskog kapaciteta TES i električnog kapaciteta BES prikazana preko SCOP i SEER odabrane DTMV.

U radu se izračunao kapacitet BES i TES potreban da zadovolji ukupne godišnje toplinske potrebe u vrijeme manjka proizvodnje električne energije iz OIE. Proračun je izrađen

na temelju tehničkih i financijskih karakteristika BES i TES koje prikazuje [Tablica 16]. Izračunat je i nivelirani trošak topline (LCOH - *"levelised cost of heat"*) za slučaj C, kako bi se napravila usporedba troškova za BES i TES. Diskontna stopa uzeta je 5% a životni vijek 20 godina.

Tablica 16. Financijske i tehničke karakteristike TES i BES

	TES	**BES**
Investicijski trošak	200 EUR/m^3	200 EUR/kWh_{el}
Kapacitet	80 kWh/m^3	500 kWh/m^3

2.9 Energetski plan do 2050. godine

Energetski plan za odabrano šire gradsko područje Dubrovnika uključuje planiranje 100% udjela obnovljive proizvodnje električne energije do 2050. godine, planiranje potrošnje električne energije i skladišta energije uz zamjenu svih KV s EV. U sljedećim poglavljima je detaljno opisan energetski plan do 2050. godine, s osvrtom i na 2030. godinu.

2.9.1 Planirana proizvodnja električne energije do 2030. i 2050. godine

Za izradu energetskog plana odabranog šireg gradskog područja potrebno je bilo odrediti planirane proizvodne kapacitet električne energije iz OIE do 2050. Određeno je, za odabrano područje, da će proizvodnja iz električne energije biti iz OIE u koje spadaju HE, VE i SE. SE odnose se na elektrane na odabranim lokacijama na tlu i FN sustave na objektima.

2.9.1.1 Planirana snaga instaliranih SE za 2030. i 2050. godinu

Integracija proizvodnje električne energije iz SE za odabrano područje planirana je iz FN sustava na građevinama i iz SE na tlu na odabranim lokacijama, a koje ulaze u granice odabranog energetskog sustava šireg gradskog područja. Od SE na tlu u obzir je uzeto pet lokacija koje su predviđene Planom korištenja OIE za područje Dubrovačko-neretvanske županije [36] One spadaju unutar granica odabranog sustava i prikazane su u [Tablica 3]. U ovom radu predviđa se da će lokacija A17 i A18 biti u funkciji 2030. godine, dok se ostale četiri lokacije predviđaju za 2050. godinu. Potrebno je odrediti instaliranu snagu SE na odabranim lokacijama odabirom vrste FN modula za proizvodnju električne energije iz sunčeva zračenja i određivanjem površine koju bi sustavi zauzimali na tlu. Karakteristike odabrane vrste FN modula opisane su u [Tablica 17] a preuzete su od tvrtke SOLVIS d.o.o. [173], [174].

Tablica 17. Karakteristike odabranog FN modula

Vrsta FN modula	**Model**	**Vršna snaga, [W]**	**Učinkovitost, [%]**	**Dimenzije (V x Š x D), [mm]**
Monokristalni	SV72 E	390	19,69	1981 x 1000 x 40

Prema dostupnoj literaturi, u radu [175] se navodi da instalirana snaga SE na tlu može dosta varirati, a kreće se od 10 do 120 W_e/m^2. To ovisi o uvjetima odabrane lokacije i hoće li planirana SE biti u kombinaciji s drugim vrstama elektrana ili u kombinaciji s poljoprivrednim lokacijama koje onda utječu na smanjenje instaliranih kapaciteta SE. Primjerice, u literaturi [176] se navodi da se, u kombinaciji FN modula s poljoprivrednim zemljištem, njihova instalirana snaga kreće od 25 do 60 W_p/m^2. U radu [177] se u obzir uzima pokrivenost površine tla FN modulima u iznosu od 40 do 50% bez da se u obzir uzima kombinacija s poljoprivrednim zemljištem ili drugom vrstom elektrana. Vodeći se dostupnom literaturom, u ovom radu je odabrano da SE neće biti u kombinaciji sa poljoprivrednim zemljištem i drugim elektranama te da će zauzimati 50% raspoloživog tla. Uzimajući u obzir karakteristike FN modula iz [Tablica 17] i poznate površine odabranih lokacija iz [Tablica 3], dobivena je instalirana snaga SE na tlu za 2030. i 2050. godinu i prikazana je u [Tablica 19]. Podaci ukazuju na instaliranu snagu od 1 MW/ha, odnosno 100 W/m^2, ukoliko se uzme da FN sustavi zauzimaju 50% površine tla. U Planu za dubrovačko područje [36] navodi se instalirana snaga od 1 MW na 2,5 ha. Međutim, ovdje se radi o budućem energetskom planiranju i treba uzeti u obzir da će tehnologija napredovati, a time i instalirana snaga sustava rasti.

U radu je određeno da će dio sunčeve energije biti iskorišten putem FN sustava na građevinama unutar granica odabranog sustava šireg gradskog područja. Za određivanje potencijala FN sustava na građevinama korišteni su podaci o trenutnom i predviđenom tehničkom potencijalu za te sustave iz Zelene knjige (ZK) [178], kao i podaci o broju stanovnika i o predviđanjima broja stanovnika do 2050. godine, također iz ZK [178], Državnog zavoda za statistiku (DZS) [179] i Hotmapsa [155]. Podaci o tehničkom potencijalu za 2017. i 2050. preuzeti su iz ZK [178] i dani u [Tablica 18]. Kako bi se odredio broj instaliranih FN sustava na odabranom širem gradskom području, potrebno je bilo odrediti tehnički potencijal na broj stanovnika. S obzirom da u ZK nisu dani podaci o broju stanovnika iz 2017., onda se broj stanovnika iz 2011. usporedio za sva tri izvora podataka, kako je i prikazano u [Tablica 18]. Prema broju stanovnika iz 2017., predviđanjima za 2050. i tehničkog potencijala za FN sustave u RH, dobio se broj od 360 W/st. u 2017. i 800 W/st. u 2050. godini, koji se koristio i za DNŽ i odabrano šire gradsko područje. Iz [Tablica 18] se vidi da se predviđanja o broju stanovnika za DNŽ iz Hotmapsa ne slažu s predviđanjima iz ZK, za koju je uzeta varijanta 3 – visoka. Podaci o broju stanovnika odabranog područja poznati su samo iz Hotmapsa, određivanjem granica tog sustava. Stoga se odredio udio broja stanovnika odabranog područja u ukupnom broj stanovnika DNŽ, koji prema Hotmapsu iznosi 48,2%. Taj udio se onda koristio za izračunavanje tehničkog potencijala na odabranom području s obzirom na izračunati

tehnički potencijal DNŽ, prema podacima dobivenim iz ZK. Izračunom je dobiven tehnički potencijal od 21 MW za 2017. godinu, odnosno 41 MW za 2050. godinu. Istaknuti podaci u [Tablica 18] su izračunati podaci, dok su ostali dobiveni iz odgovarajuće literature. U radu je određeno da će u 2030. biti iskorišten tehnički potencijal iz 2017. godine za odabrano područje. U 2050. godini sve će građevine bit prekrivene FN sustavima, odnosno bit će iskorišten cjelokupni potencijal tog odabranog područja. Konačno određena instalirana snaga FN sustava na građevinama i tlu za 2030. i 2050. dana je u [Tablica 19].

Tablica 18. Podaci korišteni za određivanje instalirane snage FN sustava na građevinama za 2030. i 2050. godinu

PODRUČJE	**RH (ZK)**	**DNŽ (ZK)**	**RH (DZS)**	**DNŽ (DZS)**	**DNŽ (Hotmaps)**	**Šire gradsko područje Dubrovnika (Hotmaps)**
Broj stanovnika 2011.	4285000	122568	4284889	122568	123067	59422
Broj stanovnika 2017.	-	-	4124531	121381	122070	58800
Tehnički potencijal FN, [MW] 2017.	1485	**44**	-	-		**21**
Tehnički potencijal FN, [W/st.] 2017.	**360**	**360**	-	-		**360**
Broj stanovnika 2050.	3362000 (2051.)	107313 (2051.)	-	-	120230	57910
Tehnički potencijal FN, [MW] 2050.	2700	**86**	-	-		**41**
Tehnički potencijal FN, [W/st.] 2050.	**800**	**800**	-	-		**800**

Tablica 19. Instalirana snaga SE i FN sustava za proizvodnju električne energije na odabranom području za 2030. i 2050. godinu

Energetski plan	**SE na tlu, [MW]**	**FN sustavi na građevinama, [MW]**	**Ukupna instalirana snaga, [MW]**	**Ukupna godišnja proizvodnja električne energije, [GWh/god.]**
2030.	19	21	40	63,176
2050.	43	41	84	132,67

2.9.1.2 Planirana snaga instaliranih VE za 2030. i 2050. godinu

Instalirani kapaciteti VE na odabranom širem gradskom području određeni su za energetski plan za 2030. i 2050. godinu prema prijedlozima Plana za dubrovačko područje u [36]. Tako je za 2030. godinu planirana proizvodnja električne energije iz VE Mravinjac, za koju su već do sada ishođene neke od dozvola za izgradnju. U 2050. u radu se planira i proizvodnje električne energije iz VE Konavoska brda, koja je također predviđena Planom [36]. Proizvodnja energije iz vjetra za 10-minutne i satne podatke o brzini vjetra računala se za odabrani tip vjetroturbine Vestas V90 s visinom stupa od 80 m i instalirane snage od 2 MW.

Dobivena krivulja proizvodnje električne energije iz vjetra, za vremenski korak od 10 minuta i 1 sat, korištena je u proračunima za izradu energetskog plana za 2030. i 2050. godinu u 10-minutnom i satnom modelu. Instalirani kapaciteti VE za energetski plan za 2030. i 2050. godinu, kao i njihova ukupna godišnja proizvodnja električne energije prikazani su u [Tablica 20].

Tablica 20. Instalirana snaga VE za proizvodnju električne energije na odabranom području za 2030. i 2050. godinu

Energetski plan	Instalirana snaga VE, [MW]	Ukupna godišnja proizvodnja električne energije, [GWh/god.]
2030.	87	75,47
2050.	219	189,97

2.9.1.3 Planirana snaga instaliranih HE za 2030. i 2050. godinu

U energetskom planu za 2030. i 2050. godine za šire gradsko područje za proizvodnju električne energije iz HE određeno je da će ta proizvodnja biti iz već postojeće HE Dubrovnik. Ostale spomenute HE u radu nisu uzete u obzir u proračunima zbog niskog instaliranog kapaciteta istih. U proračunima u Excelu bila je potrebna godišnja krivulja proizvodnje električne energije iz HE Dubrovnik koju je ustupila HE Dubrovnik za 2014. godinu. Podaci o proizvodnji električne energije iz HE Dubrovnik dobiveni su za svaki sat u godini. 10-minutni podaci su dobiveni iz satne krivulje, gdje je podatak za jedan sat bio jednak i za sve 10-minutne podatke unutar tog sata. U 2014. godini HE Dubrovnik je radila sa smanjenim kapacitetom od 108 MW vršne snage. Ta je proizvodnja skalirana prema novoj instaliranoj snazi od 126 MW, koja je 2015. godine dobivena revitalizacijom HE. U ostalim proračunima i scenarijima, koji su se izvodili u programu Calliope, u obzir je također uzeta instalirana snaga od 126 MW. Podaci o instaliranoj snazi i proizvodnji električne energije iz HE prikazani su u [Tablica 21].

Tablica 21. Instalirana snaga HE za proizvodnju električne energije na odabranom području za 2030. i 2050. godinu

Energetski plan	Instalirana snaga HE, [MW]	Ukupna godišnja proizvodnja električne energije, [GWh/god.]
2030. i 2050.	126	893,74

2.9.2 Planirana potrošnja i skladištenje električne energije do 2030. i 2050. godine

Potrošnja električne energije na odabranom području sastoji se od opće potrošnje električne energije, potrošnje i potreba za toplinskom i rashladnom energijom i potrošnje električne energije za punjenje EV. S obzirom da sustav u 2050. godini ima 100% OIE u

proizvodnji električne energije, on zahtjeva i dodatna skladišta energije. Od skladišta energije odabrana su mobilna skladišta BEV i stacionarni spremnici B2U, SEV sustavi i TES i RES. Planirana potrošnja električne energije i skladišta energije opisana su u sljedećim poglavljima.

2.9.2.1 Opća potrošnja električne energije iz mjernih podataka s TS Komolac

Na temelju referentnog scenarija i poznatih podataka o potrošnji električne energije za Hrvatsku do 2050. godine, izračunata je potrošnja električne energije za odabrano šire gradsko područje Dubrovnika do 2050. godine. Ovakva gruba procjena potrošnje električne energije je uzeta zbog jednostavnosti proračuna. Rad nije bavio detaljnom analizom potreba potrošnje svakog sektora na temelju kojih bi se razvili vjerodostojniji podaci za proračun budućih scenarija. Za lokalnu procjenu treba ipak detaljnije razraditi potrebe svakog sektora za električnom energijom kao i moguće uštede, utjecaje raznih politika i strategija.

Podaci o potrošnji električne energije za Hrvatsku preuzeti su iz studije koja je obrađena za Hrvatsku [163]. Uzevši u obzir postotak povećanja potrošnje električne energije od 2014. do 2050. godine za Hrvatsku i poznati podatak o potrošnji električne energije za odabrano područje za 2014. godinu, izračunate su vrijednosti potrošnje električne energije za šire gradsko područje za 2030. i 2050. godinu, [Tablica 22].

Tablica 22. Potrošnja električne energije za Hrvatsku i Dubrovnik do 2050. godine

GODINA	**2014.**	**2020.**	**2030.**	**2050.**
Potrošnja električne energije u Hrvatskoj, [TWh/god.]	16,33	18,19	21,43	24,93
Postotak povećanja potrošnje, [%]	11,41	17,79		16,33
Potrošnja električne energije šireg gradskog područja, [TWh/god.]	0,249	0,346	0,408	0,474

Radi jednostavnosti proračuna u obzir je uzeto da će krivulja potrošnje električne energije za scenarije do 2050. pratiti jednaki trend koji se temelji na baznoj 2014. godini, jer se pretpostavlja da će navike ljudi ostati slične. [Slika 23] prikazuje satnu krivulju potrošnje električne energije za odabrano područje za treću srijedu u mjesecu siječnju u 2014. godini. Iz dijagrama se vidi da je povećana potrošnja energije tijekom dana, u jutarnjim, te kasnijim popodnevnim i večernjim satima te prati navike ljudi.

Pretpostavka je da će se potrošnja električne energije povećavati do 2050. godine zbog povećanja potreba za električnom energijom. Na temelju izračunatih vrijednosti i određenih pretpostavki dobivene su satne krivulje potrošnje za 2020., 2030. i 2050. godinu i prikazane na [Slika 24].

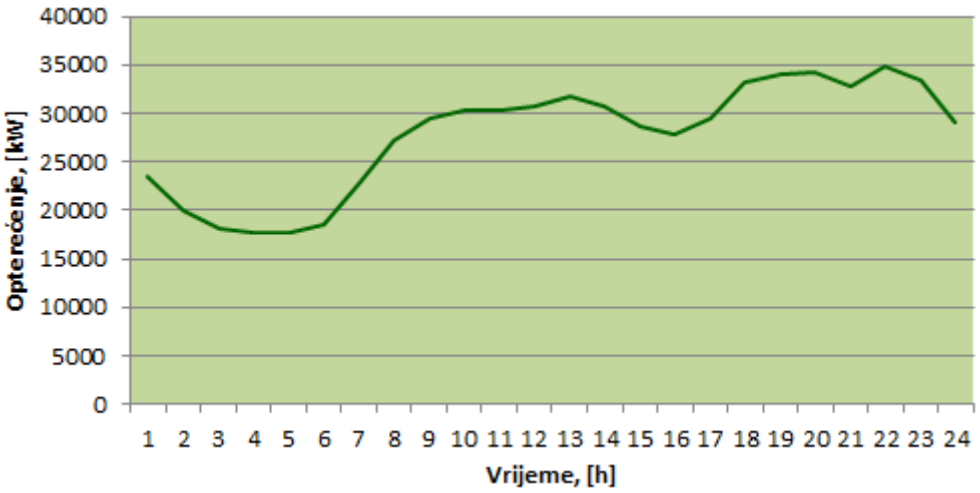

Slika 23. Potrošnja električne energije za odabrano šire gradsko područje, prva srijeda u mjesecu siječnju u 2014. godini

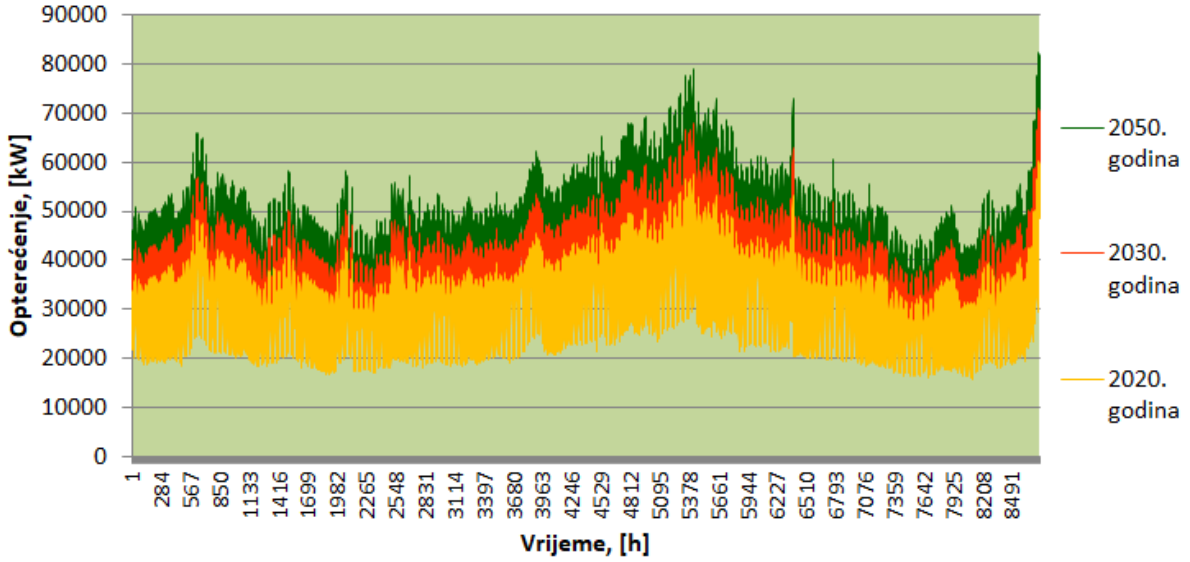

Slika 24. Satne krivulje potrošnje električne energije za 2020., 2030. i 2050. godinu

2.9.2.2 *Planirana potrošnja toplinske i rashladne energije za grijanje i hlađenje do 2030. i 2050. godine*

U poglavlju 2.4.3 napravljena je analiza potrošnje energije za grijanje i hlađenje za odabrano šire gradsko područje. Podaci o potrebnoj toplinskoj i rashladnoj energiji dobiveni su pomoću Hotmapsa za 2014. godinu. Predviđanja potrošnje za 2030. i 2050. godinu također su dobivena korištenjem Hotmapsa, u kojem se mogu dobiti podaci o predviđenoj potrošnji toplinske energije za grijanje prostora i PTV. S obzirom na poznate podatke o potrošnji rashladne energije u 2014. godini i kretanje potrošnje toplinske energije do 2050. godine, dobio

se podatak i o potrošnji rashladne energije za odabrano područje. Podaci su prikazani u [Tablica 23]. Podaci ukazuju na smanjenje potrošnje toplinske energije do 2050. godine. Podaci su dobiveni iz projekcija Hotmapsa koji ujedno predviđa i pad stanovnika. Stoga je potrošnja toplinske energije, prema Hotmapsu, uvjetovana kretanjem stanovništva do 2050. U obzir je uzeto da i toplinske i rashladne potrebe opadaju u jednakim omjerima do 2050. godine. Iako bi se za rashladne potrebe mogao uzeti u obzir i porast potrošnje zbog rastućeg turizma, u ovom radu to nije uzeto u obzir. Za određivanje porasta rashladnih potreba bilo bi potrebno analizirati porast turizma, što u ovom radu nije izvođeno zbog jednostavnosti proračuna.

Tablica 23. Toplinske i rashladne potrebe za odabrano šire gradsko područje do 2030. i 2050. godine

GODINA	**Ukupna potrošnja toplinske energije, [GWh/god.]**	**Potrošnja toplinske energije za grijanje prostora, [GWh/god.]**	**Potrošnja toplinske energije za pripremu PTV, [GWh/god.]**	**Ukupna potrošnja rashladne energije, [GWh/god.]**
2014.	239,83	203	36,83	77,37
2030.	231,57	196	35,56	74,71
2050.	189,09	160,05	29,04	61

Za poznate toplinske i rashladne potrebe bilo je potrebno odrediti udio potrošnje koji će se snabdijevati sustavima DTMV prema modelu kako je to u radu opisano za područje Starog grada. Potrošnja toplinske i rashladne energije nije se razmatrala u proračunima u novom algoritmu i u EnergPLAN-u, jer je cilj tih proračuna pokazati razliku između brzog i standardnog punjenja EV i njihov utjecaj na energetski sustav i integraciju OIE, bez integracije s toplinskim sustavom. Integracija transportnog i toplinskog sektora razmatrat će se u proračunima u programu Calliope.

Analizom toplinskog sektora utvrđeno je da se 32% toplinske energije za grijanje prostora snabdijeva iz konvencionalnih izvora energije. Tu spadaju UNP, biomasu i loživo ulje. Pretpostavka da će se ti energenti zamijeniti sustavima DTMV. Taj iznos u 2030. godini, od 62,72 GWh/god., približno je jednak predviđenom iznosu za daljinsko grijanje odabranog šireg gradskog područja, u iznosu od 69,12 GWh/god. Tom iznosu se dodao i iznos od 32% rashladne energije koji će se također zamijeniti sustavima DTMV. Pretpostavka za 2050. godinu je da će se 70% ukupne toplinske i rashladne energije odabranog područja snabdijevati sustavima DTMV, daljinskim sustavima i pojedinačnim sustavima, kao što su pojedina kućanstva uz more i hoteli, a takvih objekata uz more je na dubrovačkom području velika većina. Kod sustava DTMV nije razmatrana priprema PTV već samo potrebe za grijanjem i

hlađenjem prostora. Razlog tome je što se većina pripreme PTV na odabranom području vrši putem električnih bojlera, što znači da je većinom PTV prethodno uvršten u opću potrošnju električne energije. Predviđeni iznosi za 2030. i 2050 nalaze se u [Tablica 24].

Tablica 24. Predviđena potrošnja toplinske i rashladne energije za grijanje i hlađenje prostora na sustave DTMV za 2030. i 2050. godinu

GODINA	Potrošnja toplinske energije za grijanje prostora, [GWh/god.]	Potrošnja rashladne energije za hlađenje prostora, [GWh/god.]
2030.	62,72	23,91
2050.	112,04	42,7

Na odabranom području se rashladne potrebe pokrivaju klimatizacijskim sustavima na električnu energiju. Stoga se iznos električne energije za rashladne potrebe, koja se prenamijenila za sustave DTMV, oduzeo od ukupne potrošnje električne energije s TS Komolac s predviđenom potrošnjom za 2030. godinu. Toplinske potrebe u 2030. godini nisu se oduzimale jer su konvencionalni izvori zamijenjeni sustavima DTMV. U 2050. godini su se također oduzeli dodatni iznosi električne energije za rad DTMV od predviđene potrošnje električne energije na TS Komolac za 2050. godinu. Ostatak toplinskih potreba smatra se da će kao i do sada biti pokriven klimatizacijskim i drugim električnim uređajima i spada pod opću potrošnju električne energije na odabranom području.

2.9.2.3 Porast udjela EV do 2030. i 2050. godine i karakteristike baterija

Povećanje udjela EV do 100% do 2050. za šire gradsko područje Dubrovnika prethodno je izvedeno u diplomskom radu [162] i studijama [2] i [180], i preuzeto je i u ovom radu. Za proračun porasta udjela broja EV na odabranom širem gradskom području korišteni su podaci o broju vozila u Hrvatskoj iz rada [163] i udio vozila odabranog područja u ukupnom broju vozila u Hrvatskoj, prikazan u [Tablica 7]. S obzirom na poznat broj EV u Hrvatskoj do 2050., dobio se broj EV na odabranom području do 2050. godine za svaki scenarij [Tablica 25].

Tablica 25. Broj EV u Hrvatskoj i Dubrovniku za svaki od budućih scenarija

GODINA	2014.	2020.	2030.	2050.
Broj EV u Hrvatskoj, [163]	0	10723	581802	1368462
Broj EV na odabranom području	0	146	7922	18635

U [Tablica 25] prikazan je i predviđeni broj EV za 2020. godinu, što možemo usporediti sa stvarnim brojem EV u toj godini. Prema podacima Centra za vozila Hrvatske [181], broj EV u Hrvatskoj u 2020. godini iznosio je 1343 cestovna motorna vozila (M kategorija) i 1437 motorna vozila (L kategorije), što je znatno manje od predviđenog broja EV u 2020. godini.

Stvarni broj EV od ukupno 2780 je tek 26% od predviđenog broja EV u Hrvatskoj, prema podacima iz rada [163]. Razlog tome je i dalje nepovoljno tržište EV, visoke cijene EV, nedovoljno razvijena infrastruktura i nedovoljni poticaji za njihovom upotrebom. Smatra se kako će ipak uporaba EV u budućem razdoblju ići uzlaznom putanjom i to značajno brže s uređenjem infrastrukture i padom cijena EV. Ovaj rad će pokazati da će EV igrati značajnu ulogu u integraciji visokog udjela OIE u EES. Pružit će prijedloge za poticanje njihova korištenja, a samim time i pad visoke cijene EV. U [Tablica 26] je prikazan broj EV u 2020. godini zajedno s HEV vozilima i vozila na hibridni pogon s vanjskim punjenjem (PHEV – *"plug in hybrid electric vehicle"*).

Tablica 26. Podaci o broju EV, HEV i PHEV u RH za 2020. godinu, [181]

Vrsta pogona vozila	**EV**		**HEV**		**PHEV**	
Vrsta vozila	**M**	**L**	**M**	**L**	**M**	**L**
Broj vozila u 2020. g	1343	1437	8080	3	553	0
Ukupan broj po vrsti pogona	2780		8083		553	
Ukupan broj svih vozila	11416					

Procjena porasta udjela EV za šire gradsko područje Dubrovnika temeljila se na grubim pretpostavkama. Za lokalnu procjenu broja vozila bit će potrebno analizirati i uzeti u obzir vanjske faktore koji će utjecati na određivanje broja vozila do 2050. Također, broj osobnih vozila koji se razmatra ne pokriva broj vozila cijelog područja koje ulazi u granice odabranog sustav. Smatra se da je broj vozila, u onim mjestima koja nisu obuhvaćena odabranim brojem vozila, zanemariv u ukupnom broju vozila. Treba naglasiti i da utjecaj turizma i prijevoz robe i putnika nije uzet u obzir u proračunima ovoga rada. To bi zahtjevalo izradu dodatnih analiza, što se zbog jednostavnosti proračuna izostavilo. Također se smatra da su grube pretpostavke i odabrani podaci zadovoljavajući za potrebe ovog rada.

2.9.2.4 Baterije EV i njihove karakteristike

Nakon što se odredio porast udjela EV vozila do 2050. godine, potrebno je odrediti i karakteristike vozila, odnosno baterije. Radi jednostavnosti proračuna, EV voznog parka podijeljena su na tri kategorije vozila, mala, srednja i velika. Ona zauzimaju jednak udio u ukupnom broju EV za pojedini scenarij, kao što je to prethodno napravljeno u [2], [162] i [180]. U ovom radu su izmijenjene karakteristike baterija za sva tri tipa vozila. Povećani su kapaciteti baterije za svako vozila u odnosu na prethodne radove. Za mala vozila odabran je model Nissan Leaf 2011-2015 (24 kWh), za srednji tip vozila odabran je model Hyundai Kona Electric 64

2019 (64 kWh), a za veliki tip vozila odabran je Tesla Model S 100 2012 (100 kWh) [182]. Njihove karakteristike prikazane su u [Tablica 27] kao i podaci za standardno i brzo punjenje. Standardno punjenje određeno je u trajanju od 5 sati za punu bateriju, dok je brzo punjenje određeno u trajanju od 10 minuta za punu bateriju, prema čemu je izračunata i potrebna snaga iz mreže. Uzeta je u obzir i efikasnost punjenja i pražnjenja EV od 95%, kako je to bilo i u [2], [162] i [180].

Tablica 27. Karakteristike baterija EV

Karakteristike vozila				**Snaga iz mreže potrebna za punjenje, [kW]**	
EV	**Kapacitet, [kWh]**	**Doseg, [km]**	**Potrošnja, [kWh/100km]**	**Standardno punjenje (5 h), P_{SC}**	**Brzo punjenje (10 min), P_{FC}**
Mala	24	121	19	5,1	151,6
Srednja	64	415	18	13,5	404,2
Velika	100	507	23	21,1	631,6

Na temelju krivulje opterećenja prometa za područje Dubrovnika, broja EV i kapaciteta baterije EV, izradio se model potrošnje električne energije za punjenje EV. Dobila se dnevna krivulja opterećenja potrošnjom električne energija za punjenje, kao što je to izvedeno u [2], [162] i [180]. Sva vozila su se u proračunima promatrala kao jedna velika baterija. Cijeli model preuzet je iz prethodnih radova uz promjene na kapacitetima baterija i njihovim karakteristikama. Određeno je da vozilo na širem gradskom području Dubrovnika dnevno prijeđe 45 km [2], [162], [180]. Na temelju tog podatka i podataka u [Tablica 27], dobio se broj punjenja u jednom danu za svaki tip vozila i broj vozila koji se treba puniti, a samim tim i potrebe za električnom energijom za 2030. i 2050. godinu, dane u [Tablica 28]. Dobila se krivulja potrošnje električne energije za punjenje za jedan specifični dan koji se distribuirao na cijelu godinu u vremenskom koraku od 1 sata i 10 minuta. Dnevna potrošnja električne energije za punjenje EV u jednom danu prikazana je dijagramom na [Slika 25]. U obzir su se uzele razlike u karakteristikama baterija kod brzog i standardnog punjenja.

Tablica 28. Karakteristike punjenja EV za jedan dan

EV	**Broj EV**		**Broj EV za punjenje u jednom danu, N_{EV}**		**Broj punjenja u jednom danu, N_{Ch}**
	2030. god.	**2050. god.**	**2030. god.**	**2050. god.**	
Mala	2641	6212	982	2310	0,372
Srednja	2641	6212	286	674	0,108
Velika	2641	6212	234	551	0,089

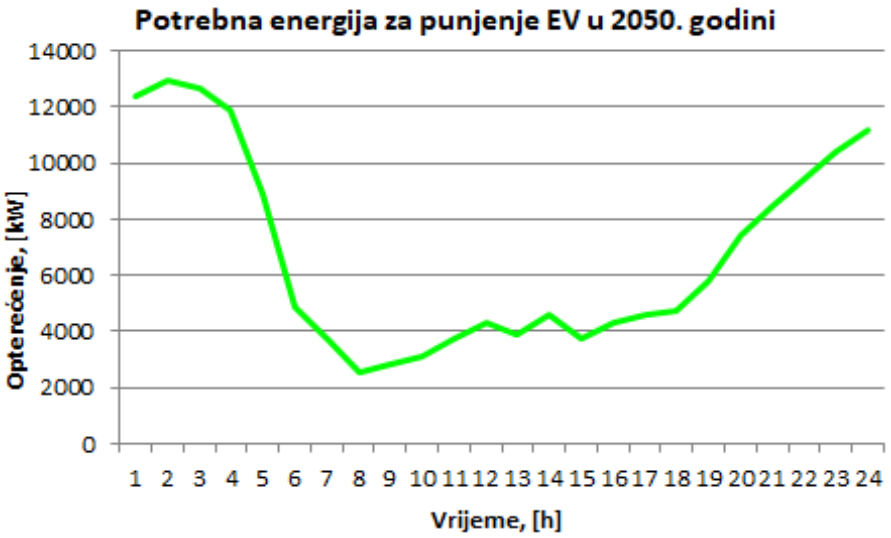

Slika 25. Potrošnja električne energije za punjenje EV za jedan dan u 2050. godini

2.10 Novi algoritam satnog i 10-minutnog modela za integraciju OIE regulacijom modela V2G po uzoru na EnergyPLAN

Postojeća infrastruktura distribucije električne energije postavlja određena ograničenja na uvođenje velikog broja EV u EES. Punjenje EV, koje nije regulirano i ovisi isključivo o potrebama i navikama potrošača, može utjecati na povećanje vršnog opterećenja potrošnje električne energije, čak i u slučaju kada je godišnja potrošnja za punjenje EV niska, na primjer nekoliko tisuća kW. Distribucija nereguliranog punjenja EV podudara se s distribucijom potrošnje električne energije i vršnim opterećenjima, upravo zbog potreba i navika potrošača. Razvijanje IKT između EV i infrastrukture energetskog sustava može prebaciti punjenje u vrijeme niske potrošnje električne energije. EV se mogu koordinirati na način da njihovo punjenje bude regulirano, što nazivamo pametnim punjenjem. Pametnim punjenjem EV osigurava se regulacija EES i kompenzira proizvodnja električne energije iz OIE s distribucijom potrošnje. Pametnim punjenjem EV mogu na efikasan način doprinijeti radu mreže zahvaljujući brzom odzivu na potrebe energetskog sustava i očekivanom rastu broja EV u budućnosti. Pametno punjenje uključuje kontrolu punjenja svakog pojedinog vozila u cilju zadovoljenja potreba vozača za punjenjem vozila u određeno vrijeme. Uključuje i kontrolu za potrebe mreže u cilju osiguravanja regulacije i izbjegavanje preopterećenja mreže, uvjetujući punjenje EV za vrijeme niske potrošnje električne energije.

Mreža može imati dva načina distribucije energije, jednosmjerni i višesmjerni energetski tok. Model pametnog punjenja predstavlja jednosmjerni energetski tok distribucije energije iz

mreže za punjenje EV. Višesmjerni tok distribucije energije, iz mreže za EV i od EV prema mreži, predstavlja takozvani V2G model. Svako vozilo treba obuhvaćati tri osnovna elementa:

- priključak na mrežu za ostvarivanje energetskog toka,
- kontrola i komunikacijska veza s operatorom distribucijskog sustava,
- upravljačku ploču u vozilu za mjerenje snage vozila.

Operator distribucijskog sustava mora imati mogućnost preuzimanja dijela kontrole sustava upravljanja vozilom. Vozač vozila uvijek u većoj mjeri sudjeluju u kontroli punjenja i pražnjenja u cilju smanjenja istrošenosti baterije vozila i pripreme vozila za vožnju. Vozilo uvijek treba biti na raspolaganju za vozača. Time se osigurava sigurnost i pouzdanost za svako zasebno vozilo, dok se pouzdanost električne mreže osigurava kroz veliki broj vozila [162].

U ovom radu će se energetski tokovi u modelu V2G regulirati proizvodnjom električne energije iz OIE koja će utjecati na cijene električne energije. Ukoliko u EES postoji višak u proizvodnji električne energije, on će utjecati na smanjenje cijene energije, a samim time i punjenje EV po nižoj cijeni električne energije. Kod manjka proizvodnje električne energije, cijena energije raste. EV u tom slučaju imaju mogućnost pražnjenja baterije u cilju snabdijevanja manjka u proizvodnji, a i dodatne zarade na visokoj cijeni energije. Konačni cilj uvođenja V2G modela u sustav je kompenziranje nesigurne proizvodnje energije iz OIE u svrhu smanjenja vršnih opterećenja i integracije većeg udjela OIE u EES, gdje EV predstavljaju dodatan izvor fleksibilnosti u sustavu.

Nestabilna i nestalna proizvodnja električne energije iz OIE zahtjeva veliki broj izvora fleksibilnosti u sustavu koji bi osigurali siguran rad sustava. U prethodnim radovima [2], [162] analizirano je planiranje energetskog sustava dubrovačkog područja sa 100% udjela OIE u proizvodnji električne energije i potpuna zamjena KV s EV do 2050. godine. Rezultati su pokazali da unatoč pametnom punjenju, V2G modelu i fleksibilnoj potrošnji električne energije, sustav i dalje ima kritični višak proizvodnje električne energije (CEEP – *"critical excess in electricity production"*). U ovom radu odabrano je šire gradsko područje Dubrovnika za izradu energetskog plana do 2050. U radu se teži samodostatnom EES uz dodatna skladišta i integraciju i elektrifikaciju transportnog i toplinskog sektora, te povezivanje s tržištem električne energije zamjenom dvotarifnog sustava cijena električne energije s varijabilnim cijenama. Integraciju svih sudionika i regulaciju sustava omogućit će primjena IKT alata.

Pretpostavka je da će sustav, baziran na vremenskom koraku od 10 minuta, pružiti više mogućnosti za bolje iskorištavanje proizvodnje električne energije iz OIE te osigurati dodatne izvore fleksibilnosti. Pretpostavka se temelji na razlici u količini energije potrebnoj za

standardno i brzo punjenje. Naime, brzo punjenje omogućuje potpunu napunjenost baterije u 10 minuta, dok za standardno punjenje treba 5 sati da bi se napunila baterija do 100% SOC. Iako brzo punjenje zahtijeva 30 puta manje vremena za punjenje baterije, zahtijeva i 30 puta više snage iz mreže, za 10 minuta punjenja, od jednog sata punjenja standardnim punjenjem. Upravo ta razlika u zahtjevu električne energije za punjenjem predstavlja izvor fleksibilnosti za sustave s brzim punjenjem. Ono omogućuje bolje iskorištavanje isprekidane i nestalne proizvodnje iz OIE. Uz regulaciju varijabilnim cijenama električne energije za punjenje i pražnjenje EV, može osigurati sigurniji rad sustava i smanjiti vršna opterećenja. Također, sustavi modelirani za kratkoročan vremenski korak od 10 minuta, pružaju stvarnu i točniju sliku o energetskim tokovima u sustavu. Osim ovih prednosti koje pruža brzo punjenje, ono ima i nedostataka jer zahtijeva izmjenu infrastrukture, visokonaponske mreže i punjače kako bi bilo omogućeno brzo punjenje EV, a što je i pojašnjeno u uvodnom dijelu ovog rada.

U radu je uzeta pretpostavka da će visokonaponska mreža biti razvijena do 2050. godine i da će biti moguće provoditi brzo punjenje vozila u trajanju od 10 minuta. Razvijen je novi model energetskog planiranja s proračunima za vremenski korak od 10 minuta, po uzoru na EnergyPLAN model koji radi na vremenskom koraku od 1 sat. EnergyPLAN nije mogao poslužiti za izradu analiza EES koji se bazira na 10 minutnom vremenskom koraku, stoga je bilo potrebno izraditi novi algoritam. Novi model analizira EES za period od godinu dana, kao i EnergyPLAN, i izrađen je u Excelu. Kroz rezultate analiza transportnog sektora dat će se usporedba satnog i 10 minutnog modela, kao i reguliranog punjenja i pražnjenja varijabilnim cijenama električne energije i neregulirano punjenja i usporedba s EnergyPLAN modelom. Cijene električne energije nisu razmatrane u iznosima, već ovise o proizvodnji električne energije iz OIE. Pretpostavka je da kod visoke proizvodnje cijena električne energije pada, a kod niske raste. Na taj način regulira se i V2G model u kojem je pretpostavka da se EV pune u vrijeme viška proizvodnje a prazne za vrijeme manjka proizvodnje električne energije u EES.

U jednom od analiziranih scenarija u novom algoritmu, cijene električne energije su uzete u obzir u analizama. Napravljena je usporedba regulacije punjenja i pražnjenja EV prema cijenama postojećeg dvotarifnog sustava (P2T) i varijabilnog dvotarifnog sustava (V2T) cijena električne energije u odnosu na neregulirani sustav. Regulacija punjenja i pražnjenja EV odnosila se na pretpostavku da se vozila pune u vrijeme niske cijene električne energije, a prazne u vrijeme visoke cijene električne energije. P2T model usporedio se s V2T modelom cijena koje se mijenjaju s obzirom na proizvodnju električne energije iz OIE. Kod viška proizvedene električne energije imamo nisku tarifu, a kod manjka visoku tarifu. Ovakva regulacija punjenja i pražnjenja smatra se opravdanom jer ide u korist vozača koji pražnjenjem

vozila, V2G model, mogu zaraditi na visokoj cijeni električne energije, a vozila pune u vrijeme niske tarife.

2.10.1 Izrada algoritma novog modela i opis scenarija

U ovom odjeljku predstavljen je novi model planiranja energetskog sustava koji obuhvaća samo neke od podataka i sudionika sustava. Tu spadaju: proizvodnja električne energije iz vjetra i Sunca te hidroenergija, $E_{RES,i}$, opća potrošnja električne energije za odabrano područje, $E_{DEM,i}$, i potrošnja za punjenje EV, $E_{EV,dem,i}$. Razlog tome je što se novim algoritmom želi pokazati razlika između sustava modeliranog za vremenski korak od 1 sat i 10 minuta, primjenom V2G modela u kompenziranju proizvodnje električne energije u EES i smanjenju vršnih opterećenja. Ravnoteža sustava je razlika proizvodnje i potrošnje električne energije, a može se prikazati jednadžbom (12):

$$E_{RES,i} - E_{DEM,i} - E_{EV,dem,i} \tag{12}$$

Pretpostavlja se da će novi model, baziran na vremenskom koraku od 10 minuta, dati bolje rezultate od satnog modela. To će se očitovati boljim iskorištavanjem proizvedene električne energije OIE i smanjenjem uvoza i izvoza električne energije. Varijabilne cijene električne energije za punjenje i pražnjenje, koje se mijenjaju po uzoru na proizvodnju električne energije, korištene su za regulaciju punjenja i pražnjenja EV.

Punjenje i pražnjenje EV u Excelu analizirano je prema modelu jedne velike baterije. Ukupni kapacitet baterije obuhvaća sva vozila jednako zastupljena u tri odabran tipa vozila koja se razlikuju prema kapacitetu baterije. Ukupni kapacitet baterije jednak je za standardno i brzo punjenje a računa se prema sljedećim jednadžbama:

$$E_{batt,uk} = \left(N_{L,uk} \cdot P_{L,SC} + N_{M,uk} \cdot P_{M,SC} + N_{S,uk} \cdot P_{S,SC}\right) \cdot 5 \cdot \eta_{ch} \tag{13}$$

$$E_{batt,uk} = \frac{\left(N_{L,uk} \cdot P_{L,FC} + N_{M,uk} \cdot P_{M,FC} + N_{S,uk} \cdot P_{S,FC}\right) \cdot \eta_{ch}}{6} \tag{14}$$

N predstavlja broj vozila, a indeks označava o kojem se tipu vozila radi. Snaga iz mreže potrebna za punjenje označena je s *P*, gdje prvi indeks predstavlja tip vozila a drugi vrstu punjenja. Podaci su preuzeti iz [Tablica 27]. Kod standardnog punjenja potrebno je 5 sati da se napuni baterija. Efikasnost punjenja η_{ch} koja iznosi 95%. Ukupni kapacitet baterije svih vozila računa se prema jednadžbi (13) za standardno punjenje. Kod brzog punjenja baterija se napuni u 10 minuta pa kao jedinicu energije imamo MW·10min. Ukupni kapacitet baterije svih vozila kod brzog punjenja računa se prema jednadžbi (14).

Maksimalna snaga iz mreže, $P_{uk,i}$, potrebna za standardno i brzo punjenje baterije, predstavlja granični slučaj kada su sva EV u isto vrijeme priključena na mrežu. Maksimalna

energija za brzo punjenje je 30 puta veća od one za standardno punjenje za jedan vremenski korak. Kod standardnog punjenja se u jednom vremenskom koraku od 1 h napuni petina baterije, dok se kod brzog punjenja napuni cijela baterija u 10 minuta. Jednadžbe za jedan vremenski korak glase:

$$P_{SC,uk,i} = N_{L,uk,i} \cdot P_{L,SC} + N_{M,uk,i} \cdot P_{M,SC} + N_{S,uk,i} \cdot P_{S,SC} \quad (15)$$

$$P_{FC,uk,i/6} = N_{L,uk,i/6} \cdot P_{L,FC} + N_{M,uk,i/6} \cdot P_{M,FC} + N_{S,uk,i/6} \cdot P_{S,FC} \quad (16)$$

Maksimalna akumulirana energija u bateriji za jedan vremenski korak glasi:

$$E_{batt,SC,max,i} = P_{SC,uk,i} \cdot \eta_{ch} = \frac{E_{batt,uk}}{5} \quad (17)$$

$$E_{batt,FC,max,i/6} = P_{FC,uk,i/6} \cdot \eta_{ch} = E_{batt,uk} \cdot 6 \quad (18)$$

U novom modelu je, osim punjenja baterije, razmatrano i pražnjenje baterije, takozvani model V2G. U slučaju punjenja EV, BEV služe kao skladišta električne energije i predstavljaju dodatni izvor fleksibilnosti u sustav. U mogućnosti su pohraniti električnu energiju, čime doprinose smanjenju vršnih opterećenja uslijed proizvodnje električne energije iz OIE. Punjenje EV u cilju smanjenja vršnih opterećenja proizvodnje iz OIE određeno je takozvanim modelom mreža-na-vozilo (G2V – *"grid-to-vehicle"*). Pretpostavka modela je da će, u vrijeme visoke proizvodnje električne energije iz OIE, cijena električne energije biti niska, zbog čega će se vlasnici EV odlučiti puniti svoja vozila u vrijeme niske cijene. Za slučaj kada u sustavu imamo manjak proizvodnje električne energije za zadovoljenje svih potreba, cijena električne energije će biti visoka. To će potaknuti vlasnike EV na pražnjenje svojih vozila za vrijeme visoke cijene. Korištenjem modela G2V i V2G vlasnici će biti u mogućnosti koristit svoje EV kao izvor fleksibilnosti u sustavu koje može koristiti električnu energiju niske cijene ili ju prodavati po visokoj cijeni, u količini u kojoj to dozvoljava trenutni kapacitet baterije. Stoga se maksimalna energija za pražnjenje može opisati jednadžbama (19) i (20), gdje je u slučaju brzog pražnjenja za jedan vremenski korak ona 30 puta veća nego kod standardnog pražnjenja.

$$E_{EV,SD,max,i} = E_{batt,\mathrm{SC},max,i} \cdot \eta_{disch} \quad (19)$$

$$E_{EV,FD,max,i/6} = E_{batt,FC,max,i/6} \cdot \eta_{disch} \quad (20)$$

Prethodno je već opisan model vožnje i potrošnje energije na vožnju za jedan dan koji se distribuirao na cijelu godinu. Radi jednostavnosti proračuna odabrano je da se taj specifičan dan ponavlja svaki dan u godini. Iz modela vožnje i potrošnje električne energije dobivene su vrijednosti potražnje električne energije za punjenje EV u svakom vremenskom koraku, $E_{EV,dem,i}$. Potrošnja električne energije na vožnju EV za jedan vremenski korak jednaka je

potražnji za električnom energijom u sljedećem vremenskom koraku, $E_{EV,dem,i+1}$, i ona u svakom koraku mora biti zadovoljena. Također, ona vozila, koja su u tom vremenskom koraku u vožnji, $E_{EV,dem,i+1}$, ne mogu biti dostupna za punjenje i pražnjenje. Kada se u modelu zadovolje te potrebe vožnje i oduzmu se vozila koja nisu parkirana za određeni vremenski korak, ostatak baterije se može razmatrati za modele G2V i V2G. Pretpostavka je da će vlasnici EV puniti svoja vozila u vrijeme niske cijene električne energije, kad je proizvodnja energije visoka. U tom slučaju nema pražnjenja vozila, V2G, već imamo samo G2V. U vrijeme niske proizvodnje električne energije njena cijena raste jer raste i potražnja za električnom energijom i vlasnici prodaju energiju mreži po visokoj cijeni. U tom slučaju smatra se da nema punjenja EV, G2V, nego imamo samo V2G. U stvarnosti se svi vozači neće ponašati na način kako je to opisano u ovom modelu, iako će biti stimulirani cijenom električne energije, pa ovaj model možemo smatrati graničnim, najboljim slučajem. Punjenje i pražnjenje EV možemo zapisati sljedećim jednadžbama:

$$0 \leq E_{G2V,max,i} \leq E_{batt,max,i} - (E_{EV,dem,i} - E_{EV,dem,i+1}) \cdot \eta_{ch} \tag{21}$$

$$0 \leq E_{V2G,max,i} \leq E_{batt,max,i} - (E_{EV,dem,i} - E_{EV,dem,i+1}) \cdot \eta_{disch} \tag{22}$$

U svakom vremenskom koraku, maksimalni mogući kapacitet baterije za punjenje, $E_{G2V,max,i}$, i pražnjenje, $E_{V2G,max,i}$, predstavlja maksimalni kapacitet baterije za taj vremenski korak, $E_{batt,max,i}$, umanjen za vozila koja se voze, $E_{EV,dem,i+1}$, i vozila koja se pune, $E_{EV,dem,i}$. Regulacija punjenja i pražnjenja zadana je sljedećim funkcijama:

regulacija punjenja EV

Ako je $E_{G2V,i} > E_{batt,uk} - E_{batt,i-1} - E_{EV,dem,i} \cdot \eta_{ch}$

onda $E_{G2V,i} = E_{batt,uk} - E_{batt,i-1} - E_{EV,dem,i} \cdot \eta_{ch}$

ako ne onda $E_{G2V,i}$

regulacija pražnjenja EV

Ako je $E_{batt,i-1} + E_{G2V,i} + (E_{EV,dem,i} - E_{EV,dem,i+1}) \cdot \eta_{ch} - E_{V2G,i} < E_{EV,dem,i+2} \cdot \eta_{ch}$

onda $E_{V2G,i} = E_{batt,i-1} - (E_{EV,dem,i+1} - E_{EV,dem,i+2} + E_{EV,dem,i}) \cdot \eta_{ch} + E_{G2V,i}$

ako ne onda $E_{V2G,i}$

Raspoloživi kapacitet baterije za punjenje u svakom vremenskom koraku, $E_{G2V,i}$, ovisi o kapacitetu baterije iz prethodnog koraka, $E_{batt,i-1}$, i kapacitetu vozila koja se trenutno pune, $E_{EV,dem,i}$, zbog potrošnje uzrokovane vožnjom u prethodnom vremenskom koraku. Također, pretpostavka je da će se vozila puniti samo u vrijeme viška proizvodnje iz OIE, dok će potrošnja baterije uslijed vožnje u svako vremenskom koraku biti zadovoljena, ako ne iz OIE onda iz

uvoza. S obzirom da se EV pristupa kao jednoj velikoj bateriji, zbog jednostavnosti proračuna smatra se da se potrošnja iz prethodnog vremenskog koraka uvijek zadovolji u sljedećem koraku. To bi zapravo u stvarnom sustavu značilo da vozač uvijek na raspolaganju ima vozilo i može njime upravljati i da će sustav i vozač uvijek osigurati da u vozilu ima dovoljno baterije za planiranu vožnju. Planirana vožnja je već prethodno modelirana i poznata za proračun i jednaka je potražnji za električnom energijom u sljedećem koraku. Temeljem tih pretpostavki postavljen je i početni kapacitet baterije nultog vremenskog koraka koji je jednak iznosu kapaciteta baterije za vožnju u prvom vremenskom koraku. Kapacitet raspoloživ za pražnjenje EV, $E_{V2G,i}$, ovisi o raspoloživom kapacitetu baterije iz prethodnog koraka i osigurava vožnju za sljedeća dva vremenska koraka, $E_{EV,dem,i+2}$. Raspoloživa baterija umanjena je za vozila koja trenutno ne mogu biti na raspolaganju za pražnjenje jer se pune i jer se voze.

Stanje raspoložive baterije u svakom koraku ovisi o kapacitetu baterije iz prethodnog koraka, $E_{batt,i-1}$, i ukupnoj energiji za punjenje, $E_{G2V,i}$, i pražnjenje EV u tom koraku, $E_{V2G,i}$. Stoga, osim o ponudi i potražnji električne energije u sustavu, punjenje i pražnjenje EV ovisi i o dostupnom kapacitetu baterije u svakom pojedinom vremenskom koraku, $E_{batt,i}$. Kapacitet baterije u svakom koraku mora biti veći ili jednak iznosu koji će zadovoljiti vožnju za sljedeća dva vremenska koraka, $E_{EV,dem,i+2}$. Također mora biti manji ili jednak ukupnom kapacitetu baterije, $E_{batt,uk}$, umanjenom za vozila koja se voze u tom vremenskom koraku, $E_{EV,dem,i+1}$, i nisu raspoloživa za punjenje i pražnjenje, prema jednadžbi:

$$\begin{aligned} E_{EV,dem,i+2} \cdot \eta_{ch} &\leq E_{batt,i} \\ &= E_{batt,i-1} + E_{G2V,i} - E_{V2G,i} + (E_{EV,dem,i} - E_{EV,dem,i+1}) \cdot \eta_{ch} \\ &\leq E_{batt,uk} - E_{EV,dem,i+1} \cdot \eta_{ch} \end{aligned} \tag{23}$$

Dijagram toka za neregulirani i regulirani sustav, za satni i 10-minutni korak, za izrađeni algoritam u Excelu prikazan je na [Slika 26]. Neregulirani sustav uključuje proizvodnju električne energije iz OIE, opću potrošnju električne energije na odabranom širem gradskom području i potrošnju električne energije za punjenje EV, uzrokovanu vožnjom EV, bez dodatne regulacije punjenja i bez modela V2G. Regulirani sustav uključuje sve sudionike navedene za prethodni neregulirani sustav, međutim uključuje model V2G i regulaciju punjenja i pražnjenja EV cijenama električne energije. Cijene električne energije nisu prikazane iznosom, već je pretpostavka da se cijena regulira viškom i manjkom proizvodnje električne energije iz OIE. Primjerice, kada je proizvodnja električne energije visoka i prelazi potrebe za konzumiranjem u danom vremenskom koraku, u tom slučaju cijena električne energije je niska i pruža ekonomično korištenje modela G2V za vlasnike EV. U vrijeme manjka proizvodnje, u

sustavu imamo nedostatak električne energije i cijena potražnje za električnom energijom je visoka, što pruža mogućnost zarade vlasnicima EV korištenjem modela V2G kako bi nadomjestili manjak u proizvodnji električne energije.

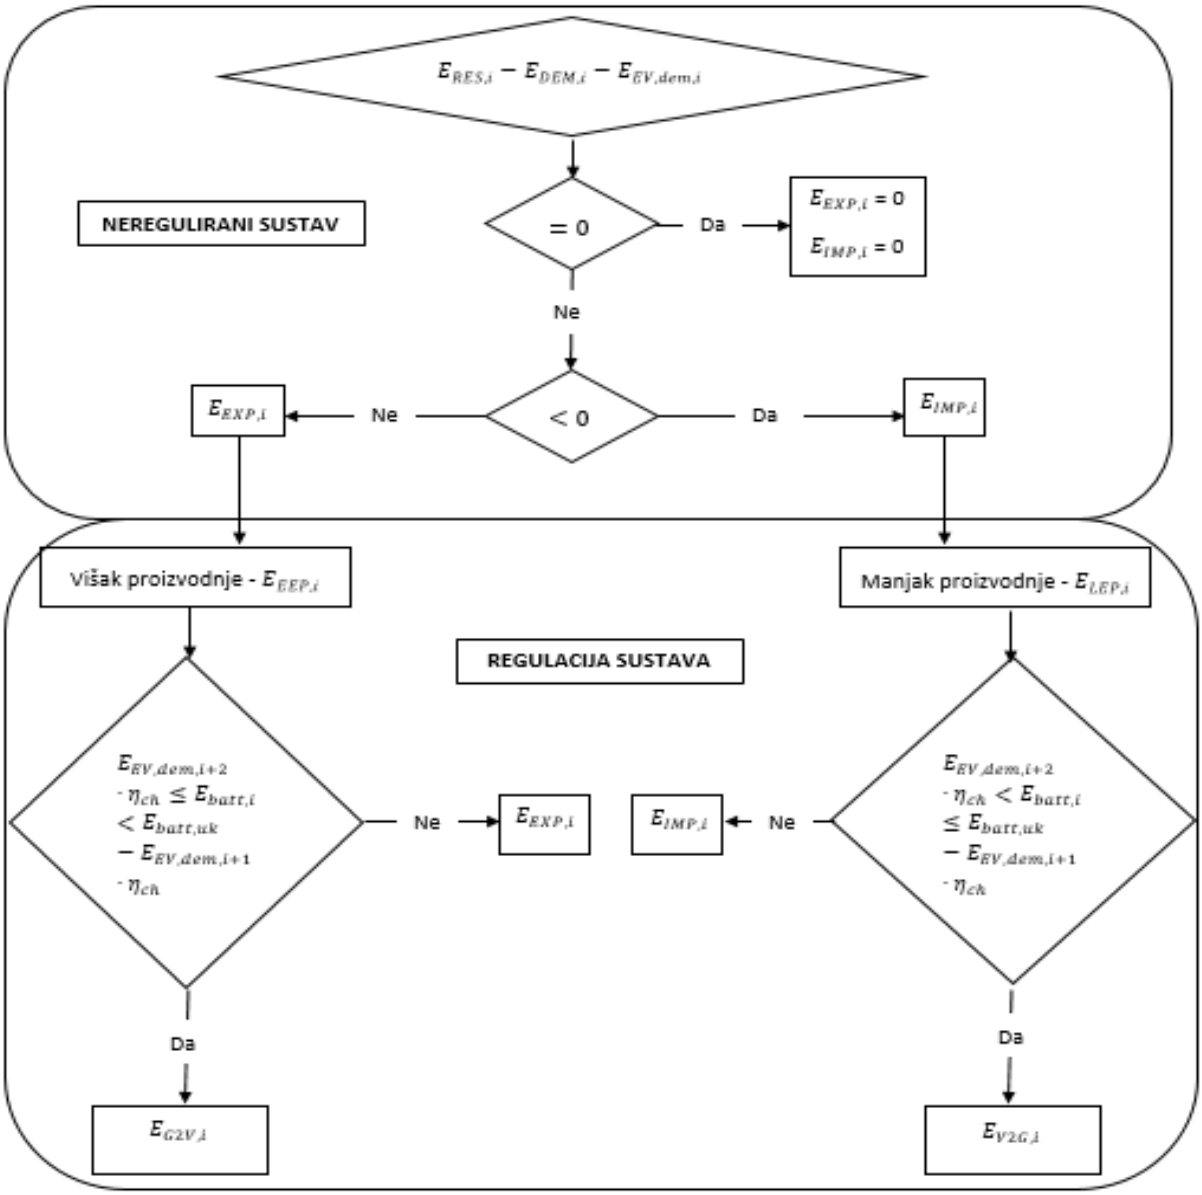

Slika 26. Dijagram toka nereguliranog sustava s EV i reguliranog sustava primjenom V2G i G2V modela

Ravnoteža sustava kod nereguliranog punjenja prikazana je jednadžbom (24), a za regulirani sustav i V2G model prikazana je jednadžbom (25):

$$E_{RES,i} - E_{DEM,i} - E_{EV,dem,i} - E_{EXP,i} + E_{IMP,i} = 0 \tag{24}$$

$$E_{RES,i} - E_{DEM,i} - E_{EV,dem,i} - \frac{E_{G2V,i}}{\eta_{ch}} + E_{V2G,i} \cdot \eta_{disch} - E_{EXP,i} + E_{IMP,i} = 0 \tag{25}$$

Proračuni i analize sektora transporta u novom algoritmu izrađeni su za scenarij 2030. i 2050. godine uz detaljnije analize i rezultate za četiri slučaja. Slučajevi su postavljeni i analizirani na način da se da usporedba satnog i 10-minutnog modela, odnosno standardnog i brzog punjenja, kao i usporedba nereguliranog i reguliranog sustava. Regulacija je uključivala primjenu V2G modela, dok se u nereguliranom sustavu punjenje EV odvija isključivo prema navikama i potrebama vozača i ne uključuje model V2G. [Tablica 29] pruža detaljan opis scenarija i slučajeva analiziranih u novom modelu. Primjerice, ako se analizira slučaj S1 za 2030. godinu, za standardno punjenje i vremenski korak od 1 sat, koji ne uključuje regulaciju punjenja i pražnjenja, možemo ga ukratko zapisati kao 2030_1h_NEREG_S1.

U slučaju S4, za 2050. godinu i za standardno i brzo punjenje, napravila se analiza troška punjenja EV i smanjenja troška uvođenjem V2G modela koji je reguliran P2T i V2T modelom cijena. Za odabrane scenarije usporedila su se dva modela cijena i dva načina punjenja i pražnjenja EV i analizirao se troška za odabrane modele i scenarije. U obzir se uzeo trošak $E_{EV,dem,i}$ za punjenje EV, koji predstavlja dio punjenja koji je izmodeliran na način da prati navike potrošača i osigurava da baterija EV uvijek ima dovoljan kapacitet za iduću vožnju. On nije reguliran cijenama električne energije, međutim, moguće je očekivati da bi dio te potrošnje ipak mogao biti dio regulirane potrošnje u budućnosti. Drugu vrstu troška predstavlja punjenje EV prema G2V modelu, $E_{G2V,i}$, i regulirano je cijenama električne energije u cilju smanjenja troška za punjenje. Treći segment predstavlja pražnjenje EV prema modelu V2G, $E_{V2G,i}$, što zapravo predstavlja zaradu vlasnika vozila. EV se prazne za vrijeme visoke cijene električne energije, odnosno u vrijeme manjka proizvodnje električne energije.

Trošak, C_i, i zarada, E_i, izračunati su prema jednadžbama (26) i (27). E_i predstavlja zaradu u pojedinom vremenskom koraku, korištenjem V2G i G2V modela. Vlasnici, osim za vožnju, vozilo koriste i kao dodatno skladište, odnosno izvor fleksibilnosti za sustav, pri čemu mogu ostvariti zaradu. C_i predstavlja ukupni trošak vlasnika EV za punjenje u svakom pojedinom vremenskom trenutku, kad se u obzir uzme i dio vozila koja se pune prema navikama potrošača, $E_{EV,dem,i}$. P_i predstavlja cijenu električne energije za punjenje EV u datom trenutku.

$$E_{V2G,i} \cdot \eta_{disch} \cdot P_i - \frac{E_{G2V,i}}{\eta_{ch}} \cdot P_i - E_{EV,dem,i} = C_i \tag{26}$$

$$E_{V2G,i} \cdot \eta_{disch} \cdot P_i - \frac{E_{G2V,i}}{\eta_{ch}} \cdot P_i = E_i \tag{27}$$

Tablica 29. Opis scenarija i slučaja ispitivanih u analizama u novom modelu

<table>
<tr><th colspan="4">SCENARIJ</th></tr>
<tr><td colspan="2">2030
(scenarij za 2030. godinu s planiranom proizvodnjom, potrošnjom i penetracijom EV u odabranom EES)</td><td colspan="2">2050
(scenarij za 2050. godinu s planiranom proizvodnjom, potrošnjom i penetracijom EV u odabranom EES)</td></tr>
<tr><th colspan="4">VREMENSKI KORAK</th></tr>
<tr><td colspan="2">1h
(vremenski korak proračuna godišnjih podatka, 8760 podataka, uključuje standardno punjenje u trajanju od 5h za punu bateriju EV)</td><td colspan="2">10min
(vremenski korak proračuna godišnjih podatka, 52560 podataka, uključuje brzo punjenje u trajanju od 10 min za punu bateriju EV)</td></tr>
<tr><th colspan="4">REGULACIJA U EES</th></tr>
<tr><td colspan="2">NEREG
(punjenje EV bazira se isključivo na potrebama i navikama potrošača i ne uključuje nikakav oblik regulacije)</td><td colspan="2">REG
(model V2G regulirano punjenje i pražnjenje EV cijenama električne energije koje su uvjetovane proizvodnjom električne energije iz OIE)</td></tr>
<tr><th colspan="4">SLUČAJ</th></tr>
<tr><th>S1</th><th>S2</th><th>S3</th><th>S4</th></tr>
<tr><td>$Batt_{MAX}$+VE+SE
(slučaj kada je ukupna raspoloživa baterija EV dostupna za punjenje i pražnjenje u svakom vremenskom koraku, gdje proizvodnja električne energije iz OIE uključuje VE i SE)</td><td>$Batt_{MAX}$+VE+SE+HE
(slučaj kada je ukupna raspoloživa baterija EV dostupna za punjenje i pražnjenje u svakom vremenskom koraku, gdje proizvodnja električne energije iz OIE uključuje VE, SE i HE)</td><td>$Batt_{MIN}$+VE+SE
(slučaj u kojem se ispitivala minimalno raspoloživa baterija EV dostupna za punjenje i pražnjenje u svakom vremenskom koraku koja će dati jednak rezultat na smanjenje uvoza i izvoza kao i u S1, gdje proizvodnja električne energije iz OIE uključuje VE i SE)</td><td>$Batt_{MIN}$+VE+SE+ 2T
(slučaj kada je ukupna raspoloživa baterija EV dostupna za punjenje i pražnjenje u svakom vremenskom koraku, gdje proizvodnja električne energije iz OIE uključuje VE i SE, a regulacija punjenje i pražnjenje odvija se prema P2T i V2T modelu cijena električne energije)</td></tr>
</table>

Rezultati novog modela usporedili su se s rezultatima EnergyPLAN modela u svrhu validacije novog modela, na satnoj i 10-minutoj rezoluciji. Treba naglasiti da, proračune za vremenski korak od 10 minuta, nije bilo moguće izvesti u EnergPLAN-u za cijelu godinu, s obzirom da on radi na satnoj bazi unosa podataka i ograničen je na 8784 podatka. Stoga su se, za usporedbu 10-minutnog modela novog algoritma s EnergyPLAN-om, uzeli podaci za lipanj i srpanj. Ta dva mjeseca u 10-minutnom modelu ukupno sadrže 8784 podatka, pa su se rezultati ta dva mjeseca usporedili za novi algoritam i EnergyPLAN. S obzirom da je EnergyPLAN prihvaćen i dobro razvijen alat u području energetskog planiranja, služio je kao usporedba novo razvijenom algoritmu i potvrda valjanosti dobivenih rezultata.

Novi model je analizirao scenarije i slučajeve koji obuhvaćaju samo elektrifikaciju transportnog sektora. Stoga se napravila nadogradnja novog modela izradom modela energetskog plana do 2050. u programu Calliope. Rezultati novog modela i modela Calliope također su se prethodno usporedili u svrhu validacije rezultata. prikazuje scenarije i slučajeve koji su korišteni za usporedbu novog modela s postojećima alatima, EnergyPLAN i Calliope. Usporedba s EnergyPLAN-om uključivala je scenarije u narančastom okviru, a s Calliope-om u plavom okviru.

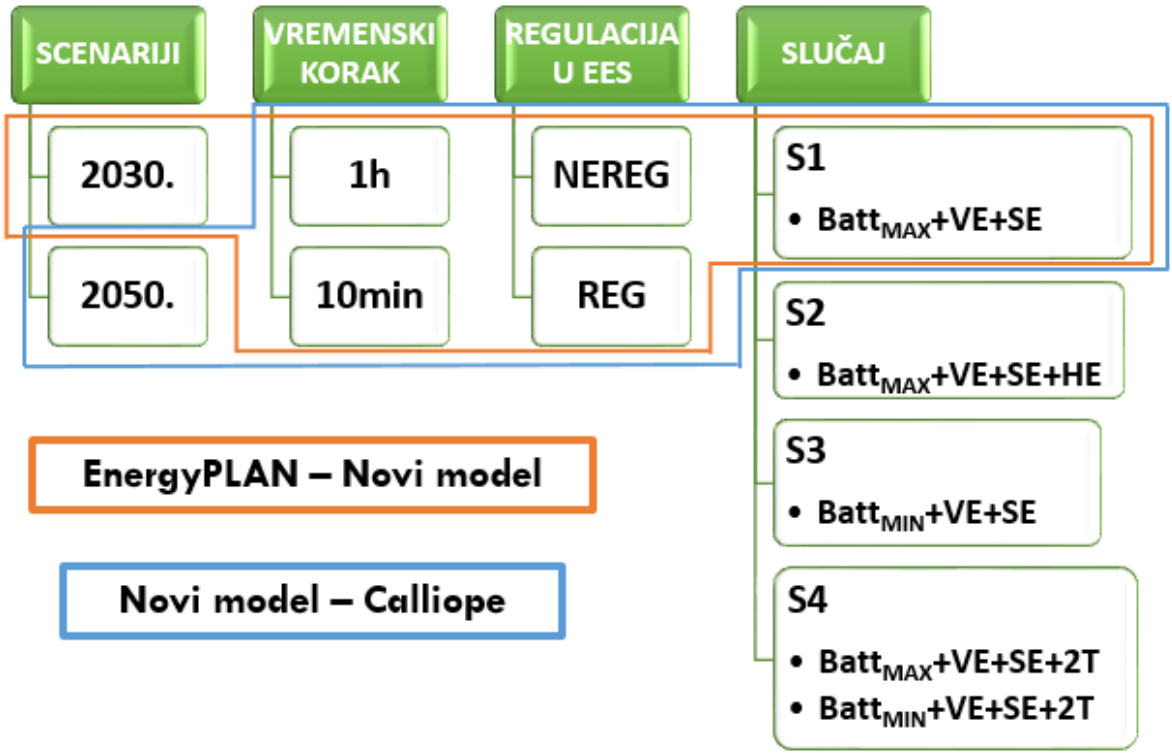

Slika 27. Prikaz metode usporedbe i validacije rezultata korištenih modela za energetsko planiranje

2.11 EnergyPLAN model

U ovom radu razvijen je algoritam za regulaciju punjenja i pražnjenja EV u svrhu smanjenja vršnih opterećenja, smanjenja uvoza i izvoza električne energije i kao dodatni izvor fleksibilnosti energetskog sustava modeliranog za satni i 10-minutni vremenski korak, a po uzoru na već postojeći model EnergyPLAN. EnergyPLAN je alat za analizu energetskog sustava razvijen u cilju proučavanja i istraživanja modela održivih energetskih rješenja s posebnim naglaskom na energetske sustave s visokim udjelom OIE. Razvija se od 1999. godine i stvorio je temelj za značajan broj doktorskih radova i nekoliko stotina znanstvenih radova. EnergyPLAN je osmišljen tako da iskoristi sinergiju omogućenu uključivanjem cijelog energetskog sustava, kao što je to izraženo u konceptu pametnog energetskog sustava. Stoga, uz EnergyPLAN, korisnik može zauzeti holistički pristup usredotočujući se na analizu međusektorske interakcije. Tradicionalno različiti sektori potražnje, kao što su zgrade, industrija i promet, povezani su s tehnologijama opskrbe električnom energijom, plinom, daljinskim grijanjem i hlađenjem. Na taj način EnergyPLAN omogućuje analizu pretvorbe obnovljive električne energije u druge nositelje energije, poput topline, vodika, zelenih plinova i elektrogoriva, kao i provedbu poboljšanja energetske učinkovitosti i očuvanja energije [183]. Detaljniji opis EnergyPLAN-a dat je u literaturi [183], u radu [2] i u diplomskom radu [162] koji analiziraju energetski sustav na području grada Dubrovnika korištenjem EnergyPLAN-a.

EnergyPLAN je program koji radi analizu energetskog sustava na satnoj bazi s podacima za svaki sat za 8784 podatka, odnosno radi proračune za prijestupnu godinu. U ovom dijelu rada i u cilju usporedbe standardnog i brzog punjenja, korišteni su samo neki od sudionika odabranog energetskog sustava. Cilj je prikazati koliko fleksibilnosti sustavu pruža regulirano punjenje u odnosu na neregulirano, na satnoj i 10-minutnoj bazi. Prikazana je usporedba reguliranog satnog i 10-minutnog modela, odnosno reguliranog standardnog i brzog punjenja. Stoga je u EnergyPLAN-u korišten dio za opću potrošnju električne energije, sektor transporta i proizvodnja iz OIE, koja uključuje proizvodnju energije iz SE i VE. U nastavku će se opisati pristup u EnergyPLAN-u i korišteni model V2G za regulaciju punjenja i pražnjenja EV. Za izradu proračuna korištena je verzija 15.0 EnergyPLAN-a. Cilj planiranja je optimizirati energetski sustav u svrhu smanjenja vršne proizvodnje iz OIE i smanjenje viška i manjka proizvedene električne energije uvođenjem dodatnih izvora fleksibilnosti u sustav, u ovom slučaju EV.

2.11.1 Opis EnergyPLAN modela

Od ulaznih podataka za proračun u EnergyPLAN-u razmatrat će se potrošnja električne energije koju je u sustavu potrebno zadovoljiti, proizvodnja električne energije iz OIE i transportni sustav. Transport spada u potrošnju električne energije, a isto tako može sudjelovati u proizvodnji električne energije ako se koriste modeli V2G koji su namijenjeni opskrbi elektroenergetskog sustava u vrijeme manjka proizvodnje. Za svaki od ulaznih podataka bilo je potrebno pripremiti satnu krivulju godišnje potrošnje ili proizvodnje električne energije, podatak o ukupnoj godišnjoj potrošnji električne energije, opće potrošnje i u transportu, te instaliranoj snazi OIE. V2G model zahtijevao je unos još dodatnih podataka o BEV i podataka za regulaciju punjenja i pražnjenja EV.

Ukupna potrošnja električne energije, d_{Total}, računa se kao suma svih potrošnji, koje ovdje uključuju opću potrošnju d_E, potrošnju za punjenje EV nereguliranim punjenjem (*"Dump charge"*), d_{BEV}, i model V2G, d_{V2G}:

$$d_{Total} = d_E + d_{BEV} + d_{V2G} \tag{28}$$

Ukupna proizvodnja energije, e_{Total}, obuhvaća samo proizvodnju iz OIE, e_{Res}, Sunce, e_{Res1}, i vjetar, e_{Res2}, i računa se prema:

$$e_{Total} = e_{Res} = e_{Res1} + e_{Res2} \tag{29}$$

Razlika između potrošnje i proizvodnje predstavlja višak ili manjak u proizvodnji električne energije, ovisno o tome je li se u određenom satu za koji se računa, proizvede više ili manje energije nego što je potrebno:

$$e_{PP} = d_{Total} - e_{Total} \tag{30}$$

Distribucija potrošnje raspoređena je unutar intervala koji se proteže između dva ograničenja:

a) uvijek mora biti pozitivna,

b) treba biti niža od zadanog maksimuma, *CFX* (definiran na ulazu).

Određivanje granica varijacija osigurava da prosječna potrošnja perioda odgovara prosječnoj godišnjoj potrošnji.

2.11.1.1 <u>EV i model V2G</u>

EV su podijeljena, s obzirom na način punjenja, na neregulirana (neregulirano punjenje ili *"Dump Charge"*) i pametna vozila (pametno punjenje ili *"Smart Charge"*). U slučaju nereguliranog punjenja, ulazni podatak određen je potrošnjom električne energije u prometu. Prikazana je podatkom o vrijednosti ukupne godišnje potrošnje, D_{BEV}, i satnom distribucijskom

krivuljom potrošnje električne energije. U slučaju pametnog punjenja, uz satnu distribucijsku krivulju potrošnje i vrijednost ukupne godišnje potrošnje, D_{V2G}, sadrži i podatke za regulaciju pa je potrebno odrediti nekoliko bitnih ulaznih podataka. Svi ulazi podaci dani su za cjelokupni sustav opskrbe koji se analizira i za cjelokupni vozni park zajedno sa svim uslugama transportnog sustava unutar sustava opskrbe. Tako je, na primjer, maksimalno opterećenje sustava, $C_{Charger}$, izračunato na temelju maksimalne snage jednog vozila i pomnoženo s maksimalnim brojem vozila koja su priključena na mrežu u bilo kojem vremenu. Jedan važan ulazni podatak je distribucija satne krivulje potrošnje u transportu, δ_{V2G}, koja se koristi u dvije svrhe. Jedna je za određivanje broja V2G vozila koji su u vožnji u satu koji se računa i nisu spojeni na mrežu. Taj podatak, zajedno s maksimalnim udjelom vozila u vožnji u satu vršne potrošnje, $V2G_{MaxShare}$, i onih spojenih na mrežu, $V2G_{Connection-Share}$, određuje raspodjelu V2G voznog parka koji je na raspolaganju energetskom sustavu u bilo kojem satu za punjenje. Druga svrha definiranja, δ_{V2G}, je određivanje pražnjenja baterije uslijed vožnje.

Satna krivulja potrošnje u transportu, a time i pražnjenje baterije, t_{V2G}, računa se na sljedeći način:

$$t_{V2G} = \left[D_{V2G} \cdot \delta_{V2G} / \sum \delta_{V2G}\right] \cdot \eta_{CHARGE} \tag{31}$$

Opterećenje priključka ukupnog V2G voznog parka na mrežu na satnoj osnovi, c_{V2G}, računa se:

$$\begin{aligned} c_{V2G} &= C_{Charger} \cdot V2G_{Connection-Share} \\ &\cdot \left((1 - V2G_{MaxShare}) + V2G_{MaxShare}\right. \\ &\cdot \left.(1 - \delta_{V2G} / Max(\delta_{V2G}))\right) \end{aligned} \tag{32}$$

Formula se sastoji od tri faktora. Prvi faktor je, $C_{Charger}$, snaga ukupnog V2G voznog parka. Pomnožen je s, $V2G_{Connection-Share}$, udio parkiranih vozila za koje se pretpostavlja da će biti priključeni na mrežu. Treći faktor, u zagradama, računa udio vozila u vožnji u svakom satu. Treći faktor temelji se na zbroju dva uvjeta. Prvi uvjet, $(1 - V2G_{MaxShare})$, predstavlja minimalni udio parkiranih vozila. Drugi uvjet predstavlja dodatni udio vozila koji su parkirani za vrijeme niskog opterećenja prometa. Udio parkiranih vozila u satu poznat je iz ulaznog podatka iz satne krivulje potrošnje električne energije voznog parka. Ova formula računa c_{V2G}, opterećenje svih priključenih V2G vozila, u bilo kojem satu. Formula računa opterećenje, ne uzimajući u obzir je li dovoljna dostupna snaga baterije. To će se uzeti u obzir u daljnjem proračunu.

Raspoloživa snaga raspodijeljena je između vršne potrošnje tijekom najvećeg opterećenja. Ova potrošnja odnosi se na potrošnju baterije, a ne na potrošnju električne energije sustava, jer su vozila nužno isključena s mreže dok su u vožnji. Proračun raspoloživog priključka na mrežu ovisi o definiciji oba udjela, maksimalnog udjela V2G vozila, $V2G_{MaxShare}$, i udjela parkiranih vozila koja su priključena na mrežu, $V2G_{Connection-Share}$. Baterije V2G voznog parka modelirane su kao jedna "velika baterija" za cijeli vozni park. Raspoloživa snaga baterije jednaka je maksimalnom opterećenju. U stvarnosti, ukupno opterećenje baterije nije raspoloživo cijelo vrijeme, zbog toga što će neka vozila biti u vožnji i ne mogu se niti prazniti niti puniti s mreže; ostala vozila će morati voziti tijekom sljedećih nekoliko sati i zbog toga se neće moći prazniti. U svakom slučaju, zbog jednostavnosti, model pretpostavlja da je baterija u potpunosti napunjena kada se vozilo isključi s mreže i krene u vožnju. Od modela se zahtijeva da osigura da je svako pojedinačno vozilo potpuno napunjeno prije isključivanja. Općenito, baterija je puna u slučaju viška proizvodnje električne energije. Međutim, kada nema viška proizvodnje energije, model mora osigurati da je baterija napunjena prije voznog ciklusa. Model pretpostavlja da je raspored vožnje svakog vozila 100% ispravan u uvjetima određivanja kada će vozač trebati ponovno koristit vozilo za vožnju. Zbog toga se u rasporedu pretpostavlja da će se prvo puniti vozila koja će se ponovno voziti u sljedećim satima. Ako postoji i mala proizvodnja iz vjetra, usmjerena je na vozila koja će se koristiti u nadolazećem vremenu. To jest, tijekom svakog sata, model ispituje sljedeći, na primjer, ispituje potrebe vožnje za dva sata i ako baterija nije dovoljno napunjena za to vrijeme, onda prisilno puni bateriju i u slučaju nedostatka viška proizvodnje. Takva procedura simulira situaciju u kojoj će svaki vozač pojedinačno određivati prioritete u pogledu optimizacije između punjenja s niskim troškom i sigurnosti napunjene baterije prije početka vožnje. Vlasnik vozila će to odrediti na način da odredi cijene i ograničenja na kompjuterskom sustavu regulacije vozila. Dakako, vozač će s vremenom iz iskustva naučiti i znati kako to optimizirati. Također će znati koliko sati prije mora početi puniti bateriju u slučaju punjenja u vrijeme više cijene energije. U ovom slučaju, model sam određuje broj sati koji su potrebni za sigurnu vožnju, a s tim i minimalno potrebno punjenje koje treba zadovoljiti. Potreban broj sati ovisit će o obliku i modelu distribucije krivulje potrošnje kao i o definiranju ostalog dijela energetskog sustava. Na primjer, sustav u kojem je značajna količina viška proizvodnje zahtijevat će manje ponovnog punjenja (baterije će se puniti do kraja), nego sustav u kojem je višak proizvodnje nizak. Potrebni sati za ponovno punjenje traže se na temelju pokušaja i pogreške. Model pokreće proračun osiguravajući da je zadovoljeno minimalno potrebno punjenje baterije kako bi osiguralo vožnju za narednih nekoliko sati i ako to rezultira manjkom napunjenosti baterije,

broj se podiže na dva i tako dalje. Broj sati postaje rezultat proračuna. U optimiziranom sustavu kontrole električne energije, broj sati koji su prioritet za vožnju, može također biti određen pomoću vremenske prognoze s obzirom na predviđeni vjetar za sljedećih nekoliko sati. Taj odnos se ovdje ne uzima u obzir.

Model izvodi proračun za svaki sat. V2G vozila su određena da se pune u vrijeme dostupnog viška proizvodnje električne energije, e_{CEEP}, i raspoloživog kapaciteta baterije, $S_{V2G-Battery}$ - $s_{V2G-Battery}$, unutar granica opterećenja priključka na mrežu, c_{V2G}, za svaki određeni sat.

Stoga formula koristi minimum sve tri vrijednosti:

$$e_{Charge} = min\left[e_{CEEP}, (S_{V2G-Battery} - s_{V2G-Battery})/\mu_{Charge,} c_{V2G}\right] \quad (33)$$

Između ostalog, kako je prethodno spomenuto, punjenje je prisilno u slučaju kada trenutna potrošnja energije u transportu i u sljedećim "y" satima ne može biti zadovoljena sa sadržajem baterije. U početku, "y" vrijednost je postavljena za jedan sat. Ako to dovede do manjka količine energije u bateriji, vrijednost se povećava u koracima od jednog sata.

Minimalna količina energije u bateriji računa se:

$$s_{V2G-Battery-min} = \sum_{a+y}^{x=a} t_{V2G} \quad (34)$$

Prema tome je punjenje baterije postavljeno na način da zahtjeva:

$$e_{Charge} \geq \left[s_{V2G-Battery} - s_{V2G-Battery-min}\right]/\mu_{Charge} \quad (35)$$

Ako e_{Charge} bude veće od vrijednosti opterećenja priključka na mrežu, c_{V2G}, broj sati, y, se poveća za jedan i računanje se ponovno pokreće. Novi sadržaj baterije se računa dodavanjem gore izračunatog punjenja i umanjuje za pražnjenje uzrokovano vožnjom, t_{V2G}:

$$s_{V2G-Battery} = s_{V2G-Battery} - t_{V2G} + (e_{Charge} \cdot \mu_{Charge}) \quad (36)$$

V2G vozila opskrbljuju mrežu u slučaju moguće zamjene proizvodnje iz elektrana, e_{PP}, i kao dostupna energija u baterijama koja se pohranjuje nakon zadovoljenja potrošnje energije tijekom vožnje:

$$e_{Inv} = min\left[e_{PP}, \left(\left(s_{V2G-Battery} - s_{V2G-Battery-min}\right) \cdot \mu_{Inv}\right), c_{V2G}\right] \quad (37)$$

Rezultat novog sadržaja baterije se računa na sljedeći način:

$$s_{V2G-Battery} = s_{V2G-Battery} - (e_{Inv}/\mu_{Inv}) \quad (38)$$

Zbog razlika u sadržaju baterije na početku i na kraju perioda proračuna (jedna godina), mogu se pojaviti greške u proračunu. Da bi se one ispravile, gornja formula se ponavlja sve dok sadržaj spremnika na kraju bude jednak onom na početku. U početku, spremnik je definiran s 50% kapaciteta spremnika baterije. Nakon prvog proračuna određen je novi početni sadržaj definiran rezultatom sadržaja na kraju proračuna. Procedura se ponavlja dok razlika postane neznatna.

Simulacijska strategija regulacije V2G modela u EnergyPLAN-u odabrana je na način da V2G model regulacije punjenja i pražnjenja EV radi u cilju balansiranja proizvodnje električne energije iz OIE i ukupnog uvoz i izvoza.

2.12 Integracija transportnog i toplinskog sektora 100% obnovljivog šireg gradskog područja

Transportni i toplinski sektor nude mnoge mogućnosti za dodatne izvore fleksibilnosti unutar EES ukoliko se njihova opskrba temelji na električnoj energiji proizvedenoj iz OIE. U transportnom sektoru izvori fleksibilnosti su EV koja koriste električnu energiju iz OIE. Osim dodatnih potrošača predstavljaju i skladišta električne energije korisna za skladištenje viška proizvedene energije u sustavu. U toplinskom sektoru to su prvenstveno DT koje za svoj rad koriste električnu energiju OIE kao potrošači u sustavu. Smatraju se OIE jer su im izvor i/ili ponor topline OIE. U kombinaciji s dodatnim TES ili BES mogu sudjelovati i u skladištenju viškova električne energije proizvedene iz OIE. Cilj integracije dvaju sektora i dodavanje sudionika u sustav, kao što su dodatni skladišni kapaciteti i povezivanje sa tržištem električne energije, jest pokazati mogućnost integracije 100% OIE u proizvodnji električne energije u sustavu. To će se očitovati u smanjenju uvoznih i izvoznih kapaciteta i postizanju samodostatnosti energetskog sustava energetskim planom do 2050. godine.

2.12.1 Izrada energetskog plana samodostatnog šireg gradskog područja do 2050. godine nadogradnjom novog modela u programu Calliope

Integracija transportnog i toplinskog sektora odabranog područja izrađena je i analizirana u programu Calliope [184]. Calliope predstavlja temeljni okvir za izgradnju modela energetskog sustava. Dizajniran je za analizu sustava s proizvoljno visokom prostornom i vremenskom razlučivosti. Koristi matematičke formulacije neovisne o prostornoj i vremenskoj skali koja dopušta analize u rasponu od pojedinačnih urbanih središta do država i kontinenata. Bazira se na modeliranju energetskih čvorova, uzimajući u obzir i druge nositelje energije osim električne energije. Ključne značajke programa Calliope uključuju sposobnost rukovanja visokom prostornom i vremenskom razlučivosti i jednostavnog rada na računalnim sustavima

visokog učinka. Njegov dizajn jasno razdvaja opći okvir (kod) od modela (podataka) specifičnog za promatrani problem. Pruža i sučelje naredbenog retka i API za programsku upotrebu. Calliope model sastoji se od skupa YAML i CSV datoteka koje definiraju tehnologije, lokacije, veze između lokacija, potencijale izvora energije i druga ograničenja. Calliope koristi te datoteke, konstruira problem optimizacije, rješava ga i izvješćuje o rezultatima u obliku skupova podataka *"xarray"*, koji se lako mogu spremiti u NetCDF datoteke za daljnju obradu. Koristi Pyomo kao pozadinu za sučelje s otvorenim i komercijalnim algoritmima, trenutno rješavajući mješovito cjelobrojno linearno programiranje. Iako se i nelinearne komponente mogu implementirati ako je to potrebno za nove vrste problema. Calliope-ovi ugrađeni alati omogućuju interaktivno istraživanje rezultata pomoću Plotly-ja. Calliope je korišten u različitim studijama kao što su analize nacionalnih elektroenergetskih sustava u Britaniji i Južnoj Africi, te za analize manjeg energetskog sustava na razini okruga [184]. Program Calliope navedenim karakteristikama predstavlja odgovarajući odabir za analize u ovom radu.

Dosadašnja literatura je pokazala da energetski sustavi s visokim udjelom OIE u proizvodnji električne energije zahtijevaju dodatne izvore fleksibilnosti u sustavu kako bi bili održivi. Obnovljivi energetski sustavi imaju neznatan negativan utjecaj na okoliš u odnosu na sustave koji koriste fosilne izvore energije u proizvodnji i potrošnji energije. Fosilni izvori energije predstavljaju veliku globalnu ugrozu za okoliš i njegove stanovnike, stoga je opravdano nastojanje da ih se zamijeni OIE. Međutim, zamjena izvora energije zahtjeva velike napore i dodatna istraživanja kako bi ona bila održiva i u konačnici isplativa. Javljaju se složeni problemi u sustavu zbog isprekidane proizvodnje električne energije iz OIE. Ona stvara velike viškove ili manjak proizvodnje koji rezultiraju dugoročnom neodrživošću. Stoga je potrebno pomno planirati energetski sustav i analizirati sve sudionike u sustavu kako bi se postigla što veća fleksibilnost. Time će se omogućiti reguliranje energetski tokova na održiv način. Takav sustav zahtjeva integraciju i komunikaciju među svim sudionicima u sustavu. Njih je potrebno regulirati u cilju najboljeg iskorištenja svih izvor fleksibilnosti koji u sustavu postoje ili ih je potrebno sustavu dodati.

Pretpostavka u ovom radu, za energetski plan odabranog područja, jest da će integracija transportnog i toplinskog sektora s dodatnim skladišnim kapacitetima, brzim punjenjem EV i varijabilnim cijenama na tržištu električne energije, baziranim na 10-minutnom vremenskom koraku, otvoriti više mogućnosti za bolju integraciju OIE u sustav. Regulacijom energetskih tokova moguće je postići najbolju iskoristivost izvora fleksibilnosti u sustavu u cilju održivosti. Regulacija energetskih tokova u ovom radu izvest će se varijabilnim cijenama električne

energije koje će potaknuti sudionike energetskog sustav na aktivno sudjelovanje u sustavu. U energetskim sustavima s visokim udjelom OIE u proizvodnji energije, potražnju za električnom energijom potrebno je pokušati prilagoditi ponudi, odnosno proizvodnji iz OIE. To se može postići ukoliko svi sudionici aktivno sudjeluju u sustavu i budu stimulirani cijenom električne energije. To zahtjeva varijabilne cijene na tržištu električne energije. Potrebno je prilikom izrade energetskog plana, težiti samodostatnosti i održivosti energetskog sustava, uz otvoreno tržište električnom energijom između više manjih ili većih susjednih sustava.

Dio energetskog plana odabranog šireg gradskog područja prethodno je modeliran i analiziran u radu kroz razvoj novog algoritma. Njime se pokušalo dokazati da brzo punjenje i pražnjenje EV, modelom V2G, u sustavu modeliranom za kraći vremenski korak od 10 minuta i regulirano je modelom varijabilnih cijena električne energije, pruža više mogućnosti kao dodatni izvor fleksibilnosti u sustavu za bolju integraciju 100% udjela OIE u proizvodnji električne energije. Novi algoritam je uspoređen i validiran s programom EnergyPLAN. Integracija svih sudionika i energetski plan odabranog područja do 2050. modeliran je i analiziran u programu Calliope. Program Calliope odabran je jer nudi više mogućnosti prilikom izrade energetskog plana, a posebice jer nudi mogućnost odabira vremenskog koraka u proračunima. EnergyPLAN radi na satnoj bazi unosa podataka, pa je zbog tog nedostatka isključen kao mogućnost za izradu daljnjih proračuna. Novi algoritam je razvijen i razrađen za satni i 10 minutni vremenski korak uz primjenu V2G modela EV i modela regulacije energetskih tokova varijabilnim cijenama električne energije. Za daljnje širenje sustava potrebno je još rada na algoritmu i daljnji razvoj. Za potrebe ovoga rada odabran je program Calliope. U njemu se nadogradio novi model i izradio energetski plan odabranog područja do 2050. godine s izdvojenim scenarijima. Calliope je također potrebno prethodno usporediti i validirati s novim razvijenim algoritmom kako bi se izradio daljnji proračun šireg gradskog područja.

2.12.1.1 Usporedba novog algoritma s programom Calliope

Usporedba novog modela i Calliope-a napravljena je na temelju rezultata jednoga dana zime, treća srijeda u siječnju, i godišnjih rezultata za scenarij S1 za 2050. godinu i vremenski korak od 1 sat i 10 minuta. Ulazni podaci za Calliope jednaki su onima za novi algoritam za scenarij S1 za 2050. godinu i za oba vremenska koraka. Ulazne podatke za 10-minutni model bilo je potrebno prilagoditi proračunima, stoga su se kapaciteti odabranih tehnologija, kao i ostale karakteristike i vrijednosti, unosili u vrijednostima koje su u iznosu 6 puta većem od satnih. Razlog tome je što satni model koristi distribucije od 8760 podataka na godišnjoj razini,

dok 10-minutni model koristi njih 6 puta više, odnosno 52560 podataka po distribuciji. Shodno tome, vrijednosti rezultata su također dobivene na 10-minutnom nivou. Te vrijednosti je bilo potrebno umanjiti i svesti na satne vrijednosti, u svrhu usporedbe rezultata 10-minutnog i satnog modela. Takvo prilagođavanje podataka zahtijevalo je dodatni napor pri izradi proračuna. Sustav se sastoji od proizvodnje električne energije iz OIE, potrošnje električne energije i EV kao potrošača i skladišta električne energije, a s primjenom modela V2G i proizvođača električne energije. Proizvodnja uključuje proizvodnju iz VE i SE, planiranu do 2050. godine. Potrošnja električne energije uključuje potrošnju preuzetu s TS Komolac i planiranu do 2050. godine. EV uključuju potrošnju uslijed vožnje koja je zadana krivuljom potrošnje. Punjenje EV uspoređeno je za neregulirani i regulirani sustav punjenja EV. Neregulirani sustav uključuje samo punjenje EV kako bi se zadovoljila potrošnja energije uslijed vožnje. To punjenje predstavlja vozila koja se pune iz mreže zbog potrošnje uslijed vožnje i označena su kao G2V vozila. Regulirani sustav uključuje model V2G, u kojem se vozila pune u vrijeme viška proizvodnje iz OIE (G2V), a prazne (V2G) u vrijeme manjka proizvodnje električne energije iz OIE.

Jednostavni model odabranog sustava u programu Calliope, koji je služio za usporedbu i validaciju novog algoritma, prikazuje [Slika 28]. Slika prikazuje tri lokacije. Lokacija X1 obuhvaća: opću potrošnju električne energije odabranog područja, preuzetu s TS Komolac; potrošnju EV uslijed vožnje; proizvodnju FN sustava na krovovima kuća i SE na tlu, BEV koja obuhvaća sva EV, G2V vozila koja se pune i V2G vozila koja se prazne. Opća potrošnja određena je krivuljom potrošnje kao i potrošnja EV uslijed vožnje. FN sustavi na krovovima i SE na tlu su u ovom slučaju sastavljeni u zajedničku proizvodnju i određeni su instaliranim kapacitetom i krivuljom proizvodnje električne energije. Baterija EV obuhvaća sva EV u jednu veliku integriranu bateriju koja je određena ukupnim maksimalnim kapacitetom baterije svih vozila. U nereguliranom sustavu lokacija X1 ne obuhvaća model V2G vozila, već samo G2V vozila koja se pune u cilju zadovoljenja potrošnje energije iz baterije na vožnju. U reguliranom sustavu uključena su i V2G vozila, koja uz punjenje uključuju i pražnjenje baterije u cilju smanjenja uvoza. G2V i V2G su određene maksimalnim kapacitetom punjenja i pražnjenja u jednom vremenskom koraku i efikasnošću punjenja i pražnjenja koja iznosi 95%, kao u prethodnim scenarijima. Lokacija X2 obuhvaća VE Mravinjac i VE Konavoska brda, čija proizvodnja je objedinjena i stavljena pod istu lokaciju. VE su određene instaliranim kapacitetom i krivuljom proizvodnje električne energije. Lokacija X3 predstavlja susjedni energetski sustav s kojim se vrši trgovanje električnom energijom, odnosno uvoz i izvoz električne energije. Ona je određena maksimalnim opterećenjem prijenosa električne energije.

Distribucijska mreža električne energije povezuje međusobno tri lokacije i njome se vrši opskrba potrošnje električne energije i izvoz. Određena je također maksimalnim opterećenjem prijenosa električne energije.

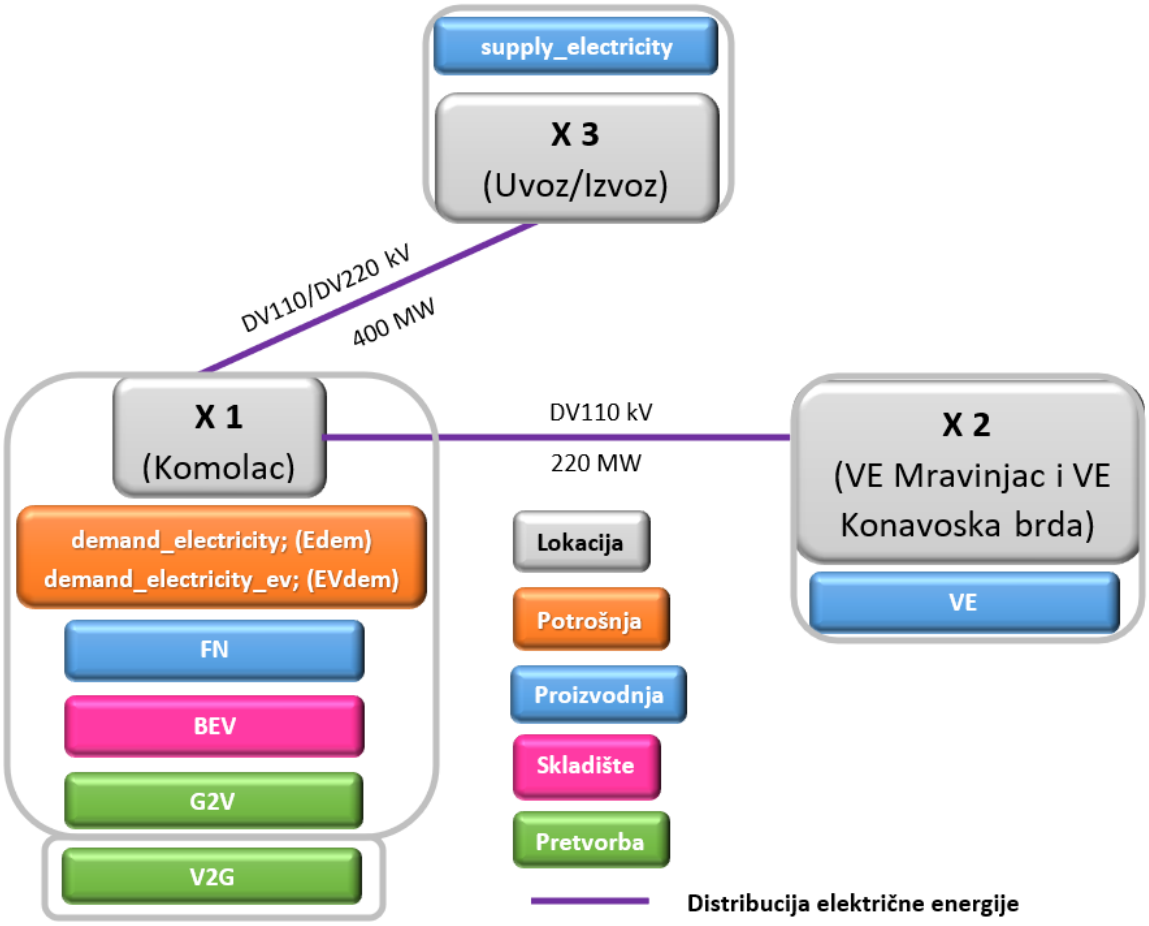

Slika 28. Model energetskog sustava odabranog područja u programu Calliope prema scenariju S1

Kao još jedan od doprinosa ovog rada, može se izdvojiti i razvijeni V2G model u programu Calliope, koji do sada nije bio izrađen u tom programu. Razvio se V2G model EV za potrebe ovog rada, baziran na satnom i 10-minutnom vremenskom koraku. Opisan je u nastavku, a kod cjelokupnog energetskog sustav dan je u [PRILOG]. U novom algoritmu, punjenje EV u nereguliranom sustavu ($E_{EV,dem,i}$) radilo je na način da se vozila pune u svakom vremenskom koraku za iznos potrošnje baterije koja se ispraznila u prethodnom vremenskom koraku uslijed vožnje iz prethodnog vremenskog koraka ($E_{EV,dem,i+1}$). U Calliope-u, za razliku od novog algoritma, punjenje vozila u nereguliranom sustavu radi na način da i to punjenje regulira tako da se vozila pune uvijek u vrijeme viška proizvodnje električne energije. Ta energija se skladišti u baterijama EV i troši na vožnju u sljedećim koracima. Punjenje EV označeno je s G2V, a pražnjenje uslijed vožnje s EVdem. G2V vozila, koja su na raspolaganju

za punjenje u svakom vremenskom koraku, ovise o maksimalnom priključnom kapacitetu baterije u jednom vremenskom koraku, kapacitetu baterije iz prethodnog koraka i vozilima koja se voze u tom koraku. Iznos opterećenja od vozila, koja su na raspolaganju za punjenje u svakom vremenskom trenutku, računa se prema jednadžbi (39). Maksimalni kapacitet punjenja, u svakom vremenskom trenutku, dat je izrazom u (40). On predstavlja maksimalno raspoloživu bateriju svih EV za punjenje koja ne uključuje vozila koja se voze u tom trenutku, $E_{EV,dem,i}$. Broj vozila koja se voze u svakom trenutku mijenja se prema zadanoj krivulji. Broj tih vozila je objedinjen postotkom i za svaki korak je jednak i iznosi 8% pa raspoloživa baterija iznosi 92% maksimalnog kapaciteta u svakom vremenskom trenutku, $e_{max,i}$. Taj postotak maksimalno raspoložive baterije u svakom vremenskom trenutku uzet jednako kao u EnergyPLAN-u, kao fiksan podatak. U novom algoritmu se maksimalno raspoloživa baterija mijenja u svakom koraku i ovisi o zauzetim vozilima koja se voze u tom trenutku, a zadana su prema prethodno modeliranoj distribuciji potrošnje energije uslijed vožnje.

$$E_{G2V,i} = E_{batt,max,i} - E_{EV,dem,i} - E_{batt,i-1} \tag{39}$$

$$E_{G2V,max,i} = E_{batt,max,i} - E_{EV,dem,i} = E_{batt,max,i} \cdot e_{max,i} \tag{40}$$

U reguliranom sustavu dodao se model V2G, gdje regulacija ide u smjeru smanjenja uvoza i izvoza u sustavu. Vozila se pune u vrijeme viška proizvodnje električne energije, u cilju smanjenja izvoza, a prazne u vrijeme manjka proizvodnje u cilju smanjenja uvoza. Vozila koja se pune, G2V, određena su formulama (39) i (40), a vozila koja se prazne, V2G, određena su formulama (41) i (42). Jednadžbom (41) računaju se vozila koja su raspoloživa za pražnjenje u svakom vremenskom trenutku. Jednadžbom (42) dan je izraz za maksimalno raspoloživu bateriju za pražnjenje u svakom vremenskom trenutku.

$$E_{V2G,i} = (E_{batt,i-1} - E_{EV,dem,i}) \cdot \eta_{disch} \tag{41}$$

$$E_{V2G,max,i} = (E_{batt,max,i} - E_{EV,dem,i}) \cdot \eta_{disch} = E_{batt,max,i} \cdot e_{max,i} \cdot \eta_{disch} \tag{42}$$

Kapacitet baterije u svakom koraku računa se prema jednadžbi za neregulirani sustav (43), dok je za regulirani u jednadžbu samo dodan V2G u jednadžbi (44). Maksimalni mogući kapacitet baterije jednak je ukupnom kapacitetu baterija svih EV i prikazan je jednadžbom (45).

$$E_{batt,i} = E_{batt,i-1} + E_{G2V,i} - E_{EV,dem,i} \tag{43}$$

$$E_{batt,i} = E_{batt,i-1} + E_{G2V,i} - E_{EV,dem,i} - \frac{E_{V2G,i}}{\eta_{disch}} \tag{44}$$

$$E_{batt,max} = E_{batt,uk} \tag{45}$$

[Slika 29] daje prikaz energetskih tokova u bateriju i iz baterije, odnosno punjenja i pražnjenja baterije. Siva linija obuhvaća tokove u nereguliranom sustavu, dok regulirani sustav ima i V2G vozila s pražnjenjem u mrežu. G2V i V2G predstavljaju pretvorbu energije iz energije mreže, *electricity*, u energiju baterije, *electricity_ev*, prilikom punjenja i obratno za pražnjenje.

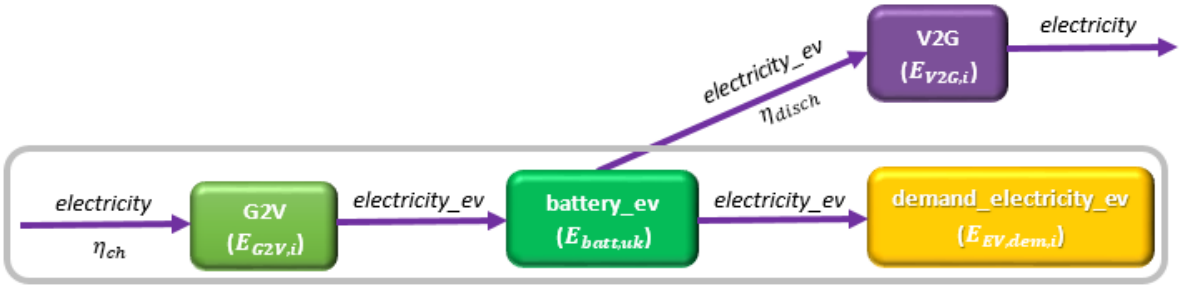

Slika 29. Energetski tokovi baterije EV – punjenje i pražnjenje baterije

Ravnoteža sustava računa se prema jednadžbi (46) i vrijedi za neregulirani sustav, dok je za regulirani sustav dodan još V2G u jednadžbi (47).

$$E_{RES,i} - E_{EV,dem,i} - E_{dem,i} - \frac{E_{G2V,i}}{\eta_{ch}} + E_{IMP,i} - E_{EXP,i} = 0 \tag{46}$$

$$E_{RES,i} - E_{EV,dem,i} - E_{dem,i} - \frac{E_{G2V,i}}{\eta_{ch}} + E_{IMP,i} - E_{EXP,i} + E_{V2G,i} = 0 \tag{47}$$

2.12.1.2 Modeliranje 100% obnovljivog energetskog sustava šireg gradskog područja do 2050. godine

U energetskom planu odabranog energetskog sustava šireg gradskog područja grada Dubrovnika određeno je da će sustav do 2050. godine biti 100% obnovljiv. Proizvodnja električne energije bit će 100% obnovljiva i uključuje proizvodnju iz HE Dubrovnik, VE, SE i FN sustava na krovovima objekata. Potrošnja električne energije uključuje opću potrošnju električne energije na odabranom području, toplinske i rashladne potrebe za energijom i potrošnju EV. Dodani su i dodatni spremnici energije kao izvori fleksibilnosti u sustavu. Mobilni spremnici odnose se na BEV u vozilima, a od stacionarnih spremnika dodane su B2U, SEV, TES i RES. Svaka tehnologija je određena s potrebnim podacima i cijenama energije i sustav je spojen na susjedno tržište električnom energijom. Proračuni su izrađeni za vremenski korak od 1 sat i 10 minuta.

Na [Slika 30] prikazan je model 100% obnovljivog energetskog sustava odabranog šireg gradskog područja za 2050. godinu za program Calliope. Prikazani su svi sudionici sustava, odabrane lokacije i elektroenergetske veze između lokacija. U modelu je određeno pet lokacija koje su međusobno povezane DV, od kojih su neki postojeći a neki planirani.

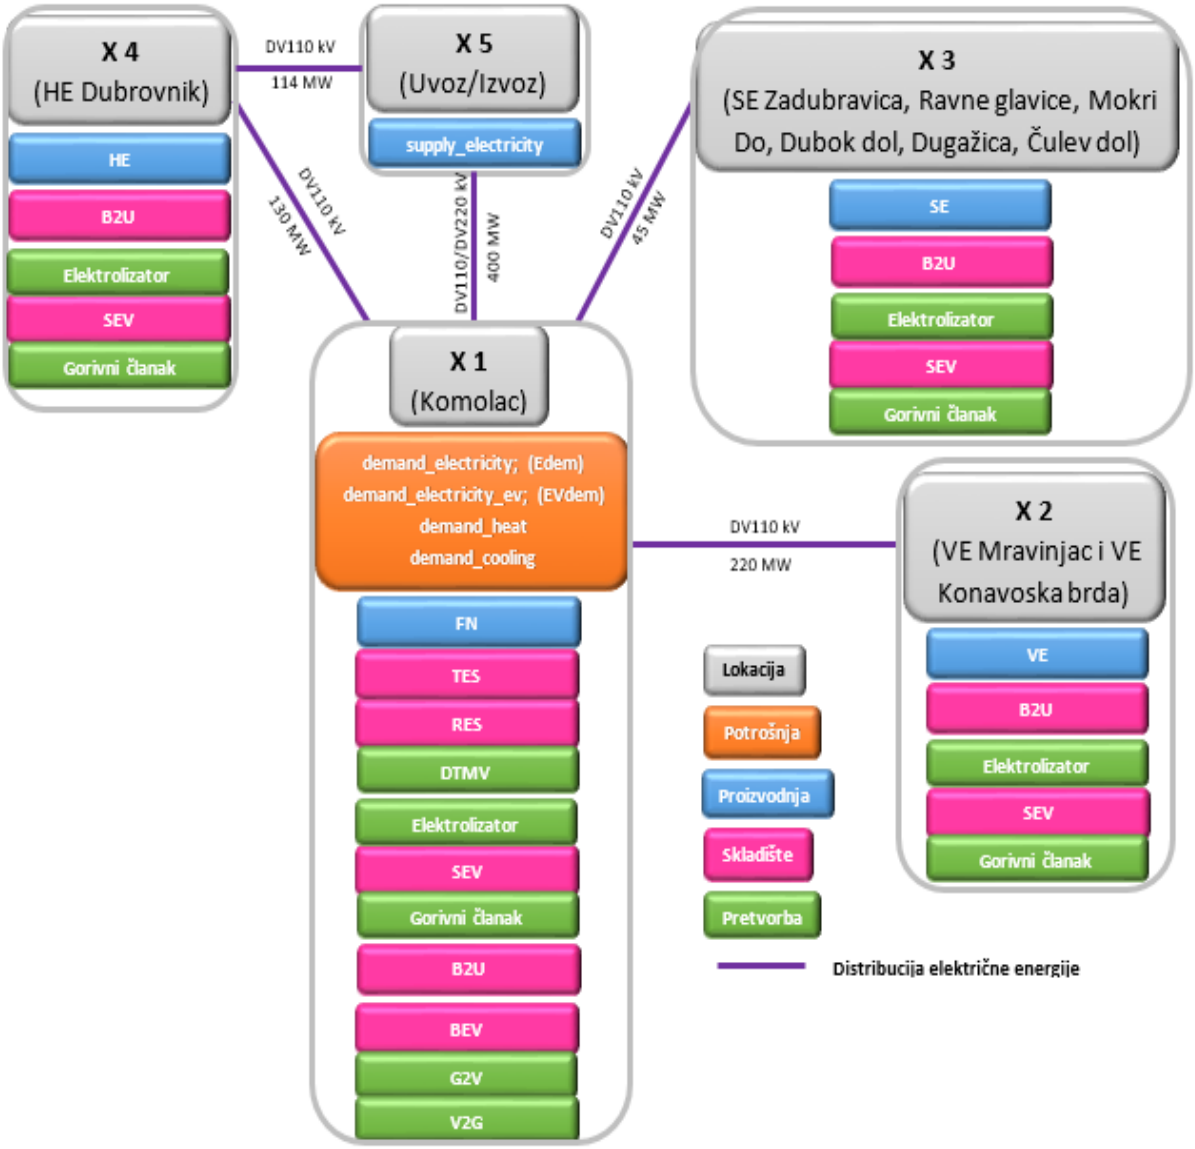

Slika 30. Model 100% obnovljivog energetskog sustava šireg gradskog područja do 2050. godine u programu Calliope

Za lokaciju X1 odabrana je TS Komolac. U nju su uključeni svi sudionici sustava koji se nalaze na odabranom području, od potrošnje, proizvodnje i spremnika električne energije. Potrošnja električne energije označena je narančastom bojom. Uključuje opću potrošnju sa TS Komolac, potrebe za toplinskom i rashladnom energijom i potrošnju uslijed korištenja EV. Od proizvodnje električne energije, u lokaciju X1 uvršteni su samo FN sustavi na krovovima objekata u ukupnom iznosu od 41 MW instalirane snage. Ostatak proizvodnje energije iz

Sunca, sa instaliranom snagom od ukupno 44 MW, odnosi se na planirane SE na tlu koje su objedinjene u lokaciji X3. Za snabdijevanje toplinskih i rashladnih potreba, dijelom se koristi električna energija s klimatizacijskim sustavima a dijelom sustavi s DTMV s TES i RES. EV uređena su modelom V2G, gdje varijabla G2V označava vozila koja se pune iz mreže a varijabla V2G vozila koja se prazne u mrežu s BEV kao spremnikom energije. B2U i SEV sustav, s gorivnim člancima i elektrolizatorima, služe kao spremnici energije. Energija se u vrijeme viška proizvodnje električne energije iz mreže skladišti i ponovno vraća u mrežu u vrijeme manjka proizvodnje električne energije u cilju smanjenja troška i uvoza i izvoza energije u sustavu. Spremnici energije označeni su zelenom bojom, dok su dijelovi sustava u kojima se vrši pretvorba energije, označeni ružičastom bojom. B2U i sustav SEV su raspodijeljeni na lokacije X1, X2, X3 i X4 u jednakim omjerima. Na lokacijama X2, X3 i X4 smješteni su proizvodni sustavi električne energije, VE, SE i HE. Proizvodni kapaciteti označeni su plavom bojom. Sve tri lokacije spojene su s lokacijom X1 na TS Komolac. Lokacija X1 spojena je na X5, koja označava točku uvoza i izvoza, gdje je više veza spojeno u jednu u iznosu od 400 MW. HE Dubrovnik također je spojena na lokaciju X5. Lokacija X5 predstavlja točku susjednog tržišta električnom energijom i uključuje cijene varijabilnog tržišta električnom energijom, prema podacima cijena s CROPEX-a za 2018. godinu.

2.12.2 Tržišno vrednovanje izvora fleksibilnosti u sustavu

Program Calliope odabran je kao računalni alat za izradu energetskog plana odabranog šireg gradskog područja jer pruža mogućnost proračuna za različite vremenske korake. Daje mogućnost upravljanja energetskim tokovima unutar sustava pomoću cijena električne energije i povezivanjem sa susjednim tržištima. Pruža mogućnost detaljne analize rada energetskog sustava i opširne rezultate. Kao takav odgovara analizama koje su zahtijevane u radu. Calliope radi u cilju minimiziranja troška energije u sustavu, pa je stoga potrebno odrediti cijene energije za sve sudionike u sustavu, potrošače, proizvođače i skladišta energije. Cijene i podaci o tehnologiji za sve sudionike preuzete su sa internetske stranice Danske energetske agencije (*"Danish Energy Agency"*) s projekcijama za 2050. godinu [185]. Cijene svih sudionika kao i podaci o tehnologiji prikazani su u modelu koji je dat u [PRILOG 1]. Prema cijenama i podacima o tehnologiji, program odlučuje hoće li energiju koristiti u cilju minimiziranja troška. Ukoliko je tehnologija skupa i neefikasna sustav je ne koristi ili koristi u maloj mjeri. Stoga će se ispitati koje tehnologije su za sustav isplative i koji scenarij pruža bolje mogućnosti za integraciju OIE u sustav.

3 REZULTATI

Rezultati analiza podijeljeni su u četiri grupe. Prva se odnosi na rezultate analize linearne korelacije i regresije. Druga grupa odnosi se na rezultate analize sustava DGH s DTMV i TES i BES za područje Starog grada, kao izdvojene cjeline šireg gradskog područja, korištene za detaljniju analizu elektrifikacije toplinskog sektora. Treća grupa obuhvaća analize elektrifikacije transportnog sektora u novom modelu i usporedbu s EnergPLAN modelom. Četvrta grupa odnosi se na rezultate analiza u modelu Calliope, koji je odabran za nadogradnju novog modela u svrhu postizanja samodostatnog 100% obnovljivog šireg gradskog područja. Obuhvaća usporedbu i validaciju rezultata novog modela i programa Calliope.

3.1 Linearne korelacijske i regresijske veze između parametara

Analiza linearne korelacije i regresije za odabrani skup podataka izrađena je na temelju srednjih mjesečnih vrijednosti odabranih podataka i za vremenski korak od 10 minuta, kako je to objašnjeno u odjeljku 2.7. Rezultati i usporedbe rezultata daju uvid u moguće prognoze i odnose proizvodnje električne energije iz OIE i potrošnje električne energije na temelju poznatih podataka o sunčevom zračenju, brzini vjetra, temperaturi zraka i potrošnji električne energije za odabrano područje. Podaci su analizirani za tri uzastopne godine 2012., 2013. i 2014. godinu. Rezultati analiza izneseni su u nastavku. Opširniji podaci i rezultati objavljeni su u radu [186].

3.1.1 Rezultati analiza prve grupe podataka za vremenski korak od 10 minuta i razdoblje od tri uzastopne godine

Proračuni za prvu grupu podataka podijeljeni su u 4 dijela i analiziraju vezu između tri uzastopne godine za svaku pojedinu vrstu odabranih podataka. Analiza je izvedena za sunčevo zračenje, brzinu vjetra, vanjsku temperaturu zraka i potrošnju električne energije za odabrano područje. Podaci su se temeljili na vremenskom koraku od 10 minuta za cijelu godinu. Rezultati analize prikazani su u [Tablica 30], gdje su dane vrijednosti r, r^2, a i b, za svaki od odabranih parametara između uzastopnih godina. Na temelju rezultata može se zapisati linearna regresijska veza prema jednadžbi na [Slika 17].

Varijable x i y, u jednadžbi linearne regresije mogu se zamijeniti s potražnjom za električnom energijom, E_n, sunčevim zračenjem, I_n, temperaturom zraka, T_n, i brzinom vjetra, V_n. Indeks n označava pripadnost podataka određenoj godini i ima isto značenje u sljedećim jednadžbama. Vrijednost N predstavlja broj podataka korištenih u analizi. U rezultatima su prikazane i vrijednosti koeficijenta korelacije, r, između dvije varijable x i y, kao i koeficijenta

determinacije, r^2. Konstanta *a* i koeficijent regresije *b*, u jednadžbi linearne regresije, prikazani su za slučaj kada je *y* ovisna varijabla ili *x* ovisna varijabla.

Tablica 30. Rezultati analize prve grupe podataka za uzastopne tri godine za vremenski korak od 10 minuta

x, y	**Srednja vrijednost**	**Std.Dv.**	*r(x,y)*	r^2	*p*	*N*	*a; y*	*b; y*	*a; x*	*b; x*
Potrošnja električne energije										
E_{2012}	38219,50	10661,31								
E_{2013}	33931,98	8930,11	0,851455	0,724976	0,00	52560	6674,044	0,713195	3726,995	1,016519
E_{2012}	38219,50	10661,31								
E_{2014}	28474,17	7059,98	0,838916	0,703779	0,00	52560	7241,920	0,555535	2146,973	1,266851
E_{2013}	33931,98	8930,11								
E_{2014}	28474,17	7059,98	0,791839	0,627009	0,00	52560	7232,307	0,626013	5412,514	1,001591
Sunčevo zračenje										
I_{2012}	106,5377	162,3647								
I_{2013}	103,1322	161,0447	0,828616	0,686605	0,00	34822	15,57103	0,821880	20,38026	0,835408
I_{2012}	106,5377	162,3647								
I_{2014}	97,8802	158,2237	0,817296	0,667972	0,00	34822	13,02809	0,796451	24,44705	0,838685
I_{2013}	103,1322	161,0447								
I_{2014}	97,8802	158,2237	0,768492	0,590580	0,00	34822	20,01220	0,755030	26,57099	0,782194
Vanjska temperatura zraka										
T_{2012}	17,16265	7,483789								
T_{2013}	17,19362	6,473829	0,872629	0,761481	0,00	48667	4,23814	0,754865	-0,18167	1,008764
T_{2012}	17,16265	7,483789								
T_{2014}	17,14066	5,622084	0,810729	0,657282	0,00	48667	6,68778	0,609048	-1,33547	1,079195
T_{2013}	17,19362	6,473829								
T_{2014}	17,14066	5,622084	0,794331	0,630962	0,00	48667	5,28010	0,689823	1,51554	0,914672
Brzina vjetra										
V_{2012}	3,552737	3,137801								
V_{2013}	3,774814	3,369657	0,103533	0,010719	0,00	47248	3,379809	0,111183	3,188810	0,096409
V_{2012}	3,552737	3,137801								
V_{2014}	3,746781	3,135703	0,149070	0,022222	0,00	47248	3,217529	0,148970	2,993831	0,149170
V_{2013}	3,774814	3,369657								
V_{2014}	3,746781	3,135703	0,072837	0,005305	0,00	47248	3,490923	0,067780	3,481547	0,078272

Jednadžba linearne regresije između varijabli *x* i *y* može se zapisati unošenjem vrijednosti konstante *a* i regresijskog koeficijenta *b*. Rezultati analiza usporedbe pojedinih varijabli ukazuju na značajnu vezu između varijabli gdje je $p < 0,05$. To znači da postoji značajna vjerojatnost da se, promatrana veza među varijablama u odabranom uzorku, može pokazati kao pouzdan pokazatelja veze između tih varijabli u ukupnoj populaciji. Vrijednost koeficijenta korelacije ukazuje na značajnu linearnu vezu između varijabli E_n, I_n and T_n, što znači da njihova raspodjela na 10-minutnom vremenskom neznatno odstupa u uzastopnom

periodu od tri godine i može se predvidjeti za buduće razdoblje korištenjem jednadžbe linearne korelacije. Koeficijent korelacije za V_n distribuciju je blizu 0, što znači da je brzinu vjetra teško predvidjeti za buduće razdoblje, korištenjem jednadžbe linearne korelacije, jer podaci značajno variraju između odabranih godina.

3.1.2 Rezultati analize druge grupe podataka koje se temelje na srednjim mjesečnim vrijednostima

Analiza druge grupe podataka izvedena je za svaku godinu zasebno kako bi se utvrdilo postojanje linearne veze između parametara o potrošnji električne energije, sunčevom zračenju, brzini vjetra i temperaturi zraka unutar godine. Vrijednosti podataka se odnose na srednje mjesečne vrijednosti za svaki parametar i rezultati su prikazani u [Tablica 31]. Ova analiza se provela kako bi se dala usporedba s prethodnim studijama i njihovim rezultatima. Rezultati u [Tablica 31], koji nisu istaknuti crvenom bojom, ukazuju da nema linearne veze između varijabli jer je $p > 0,05$.

Rezultati korelacije između E_{2014} i T_{2014} i između E_{2014} i I_{2014} ukazuju na postojanje linearne veze između varijabli i istaknuti su crvenom bojom u tablici. Prethodna studija, koja analizira slučaj Brazila [61], pokazala je da je $r = 0,46$ između varijabli E i I, dok je između E i V $r = 0,29$. Analiza linearne korelacije i regresije među varijablama T_n i I_n, T_n i V_n, i V_n i I_n, također je rezultirala postojanjem značajne veze među varijablama. U radu [57], koji je analizirao slučaj Italije, uspoređene su se srednje mjesečne vrijednosti varijabli V i I gdje su rezultati pokazali da koeficijent korelacije doseže vrijednost nižu od -0,8 u nekoliko područja. Rezultati na razini cijele države imali su vrijednosti između -0,65 i -0,6, dok je vrijednost r bila više bliža 0 za srednje dnevne vrijednosti odabranih varijabli. Funkcija linearne regresije može se zapisati korištenjem jednadžbe linearne regresije i dobivenih rezultata.

Tablica 31. Rezultati analize druge grupe podataka koji se temelje na srednjim mjesečnim vrijednostima odabranih parametara

x, y	**Srednja vrijednost**	**Std.Dv.**	*r(x,y)*	r^2	*p*	*N*	*a; y*	*b; y*	*a; x*	*b; x*
2012										
E_{2012}	38221,26	6703,026								
T_{2012}	17,67	7,157	0,278244	0,077420	0,381196	12	6,32	0,00	33616,32	260,61
E_{2012}	38221,26	6703,026								
I_{2012}	113,13	57,820	0,323019	0,104341	0,305783	12	6,64	0,00	33984,69	37,45
E_{2012}	38221,26	6703,026								
V_{2012}	3,59	0,980	-0,264313	0,069862	0,406446	12	5,06	-0,00	44702,76	-1807,95
T_{2012}	17,67	7,157								
I_{2012}	113,13	57,820	0,794745	0,631620	0,002009	12	-0,32	6,42	6,54	0,10
T_{2012}	17,67	7,157								
V_{2012}	3,59	0,980	-0,834147	0,695801	0,000743	12	5,60	-0,11	39,51	-6,09
I_{2012}	113,13	57,820								
V_{2012}	3,59	0,980	-0,812641	0,660386	0,001315	12	5,14	-0,01	285,03	-47,95
2013										
E_{2013}	33945,51	5087,649								
T_{2013}	17,57	6,024	0,203949	0,041595	0,524908	12	9,37	0,00	30919,74	172,26
E_{2013}	33945,51	5087,649								
I_{2013}	114,51	61,956	0,459679	0,211304	0,132711	12	-75,51	0,01	29622,99	37,75
E_{2013}	33945,51	5087,649								
V_{2013}	3,80	1,068	-0,226821	0,051448	0,478368	12	5,42	-0,00	38051,79	-1080,36
T_{2013}	17,57	6,024								
I_{2013}	114,51	61,956	0,903236	0,815835	0,000057	12	-48,67	9,29	7,51	0,09
T_{2013}	17,57	6,024								
V_{2013}	3,80	1,068	-0,862404	0,743740	0,000307	12	6,49	-0,15	36,05	-4,86
I_{2013}	114,51	61,956								
V_{2013}	3,80	1,068	-0,841384	0,707928	0,000602	12	5,46	-0,01	300,00	-48,80
2014										
E_{2014}	28452,90	3654,105								
T_{2014}	17,52	5,100	0,774233	0,599436	0,003117	12	-13,23	0,00	18736,92	554,70
E_{2014}	28452,90	3654,105								
I_{2014}	104,55	55,722	0,637465	0,406361	0,025759	12	-172,04	0,01	24082,46	41,80
E_{2014}	28452,90	3654,105								
V_{2014}	3,74	0,987	-0,477260	0,227777	0,116651	12	7,41	-0,00	35068,73	-1767,76
T_{2014}	17,52	5,100								
I_{2014}	104,55	55,722	0,845374	0,714657	0,000534	12	-57,23	9,24	9,43	0,08
T_{2014}	17,52	5,100								
V_{2014}	3,74	0,987	-0,806156	0,649888	0,001541	12	6,47	-0,16	33,11	-4,17
I_{2014}	104,55	55,722								
V_{2014}	3,74	0,987	-0,863273	0,745241	0,000298	12	5,34	-0,02	287,03	-48,76

3.1.3 *Rezultati analize treće grupe podataka za 10-minutni vremenski korak*

Tablica 32. Rezultati analize treće grupe podataka čije se vrijednosti temelje na 10-minutnom vremenskom koraku

x, y	**Srednja vrijednost**	**Std.Dv.**	*r(x,y)*	r^2	*p*	*N*	*a; y*	*b; y*	*a; x*	*b; x*
A – 2012										
E_{2012}	36698,17	10309,57								
T_{2012}	17,55	6,83	0,207789	0,043176	0,000000	39188	12,50	0,000	31194,94	313,546
E_{2012}	36698,17	10309,57								
I_{2012}	114,88	170,03	0,238412	0,056840	0,000000	39188	-29,42	0,004	35037,46	14,455
E_{2012}	36698,17	10309,57								
V_{2012}	3,52	3,10	-0,033600	0,001129	0,000000	39188	3,89	-0,000	37091,70	-111,908
T_{2012}	17,55	6,83								
I_{2012}	114,88	170,03	0,457128	0,208966	0,000000	39188	-84,79	11,377	15,44	0,018
T_{2012}	17,55	6,83								
V_{2012}	3,52	3,10	-0,230647	0,053198	0,000000	39188	5,35	-0,104	19,34	-0,509
I_{2012}	114,88	170,03								
V_{2012}	3,52	3,10	-0,060655	0,003679	0,000000	39188	3,64	-0,001	126,60	-3,332
B – 2012										
E_{2012}	36672,83	10303,81								
T_{2012}	17,56	6,83	0,228995	0,052439	0,000000	39164	11,99	0,0002	30609,70	345,3601
E_{2012}	36672,83	10303,81								
I_{2012}	114,96	170,06	0,317798	0,100995	0,000000	39164	-77,40	0,0052	34459,38	19,2549
E_{2012}	36672,83	10303,81								
V_{2012}	3,52	3,10	-0,028810	0,000830	0,000000	39164	3,84	-0,0000	37010,14	-95,8866
T_{2012}	17,56	6,83								
I_{2012}	114,96	170,06	0,456913	0,208770	0,000000	39164	-84,72	11,3734	15,45	0,0184
T_{2012}	17,56	6,83								
V_{2012}	3,52	3,10	-0,231189	0,053448	0,000000	39164	5,36	-0,1048	19,35	-0,5102
I_{2012}	114,96	170,06								
V_{2012}	3,52	3,10	-0,060954	0,003715	0,000000	39164	3,65	-0,0011	126,73	-3,3483
A – 2013										
E_{2013}	34548,85	8804,062								
T_{2013}	17,09	6,683	0,154528	0,023879	0,000000	44189	13,03	0,0001	31070,40	203,5715
E_{2013}	34548,85	8804,062								
I_{2013}	112,82	170,496	0,263732	0,069554	0,000000	44189	-63,63	0,0051	33012,43	13,6186
E_{2013}	34548,85	8804,062								
V_{2013}	3,80	3,418	-0,018643	0,000348	0,000089	44189	4,05	-0,0000	34731,43	-48,0282
T_{2013}	17,09	6,683								
I_{2013}	112,82	170,496	0,482973	0,233262	0,000000	44189	-97,72	12,3215	14,95	0,0189
T_{2013}	17,09	6,683								
V_{2013}	3,80	3,418	-0,180600	0,032616	0,000000	44189	5,38	-0,0924	18,43	-0,3532
I_{2013}	112,82	170,496								
V_{2013}	3,80	3,418	-0,116038	0,013465	0,000000	44189	4,06	-0,0023	134,83	-5,7890

B – 2013										
E_{2013}	34525,37	8807,018								
T_{2013}	17,09	6,679	0,154885	0,023989	0,000000	44159	13,04	0,0001	31034,40	204,2413
E_{2013}	34525,37	8807,018								
I_{2013}	112,71	170,391	0,348371	0,121362	0,000000	44159	-119,99	0,0067	32495,86	18,0063
E_{2013}	34525,37	8807,018								
V_{2013}	3,80	3,418	-0,011112	0,000123	0,019543	44159	3,95	-0,0000	34634,21	-28,6312
T_{2013}	17,09	6,679								
I_{2013}	112,71	170,391	0,416649	0,173597	0,000000	44159	-68,98	10,6297	15,25	0,0163
T_{2013}	17,09	6,679								
V_{2013}	3,80	3,418	-0,194796	0,037945	0,000000	44159	5,51	-0,0997	18,54	-0,3806
I_{2013}	112,71	170,391								
V_{2013}	3,80	3,418	-0,115879	0,013428	0,000000	44159	4,06	-0,0023	134,67	-5,7768
A – 2014										
E_{2014}	28172,62	7015,753								
T_{2014}	16,92	5,562	0,358931	0,128832	0,000000	47376	8,90	0,0003	20511,62	452,7414
E_{2014}	28172,62	7015,753								
I_{2014}	98,72	158,155	0,305787	0,093506	0,000000	47376	-95,48	0,0069	26833,53	13,5647
E_{2014}	28172,62	7015,753								
V_{2014}	3,83	3,205	-0,007734	0,000060	0,092306	47376	3,93	-0,0000	28237,39	-16,9304
T_{2014}	16,92	5,562								
I_{2014}	98,72	158,155	0,450734	0,203162	0,000000	47376	-118,15	12,8165	15,36	0,0159
T_{2014}	16,92	5,562								
V_{2014}	3,83	3,205	-0,161061	0,025941	0,000000	47376	5,40	-0,0928	17,99	-0,2795
I_{2014}	98,72	158,155								
V_{2014}	3,83	3,205	-0,072050	0,005191	0,000000	47376	3,97	-0,0015	112,32	-3,5556
B – 2014										
E_{2014}	28164,29	7017,463								
T_{2014}	16,92	5,564	0,358288	0,128370	0,000000	47237	8,92	0,0003	20520,41	451,8583
E_{2014}	28164,29	7017,463								
I_{2014}	98,93	158,384	0,360612	0,130041	0,000000	47237	-130,30	0,0081	26583,62	15,9775
E_{2014}	28164,29	7017,463								
V_{2014}	3,82	3,200	0,003552	0,000013	0,440188	47237	3,77	0,0000	28134,55	7,7884
T_{2014}	16,92	5,564								
I_{2014}	98,93	158,384	0,386896	0,149689	0,000000	47237	-87,37	11,0127	15,57	0,0136
T_{2014}	16,92	5,564								
V_{2014}	3,82	3,200	-0,178578	0,031890	0,000000	47237	5,56	-0,1027	18,10	-0,3105
I_{2014}	98,93	158,384								
V_{2014}	3,82	3,200	-0,071292	0,005083	0,000000	47237	3,96	-0,0014	112,40	-3,5286

Analize treće grupe podataka napravljene su za svaku godinu zasebno, kako bi se ustanovila linearna i regresijska veza među odabranim varijablama, čiji se podaci temelje na 10-minutnom vremenskom koraku. Rezultati su prikazani u [Tablica 32].

Slučaj A predstavlja rezultate analiza izvedene za vremenski korak, t = 10 min, a slučaj B rezultate sustava koji uključuju vremenski odmak potrošnje u odnosu na proizvodnju za 4 sata, $t_1 = t$ + 4h, za svaku godinu zasebno.

Rezultati korelacijske analize, među parametrima za svaku odabranu godinu, ukazuju na značajno smanjenje koeficijenta korelacije u usporedbi s rezultatima korelacije za srednje mjesečne vrijednosti. Rezultati u slučaju B su nešto bolji od onih u slučaju A. Svi rezultati su istaknuti crvenom bojom i znače postojanje značajne veze među parametrima, osim veze između E_{2014} *vs*. V_{2014}. Tu je, s obzirom na njihove niske vrijednosti *r*, malo vjerojatno da se one mogu izraziti funkcijom linearne regresije. Funkcija linearne regresije se za ostale parametre može zapisati uz pomoć jednadžbe linearne regresije i koeficijenata *a* i *b* dobivenih proračunom i prikazanih u [Tablica 32].

3.1.4 Rezultati analize četvrte grupe podataka za vremenski korak od 10 minuta za zimski i ljetni period

Dodatna analiza je napravljena za grupu podataka koji se temelje na 10-minutnom vremenskom koraku, gdje su proračuni napravljeni kako bi se ustanovila veza između odabranih varijabli za vremenski period zime i ljeta za svaku od godina pojedinačno. Dijagrami na [Slika 18] pokazuju da potencijal vjetra i Sunca varira tijekom godine. Sunčevo zračenje doseže svoj maksimum tijekom ljetnog perioda, dok brzina vjetra svoj maksimu doseže u zimskom periodu godine. Prema tome, ta dva perioda su odabrana za dodatnu analizu. Ljetni period određen je prema maksimalnoj vanjskoj temperaturi zraka i maksimalnom vršnom opterećenju uslijed potrošnje električne energije za tri uzastopna mjeseca, lipanj, srpanj i kolovoz, kako je i vidljivo iz dijagrama na [Slika 18]. Zimski period određen je za tri uzastopna mjeseca s najnižom vanjskom temperaturom zraka i najvećim vršnim opterećenjem uslijed potrošnje električne energije u razdoblju zime. Za 2012. i 2013. godinu određeni su mjeseci prosinac, siječanj i veljača, dok su za 2014. godinu odabrani mjeseci siječanj, veljača i ožujak, kako je i pokazano na [Slika 18]. Rezultati analiza linearne korelacije i regresije prikazani su u [Tablica 33], [Tablica 34] i [Tablica 35]. Svaka od tablica prikazuje svaku od odabranih godina za slučaj A i B. Slučaj A odnosi se na rezultate dobivene za odabrani ljetni period, a slučaj B odnosi se na rezultate za odabrani zimski period.

Tablica 33. Rezultati linearne korelacije i regresija za ljetni i zimski period za 2012. godinu

x, y	**Srednja vrijednost**	**Std.Dv.**	*r(x,y)*	r^2	*p*	*N*	*a; y*	*b; y*	*a; x*	*b; x*
A – 2012										
E_{2012}	44088,56	10275,24								
T_{2012}	26,13	3,31	0,662773	0,439268	0,000000	9074	16,73	0,000	-9743,73	2060,366
E_{2012}	44088,56	10275,24								
I_{2012}	193,18	213,12	0,318626	0,101522	0,000000	9074	-98,20	0,007	41121,05	15,362
E_{2012}	44088,56	10275,24								
V_{2012}	2,45	2,28	-0,029784	0,000887	0,004548	9074	2,74	-0,000	44417,65	-134,216
T_{2012}	26,13	3,31								
I_{2012}	193,18	213,12	0,537326	0,288720	0,000000	9074	-712,05	34,647	24,52	0,008
T_{2012}	26,13	3,31								
V_{2012}	2,45	2,28	-0,009193	0,000085	0,381225	9074	2,62	-0,006	26,16	-0,013
I_{2012}	193,18	213,12								
V_{2012}	2,45	2,28	0,167744	0,028138	0,000000	9074	2,11	0,002	154,73	15,679
B – 2012										
E_{2012}	42309,77	9986,495								
T_{2012}	8,83	3,633	-0,287529	0,082673	0,000000	7531	13,26	-0,000	49289,32	-790,333
E_{2012}	42309,77	9986,495								
I_{2012}	53,47	94,390	0,036433	0,001327	0,001566	7531	38,90	0,000	42103,66	3,855
E_{2012}	42309,77	9986,495								
V_{2012}	4,48	3,084	0,060190	0,003623	0,000000	7531	3,69	0,000	41436,46	194,895
T_{2012}	8,83	3,633								
I_{2012}	53,47	94,390	0,434655	0,188925	0,000000	7531	-46,25	11,292	7,94	0,017
T_{2012}	8,83	3,633								
V_{2012}	4,48	3,084	-0,139021	0,019327	0,000000	7531	5,52	-0,118	9,56	-0,164
I_{2012}	53,47	94,390								
V_{2012}	4,48	3,084	-0,110865	0,012291	0,000000	7531	4,67	-0,004	68,68	-3,393

Tablica 34. Rezultati linearne korelacije i regresija za ljetni i zimski period za 2013. godinu

x, y	**Srednja vrijednost**	**Std.Dv.**	*r(x,y)*	r^2	*p*	*N*	*a; y*	*b; y*	*a; x*	*b; x*
A – 2013										
E_{2013}	39240,88	8640,876								
T_{2013}	25,06	3,702	0,503655	0,253669	0,000000	10610	16,60	0,000	9772,74	1175,673
E_{2013}	39240,88	8640,876								
I_{2013}	196,09	218,618	0,360576	0,130015	0,000000	10610	-161,89	0,009	36446,21	14,252
E_{2013}	39240,88	8640,876								
V_{2013}	2,66	2,301	-0,140073	0,019620	0,000000	10610	4,13	-0,000	40642,09	-526,119
T_{2013}	25,06	3,702								
I_{2013}	196,09	218,618	0,447643	0,200385	0,000000	10610	-466,55	26,437	23,58	0,008
T_{2013}	25,06	3,702								
V_{2013}	2,66	2,301	0,036142	0,001306	0,000196	10610	2,10	0,022	24,91	0,058
I_{2013}	196,09	218,618								
V_{2013}	2,66	2,301	0,000447	0,000000	0,963243	10610	2,66	0,000	195,98	0,043
B – 2013										
E_{2013}	37472,21	8459,776								
T_{2013}	10,47	3,188	-0,112984	0,012765	0,000000	12920	12,06	-0,000	40610,95	-299,812
E_{2013}	37472,21	8459,776								
I_{2013}	60,90	110,088	0,030708	0,000943	0,000481	12920	45,93	0,000	37328,50	2,360
E_{2013}	37472,21	8459,776								
V_{2013}	5,05	4,090	0,034421	0,001185	0,000091	12920	4,42	0,000	37113,00	71,192
T_{2013}	10,47	3,188								
I_{2013}	60,90	110,088	0,408545	0,166909	0,000000	12920	-86,79	14,108	9,75	0,012
T_{2013}	10,47	3,188								
V_{2013}	5,05	4,090	0,232899	0,054242	0,000000	12920	1,92	0,299	9,55	0,182
I_{2013}	60,90	110,088								
V_{2013}	5,05	4,090	-0,139772	0,019536	0,000000	12920	5,36	-0,005	79,88	-3,762

Rezultati se razlikuju za dva odabrana godišnja perioda. Vidljivo je iz rezultata da sunčevo zračenje ima bolju korelaciju s potrošnjom električne energije u ljetnom periodu. Brzina vjetra ima pozitivnu korelaciju s potrošnjom električne energije, što znači da u slučaju kada imamo porast brzine vjetra u zimskom periodu i potrošnja se povećava. To upućuje na to da energija vjetra može predstavljati dobar izvor električne energije tijekom zimskog perioda. Međutim, vrijednost *r* je blizu 0 što ukazuje na to da se veza između varijabli ne može opisati funkcijom linearne regresije. Vjetar ima dobru pozitivnu korelaciju s potrošnjom električne energije tijekom ljetnog perioda u 2014. godini, što ukazuje na to da bi se vjetar mogao koristiti kao dobar izvor električne energije i u ljetnom periodu.

Tablica 35. Rezultati linearne korelacije i regresija za ljetni i zimski period za 2014. godinu

x, y	Srednja vrijednost	Std.Dv.	*r(x,y)*	r^2	*p*	*N*	*a; y*	*b; y*	*a; x*	*b; x*
A – 2014										
E_{2014}	34259,62	7440,386								
T_{2014}	24,78	2,711	0,531300	0,282280	0,000000	9200	18,15	0,000	-1867,68	1458,034
E_{2014}	34259,62	7440,386								
I_{2014}	173,95	207,594	0,343010	0,117656	0,000000	9200	-153,93	0,010	32121,16	12,294
E_{2014}	34259,62	7440,386								
V_{2014}	2,89	2,108	0,045017	0,002026	0,000016	9200	2,45	0,000	33800,84	158,917
T_{2014}	24,78	2,711								
I_{2014}	173,95	207,594	0,552724	0,305504	0,000000	9200	-874,69	42,321	23,52	0,007
T_{2014}	24,78	2,711								
V_{2014}	2,89	2,108	0,183272	0,033588	0,000000	9200	-0,64	0,142	24,10	0,236
I_{2014}	173,95	207,594								
V_{2014}	2,89	2,108	0,144022	0,020742	0,000000	9200	2,63	0,001	132,99	14,186
B – 2014										
E_{2014}	27495,46	6493,145								
T_{2014}	11,91	3,437	-0,339692	0,115391	0,000000	12936	16,86	-0,000	35138,66	-641,666
E_{2014}	27495,46	6493,145								
I_{2014}	39,49	77,695	0,105663	0,011165	0,000000	12936	4,73	0,001	27146,71	8,830
E_{2014}	27495,46	6493,145								
V_{2014}	5,18	4,046	0,113016	0,012773	0,000000	12936	3,24	0,000	26556,15	181,372
T_{2014}	11,91	3,437								
I_{2014}	39,49	77,695	0,224492	0,050397	0,000000	12936	-20,95	5,074	11,52	0,010
T_{2014}	11,91	3,437								
V_{2014}	5,18	4,046	0,036559	0,001337	0,000032	12936	4,67	0,043	11,75	0,031
I_{2014}	39,49	77,695								
V_{2014}	5,18	4,046	-0,064810	0,004200	0,000000	12936	5,31	-0,003	45,94	-1,245

3.2 Daljinski sustav grijanja i hlađenja DTMV sa i bez skladišta energije za područje Starog grada, Dubrovnik

Dubrovačka područje ima visok potencijal OIE, posebice vjetra i Sunca, zbog čega su ti potencijali odabrani kao izvor električne energije u ovom radu. U prethodnoj studiji [186], u kojoj je za korelacijske analize odabrano dubrovačko područje, a dio rezultata iznesen je i u prethodnom poglavlju, pokazalo se da vanjska temperatura zraka može biti pouzdan faktor za predviđanje sunčeva zračenja i potrošnje električne energije, čak i na kratkoročnom vremenskom koraku od 10 minuta. Rezultati su pokazali da prosječne mjesečne vrijednosti brzina vjetra i sunčevog zračenja imaju značajnu negativnu korelacijsku vezu što znači da ova dva OIE u kombinaciji mogu pružiti pouzdanu proizvodnju električne energije. Rezultati analiza za kratkoročni vremenski korak od 10 minuta pokazali su da nema značajne veze među

varijablama. To znači i veće potrebe za fleksibilnošću kako bi se postigla ravnoteža energetskog sustava za kratkoročan vremenski korak i bolja iskoristivost promjenjivih OIE.

U ovom poglavlju predstavit će se rezultati primjene DTMV u sustavu DGH na području Staroga grada Dubrovnika. Ispitati će se mogućnosti DTMV i odabranih skladišta energije u poticanju integracije OIE u proizvodnji električne energije na odabranom području. Shodno rezultatima prethodnog poglavlja i prethodnim studijama, koje ukazuju na značajan potencijal vjetra i Sunca u kombinaciji u proizvodnji električne energije, kao i značajan potencijal tih izvora energije na odabranom području, za proizvodnju električne energije odabrani su vjetar i Sunce. U ovom poglavlju prikazat će se samo područje Starog grada kako bi se ispitao potencijal DTMV na odabranom području, kao i mogućnosti skladištenja energije. U sljedećim poglavljima razmatrat će se primjena DTMV i na čitavom odabranom širem gradskom području, uz korištenje skladišnih kapaciteta energije i integraciju i elektrifikaciju toplinskog i transportnog sektora, u vidu poticanja integracije OIE u proizvodnji električne energije. Rezultati analize rada DTMV za područje Starog grada prikazani su u nastavku, a također su objavljeni u radu [187].

Rezultati su dani za tri scenarija i svaki od scenarija je izrađen za tri različita slučaja. Rezultati scenarija prikazuju razliku u primjeni korištenja DTMV kao samostalnog sustava i kao sustava koji koristi ES, BES i TES. Također je dana i usporedba tehničkih i financijskih aspekata za BES i TES. Tri slučaja za svaki od navedenih scenarija pokazuju odstupanja između odabranih sustava u odnosu na promjene u opskrbi električnom energijom. Rezultati scenarija 1 pokazuju usporedbu modela sustava baziranog na satnom i 10-minutnom vremenskom koraku, dok su za scenarije 2 i 3 proračuni izrađeni samo za vremenski korak od 1 sat. Dobivena godišnja raspodjela potrošnje električne energije za rad DTMV, koja se koristi za snabdjevanje toplinskih i rashladnih potreba Starog grada, prikazana je na [Slika 31], za satni i 10-minutni vremenski korak.

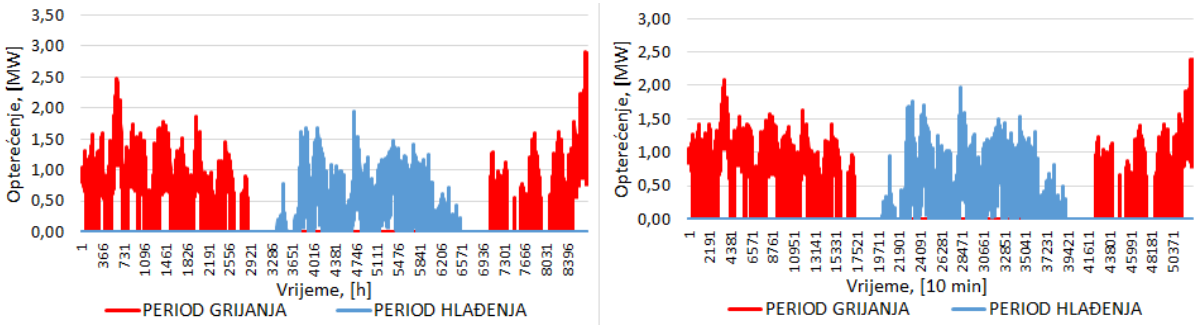

Slika 31. Godišnja raspodjela potreba električne energije za rad dizalice topline za vremenski korak od 1 sat i 10 minuta

Iz slike je vidljivo da se period grijanja proteže na dulje razdoblje godine s većim vršnim opterećenjem od onog u periodu hlađenja. Satna distribucija opterećenja ima maksimalno vršno opterećenje za 500 kW veće od onog kod 10-minutne distribucije.

3.2.1 Rezultati scenarija 1

[Slika 32] prikazuje jedan specifičan dan tijekom sezone grijanja i sezone hlađenja. Treća srijeda u siječnju odabrana je za sezonu grijanja, a treća srijeda u srpnju za sezonu hlađenja. [Tablica 36] prikazuje maksimalne vrijednosti proizvodnje električne energije iz energije Sunca i vjetra i potrošnje električne energije za rad DTMV za svaki od odabranih dana.

Tablica 36. Maksimalne vrijednosti proizvodnje električne energije iz OIE i potrebe električne energije za rad DTMV za jedan odabrani dan u sezoni grijanja i hlađenja

Vremenski korak	**1h**		**10min**	
Period	**Period grijanja**	**Period hlađenja**	**Period grijanja**	**Period hlađenja**
Jedinica	**MW**	**MW**	**MW**	**MW**
Opterećenje proizvodnjom električne energije VE	158,67	10,13	160	40
Opterećenje proizvodnjom električne energije SE	2,96	17,08	4,62	17,22
Opterećenje električnom energijom za rad DTMV	1,24	1,93	1,23	1,97

Kao što se može vidjeti iz [Slika 32], tijekom perioda hlađenja, proizvodnja električne energije iz SE može zadovoljiti većinu rashladnih potreba korištenjem DTMV. Tijekom perioda grijanja, toplinske potrebe su izraženije tijekom noći kada postoji manjak u proizvodnji električne energije iz OIE. Dio toplinskih potreba tijekom dana može se zadovoljiti proizvodnjom električne energije iz OIE, većinom iz vjetra. Ostatak proizvodnje, koji se ne može iskoristiti za snabdijevanje toplinskih potreba, ako su potrebe za toplinskom energijom niske, može se pohraniti u dodatne ES i koristiti po potrebi. U vrijeme viška proizvodnje električne energije može se očekivati i pad cijena električne energije, ako govorimo o varijabilnim cijenama. Stoga sustav DTMV može profitirati, ukoliko koristi neku vrstu ES, pohranom energije u spremnik po nižoj cijeni. S druge strane, ES može pružiti dodatni izvor fleksibilnosti sustavu s visokim udjelom OIE. Kada usporedimo satne i 10-minutne raspodjele, vidimo da kod 10-minutne raspodjele imamo više odstupanja u proizvodnji električne energije iz OIE koja su većeg iznosa. 10-minutna rezulucija daje detaljniji uvid u stvarno stanje sustava što možo pružiti više mogućnosti za bolju integraciju izvora fleksibilnosti a time i OIE u proizvodnji električne enerije. Mnogo je kraćih vršnih opterećenja tokom dana, posebice kod proizvodnje električne energije iz vjetra. Ta energije može se pohraniti u baterijama,

korištenjem brzog punjenja u trajanju od 10 minuta i iskoristiti naknadno, što zahtjeva visoke kapacitete električne energije u vrlo kratkom vremenu.

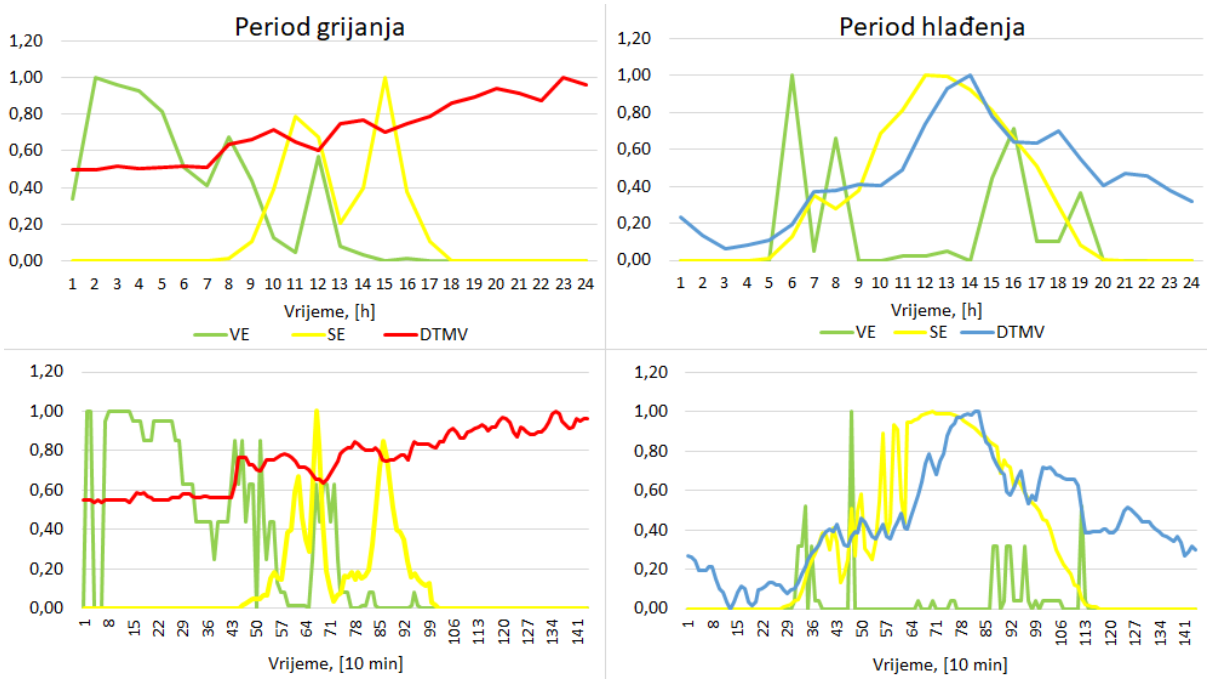

Slika 32. Usporedba normaliziranih vrijednosti proizvodnje električne energije iz OIE i potreba DTMV za jedan odabrani dan sezone grijanja i hlađenja za vremenski korak od 1 sat i 10 minuta

[Slika 33] prikazuje rezultate scenarija 1 za tri različita slučaja koja su dobivena proračunima za satni i 10-minutni vremenski korak. Stupci u dijagramu prikazuju ukupnu godišnju potrošnju električne energije za rad DTMV, gdje dio označen zelenom bojom predstavlja potrošnju, koja je zadovoljena iz proizvodnje električne energije iz OIE, dok ostatak potrošnje mora biti zadovoljen s dodatnim ES, a označen je narančastom bojom. Ukupna godišnja potrošnja električne energije za rad DTMV iznosi 4376 MWh/god. Udio iskorištene proizvodnje električne energije za rad DTMV dan je u postotku na dijagramu. Iz rezultata je vidljiva potreba za ES, ukoliko bi DTMV koristila samo proizvodnju energije iz OIE za svoj rad. Slučaj C, u oba dijela dijagrama, rezultira najboljom iskoristivosti proizvodnje električene energije OIE za snabdjevanje rada sustava DTMV. To znači da kombinacija SE i VE u proizvodnji električne energije rezultira kao povoljna opcija u sustavima s visokim udjelom OIE u proizvodnji. U slučaju C postiže se najbolja iskoristivost proizvodnje električne energije iz OIE i najmanje su potrebe za skladišnim kapacitetima. 67% potrošnje električne energije za rad DTMV može se zadovoljiti proizvodnjom iz OIE. Proračuni temeljeni na 10-minutnom vremenskom koraku općenito u svim slučajevima rezultiraju nižom iskoristivosti proizvodnje OIE u odnosu na satni, do 6% niže u slučaju C i 8 % u slučaju B, dok su za slučaj A rezultati

podjednaki. Međutim, kraća vremenska rezulucija daje detaljniji uvid u stvarno stanje sustava i time pruža veću pouzdanost kod energetskog modeliranja.

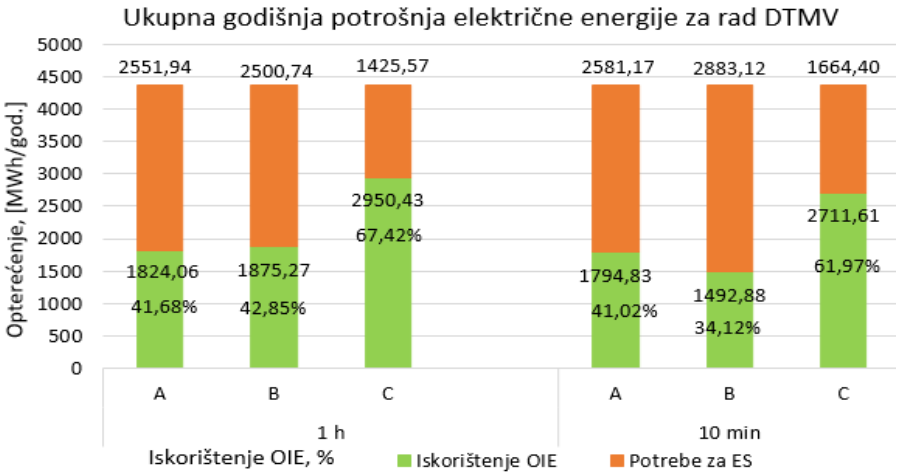

Slika 33. Rezultati scenarija 1

Sustav DTMV, uz integraciju OIE, ima značajan utjecaj i na smanjenje emisija. Kroz rezultate je dan i kratak pregled smanjenja emisija CO_2 integracijom proizvodnje električne energije iz OIE i sustava DTMV. Smanjenje emisija računalo se prema podacima koeficijenta emisije CO_2 za Hrvatsku za 2018. godinu, koji je iznosio 147 gCO_2/kWh [188]. Smanjenje emisija CO_2 za sve slučajeve, za scenarij 1, prikazano je na [Slika 34]. Veće iskorištavanje proizvodnje električne energije iz OIE za snabdjevanje potreba potrošnje znači i veće smanjenje emisija.

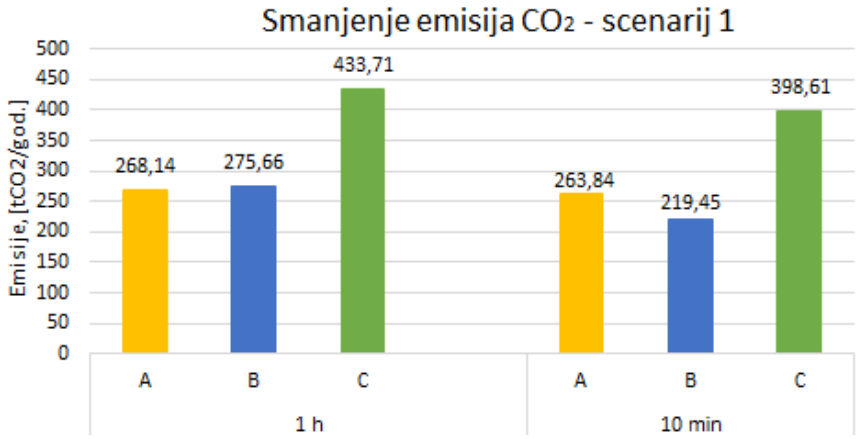

Slika 34. Smanjenje emisija CO_2 iskorištenjem proizvodnje električne energije iz OIE

3.2.2 Rezultati scenarija 2 i 3

U scenariju 2 i 3 analizirani su sustavi s DTMV u kombinaciji s BES i TES za skladištenje bilo električne bilo toplinske energije. Pretpostavka je da će se godišnje toplinske potrebe zadovoljiti iz proizvodnje električne energije iz OIE, direktnim napajanjem DTMV ili

energijom uskladištenom u BES ili TES. Kapacitet BES i TES, potreban da zadovolji preostale ukupne godišnje toplinske potrebe DTMV, u vrijeme manjka proizvodnje električne energije iz OIE, dobiven je na temelju tehničkih i financijskih karakteristika BES i TES, koje su dane u [Tablica 16], i na temelju jednadžbi (9) - (11). [Tablica 37] prikazuje dobivene rezultate. Usporedba između BES i TES nije rađena za optimalni spremnik, jer je u cilju rada bilo prikazati njihovu usporedbu s obzirom na vrstu OIE koja se koristi u proizvodnji električne energije za zadovoljenje potreba sustava.

Rezultati pokazuju da TES ima znatno veći iznos kapaciteta skladišta zbog razlike u pretvorbi električne u toplinsku energiju preko vrijednosti SCOP i SEER za odabranu DTMV. Kapacitet za BES je izražen za kapacitet pohrane električne energije, dok se za TES on odnosi na pohranjenu toplinsku energiju. Rezultati su pokazali da su investicijski troškovi 13 puta veći za BES, dok mu je volumen 40 puta manji u svakom od analiziranih slučajeva, kada se usporedi s TES. Kombinacija vjetra i Sunca u proizvodnji električne energije u slučaju C rezultirala je smanjenjem kapaciteta, volumena i troškova ES u usporedbi sa slučajevima A i B. Kapacitet skladišta, investicijski trošak i volumen TES i BES u slučaju C su se smanjili za 78% u usporedbi sa slučajem A, a za 60% u usporedbi sa slučajem B. Nivelirani trošak topline za BES je gotovo 13 puta veći, s iznosom od 24,57 EUR/MWh, dok je za TES on iznosio 1,93 EUR/MWh. U proračunu niveliranog troška topline u slučaju C nisu uzeti u obzir svi dijelovi sustava, kao što su DTMV, cjevovod i cijene električne energije. To bi se trebalo uzeti u obzir ako se želi napraviti kompletna i detaljna analiza niveliranog troška topline.

Tablica 37. Rezultati scenarija 2 i 3

SLUČAJ	Kapacitet BES, [MWh]	Kapacitet TES, [MWh]	Investicijski trošak BES, [mil.EUR]	Investicijski trošak TES, [mil.EUR]	Volumen BES, [m^3]	Volumen TES, [m^3]
A	127	800	25,4	2	254	10000
B	94	592	18,8	1,48	188	7400
C	28	176	5,6	0,44	56	2200

3.3 Rezultati analiza scenarija u novom modelu

Rezultati analiza scenarija u novom modelu obuhvaćaju scenarije za 2030. i 2050. na satnoj i 10-minutnoj rezoluciji za četiri izdvojena slučaja. Analizirana je elektrifikacija sektora transporta i uvođenje regulacije punjenja i pražnjenja EV s implementacijom modela V2G. Dana je usporedba rezultata satnog i 10-minutnog modela, odnosno reguliranog standardnog i iznimno brzog punjenja i pražnjenja EV uvođenjem modela V2G s nereguliranim punjenje EV koje se bazira na potrebama i navikama korisnika EV. Usporedili su se rezultati novog modela

i modela EnergyPLAN za slučaj S1 i scenarij za 2030. godinu u svrhu validacije novog modela. Rezultati su opisani u sljedećim poglavljima.

3.3.1 Rezultati scenarija za slučaj S1 i usporedba novog modela i modela EnergyPLAN

Usporedba rezultata proračuna za energetski plan odabranog područja u novom algoritmu i EnergyPLAN-u napravljena je za plan za 2030. godinu, za godišnje satne i dvomjesečne 10-minutne podatke. Usporedba modela razvijenog algoritma s postojećim EnergyPLAN programom pokazat će vjerodostojnost novog algoritma u energetskom planiranju. S obzirom da EnergyPLAN radi na satnoj bazi unosa podataka, rezultati za satni model mogli su se usporediti na godišnjoj razini, dok su se za provjeru 10-minutnog modela koristili podaci za dva mjeseca u godini. Za kratkoročan vremenski korak ukupan broj podataka za dva mjeseca, lipanj i srpanj, iznosi 8784 što odgovara broju podataka za EnergyPLAN, pa su ta dva uzastopna mjeseca odabrana za usporedbu rezultata.

3.3.1.1 Usporedba rezultata novog algoritma s rezultatima EnergyPLAN-a za satni model

Ulazni podaci za proračun odnose se na potrošnju i proizvodnju električne energije i dani su u [Tablica 38]. Ulazni podaci su jednaki za novi algoritam i za EnergyPLAN. Pretpostavka je da su sva EV, koja nisu u vožnji i ne pune se u određenom vremenskom koraku, na raspolaganju za model V2G, odnosno G2V, odnosno na raspolaganju za punjenje i pražnjenje u cilju smanjenja uvoza i izvoza i kao izvor fleksibilnosti u sustavu za bolju integraciju OIE. Jedna razlika je uočena prilikom unosa podataka između novog algoritma i EnergyPLAN-a, a odnosi se na proizvodnju električne energije iz SE. Za SE u EnergyPLAN unosi se podatak o instaliranoj snazi i distribucija proizvodnje električne energije, odnosno sunčeva zračenja. Ukupna godišnja proizvodnja SE dobivena u EnergyPLAN-u razlikovala se od one za novi algoritam, pa je stoga korišten korekcijski faktor kako bi se ukupna proizvodnja izjednačila. Korekcijski faktor ne mijenja maksimalnu i minimalnu vrijednost, već korigira samo vrijednosti između onih graničnih prema korekcijskom faktoru, kako bi se dobila ukupna godišnja željena proizvodnja električne energije. Rezultati proračuna energetskog plana za 2030. godinu na satnoj bazi za EnergyPLAN prikazani su u [Tablica 39], dok su oni za novi algoritam prikazani u [Tablica 40].

Tablica 38. Ulazni podaci za novi model i EnergyPLAN za vremenski korak od 1 sat

ULAZNI PODACI	2030.	2050.
Opća potrošnja električne energije (E_{DEM}), [GWh/god.]	327,33	380,78
Potrošnja električne energije za punjenje EV ($E_{EV,dem}$), [GWh/god.]	25,22	59,33
Instalirana snaga SE, [MW]	40	84
Instalirana snaga VE, [MW]	87	219

Tablica 39. Rezultati dobiveni proračunom u EnergyPLAN-u za energetski plan odabranog područja za 2030. godinu i za satni model

EnergyPLAN model (2030.)	**1h**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**
NEREG, [GWh/god.]	238,92	25,02
REG, [GWh/god.]	223,87	8,58
Smanjenje REG u odnosu na NEREG	**6,3%**	**65,7%**
Iskorištena energija u baterijama V2G, [GWh/god.]	**15,05**	**16,44**

Tablica 40. Rezultati dobiveni proračunom u novom algoritmu za energetski plan odabranog područja za 2030. godinu za satni model i 10-minutni model

Novi model (2030.)	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh/god.]	238,93	25,02	243,44	29,65
REG, [GWh/god.]	224,46	8,56	224,44	8,51
Smanjenje REG u odnosu na NEREG	**6,1%**	**65,8%**	**7,8%**	**71,3%**
Iskorištena energija u baterijama V2G, [GWh/god.]	**14,47**	**16,46**	**19**	**21,14**

Rezultati u [Tablica 39] prikazuju ukupan godišnji iznos uvoza i izvoza za odabrani energetski sustav koji ne uključuje regulaciju punjenja EV i sustav s uključenom regulacijom punjenja i pražnjenja EV s modelom V2G. U novom algoritmu se V2G model regulirao s obzirom na proizvodnju električne energije iz OIE. Kod viška proizvodnje električne energije uključuje se G2V, a kod manjka proizvodnje V2G, ukoliko kapacitet baterije dopušta pojedini smjer toka električne energije. Smatra se da će regulacija punjenja i pražnjenja biti stimulirana cijenom električne energije, što će kao rezultat dati smanjenje viška i manjka električne energije u sustavu, a u korist i vlasnika EV. Kod EnergyPLAN modela korištena je simulacijska strategija regulacije modela V2G koja teži balansiranju proizvodnih kapacitet i ukupnog izvoza i uvoza u cilju smanjenja viška i manjka proizvodnje električne energije.

Iz rezultata se vidi da primjena modela V2G, s regulacijom punjenja i pražnjenja EV, smanjuje uvoz za 6,3%, a izvoz za 65,7% na godišnjoj razini. S obzirom da je uvoz značajno veći nego izvoz električne energije, ne čudi manji postotak smanjenja uvoza uvođenjem regulacije za V2G. U konačnici je proizvedena energija iz OIE, koja se na godišnjoj razini iskoristi punjenjem EV (G2V), odnosno nadomjesti pražnjenjem EV (V2G), približno jednaka. Smanjenje izvoza odnosi se na punjenje EV, odnosno G2V, i vozila se pune u vrijeme viška

proizvedene energije u sustavu čime smanjuju izvoz. Ukupna godišnja energija za punjenje iz mreže je većeg iznosa od one za pražnjenje jer u tu energiju spada i energija za punjenje baterije koja se isprazni uslijed vožnje, dok se ukupna energija za pražnjenje vozila, V2G, odnosi samo na energiju iz baterije predanu mreži u vrijeme manjka proizvodnje iz OIE, čime se smanjuje uvoz. Rezultati satnog modela za 2030. godinu, dobiveni u EnergyPLAN-u i novom algoritmu, su približno jednaki, pa možemo zaključiti da novi algoritam ima valjan proračun. Rezultati 10-minutnog modela nešto većim smanjenjem uvoza i izvoza, uvođenjem regulacije V2G modela, u odnosu na satni modela. Postotak smanjenje uvoza i izvoza nešto je veći od satnog modela kao i ukupna godišnja energija za punjenje i pražnjenje u cilju smanjenja uvoza i izvoza. Stoga se može zaključiti da 10-minutni model pruža više mogućnosti za bolju integraciju OIE u sustavu.

[Tablica 41] prikazuje rezultati proračuna za energetski plan odabranog područja za 2050. godinu, za satni i 10-minutni model. Prema rezultatima se vidi, da za razliku od 2030. godine, imamo veći postotak smanjenja uvoza i izvoza kao i veću količinu energije koja se na godišnjoj razini iskoristi u BEV punjenjem i pražnjenjem. Razlog tome je veći broj EV u sustavu, odnosno veći kapacitet baterije na raspolaganju. Za 2050. godinu pretpostavka je da su sva osobna vozila u sustavu EV. Vidimo da veći kapacitet skladišta u sustavu značajno utječe na smanjenje uvoza i izvoza i doprinosi fleksibilnom radu sustava kao i integraciji OIE u sustav. Količina energije koja se iskoristi baterijama EV malo se razlikuje za satni i 10-minutni model i nešto je veća za 10-minutni model. Razlog tome je pretpostavka da su sva slobodna vozila u svakom vremenskom trenutku na raspolaganju za punjenje i pražnjenje. Ta pretpostavka predstavlja najbolji mogući slučaj, odnosno granični slučaj. Takva pretpostavka nije odraz stvarne situaciju u sustavu i rezultirala bi prevelikim opterećenjem na mreži s visokim naponom. U tom slučaju V2G vozila, u 10-minutnom modelu, koja se pune brzim punjenjem, nisu u mogućnosti iskoristiti svoj cjelokupan potencijal. Stoga će se u sljedećem poglavlju dati rezultati analize za slučaj u kojem će se usporediti brzo i standardno punjenje za minimalni kapacitete baterije, koji će dati rezultate jednake ovima za pretpostavku da su sva slobodna, parkirana vozila raspoloživa za punjenje u svakom vremenskom koraku. Tim rezultatima pokazat će se razlika u mogućnostima fleksibilnosti koju EV pružaju u slučaju standardnog i brzog punjenja.

Tablica 41. Rezultati dobiveni proračunom u novom algoritmu za energetski plan odabranog područja za 2050. godinu za satni model i 10-minutni model

Novi model (2050.)	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh/god.]	245,31	127,84	255,33	138,14
REG, [GWh/god.]	180,22	53,65	180,09	53,46
Smanjenje REG u odnosu na NEREG	**26,5%**	**58%**	**29,5%**	**61,3%**
Iskorištena energija u baterijama V2G, [GWh/god.]	**65,09**	**74,21**	**75,24**	**84,68**

Slučaj S1 analiziran je i za utjecaj na smanjenje vršnog opterećenja proizvodnjom električne energije iz OIE, uvođenjem regulacije u sustav za standardno i brzo punjenje. Regulacija V2G modela iznimno brzog punjenja i pražnjenja rezultirala je većim smanjenjem uvoza i izvoza električne energije. Regulacija standardnog punjenja utjecala je na veće smanjenje vršnih opterećenja, kao što se i vidi iz rezultata u [Tablica 42]. Sustav modeliran za vremenski korak od 10 minuta ima općenito veća vršna opterećenja u sustavu od onog na satnoj bazi. On nudi više detalja o stvarnom stanju energetskih tokova i nudi realističniji prikaz stanja u sustavu, što pruža više mogućnosti za bolju integraciju izvora fleksibilnosti, posebice EV s brzim punjenjem i pražnjenjem. Samo smanjenje vršnih opterećenja u iznosu je manje nego kod standardnog punjenje. Brzo punjenje donosi izazov u energetski sustav i zahtjeva izmjenu strukture opskrbe s vodovima visokih napona zbog visokih kratkoročnih opterećenja na mreži. Nedostatak infrastrukture visokonaponske mreže predstavlja velik problem u integraciji i penetraciji EV na iznimno brzo punjenje i OIE.

Tablica 42. Utjecaj regulacije standardnog i brzog punjenja EV na smanjenje vršnih opterećenja proizvodnje električne energije iz OIE

Slučaj S1	**2030. godina**		**2050. godina**	
Vremenski korak	**1h**	**10min**	**1h**	**10min**
Vršno opterećenje - NEREG, [MW]	118,76	126,94	285,7	302,87
Vršno opterećenje - REG, [MW]	98,61	108,67	258,04	292,05
Smanjenje vršnog opterećenja, [MW]	**20,15**	**18,27**	**27,66**	**10,82**

3.3.1.2 Usporedba rezultata novog algoritma s rezultatima EnergyPLAN-a za 10-minutni model

Rezultati proračuna energetskog plana odabranog područja, dobiveni korištenjem novog algoritma, usporedili su se s rezultatima u EnergyPLAN-u za vremenski korak proračuna

od 10 minuta koje uključuje brzo punjenje EV. Proračun u novom algoritmu se izradio na godišnjoj bazi podataka, dok za EnergyPLAN nije bilo moguće izraditi proračun za cijelu godinu za vremenski korak od 10 minuta, zbog toga što EnergyPLAN radi na satnoj godišnjoj bazi unosa podataka. Stoga su se za usporedbu 10-minutnog modela koristili ulazni podaci za dva mjeseca, lipanj i srpanj, koji za vremenski korak od 10 minuta imaju jednak broj podataka kao i satni godišnji podaci unosa u EnergyPLAN, odnosno 8784. Ulazni podaci za EnergyPLAN i novi algoritam prikazani su u [Tablica 43].

Tablica 43. Ulazni podaci za novi model i EnergyPLAN za vremenski korak od 10 minuta

ULAZNI PODACI (lipanj i srpanj 2030. godina)	**1h**	**10min**
Opća potrošnja električne energije (E_{DEM}), [GWh]	61,605	61,611
Potrošnja električne energije za punjenje EV ($E_{EV,dem}$), [GWh]	4,215	4,196
Instalirana snaga SE, [MW]	40	40
Instalirana snaga VE, [MW]	87	87

Rezultati dobiveni u EnergyPLAN-u prikazani su u [Tablica 44], a rezultati dobiveni proračunom u novom algoritmu prikazani su u [Tablica 45]. Dana je usporedba za sustave bazirane na vremenskom koraku od 1 sat i 10 minuta za oba modela. Iz rezultata se da zaključiti da novi algoritam ima približno jednake rezultate onima dobivenim u EnergyPLAN-u. Nešto je značajnija razlika u rezultatima koji se odnose na uvoz električne energije, odnosno smanjenje uvoza regulacijom punjenja i pražnjenja EV. EnergyPLAN rezultira nešto većim smanjenjem uvoza i izvoza kod satnog proračuna, u odnosu na novi model. Novi algoritam većim smanjenjem rezultira u 10-minutnom modelu, u odnosu na EnergyPLAN. S obzirom da razlike nisu značajne, možemo reći da je valjanost novog algoritma, u proračunima za 10-minutni vremenski korak, valjana.

Rezultate je bilo teško usporediti jer se radi o velikim iznosima energije koji se baziraju na vremenskom koraku od 10 minuta, gdje su iznosi kapaciteta baterije značajno visoki u usporedbi s ostalim iznosima koji su se unosili u EnergyPLAN. Naime, maksimalno opterećenje mreže u jednom koraku od 10 minuta je 30 puta veće od onog u jednom satu. Još se tome dodaje i pretpostavka da to opterećenje uključuje slučaj da su sva slobodna vozila u određenom trenutku raspoloživa za punjenje. Za usporedbu rezultata novog algoritma i EnergyPLAN-a odabrana je 2030. godina. Iz rezultata se također može iščitati da regulacija brzog punjenja većim smanjenjem uvoza i izvoza nego standardno punjenje za vremenski korak od 1 sat. Stoga, možemo reći da brzo punjenje pruža veću fleksibilnost u sustavu, iako

ona nije značajno veća. Povoljniji rezultati 10-minutnog proračuna očituju se u većoj energiji akumuliranoj u BEV tijekom određenog razdoblja.

Tablica 44. Rezultati proračuna u EnergyPLAN-u za lipanj i srpanj 2030. godine za vremenski korak od 1 sat i 10 min

EnergyPLAN model (6_7_2030)	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh]	42,93	1,6	43,38	2,07
REG, [GWh]	41,47	0	41,67	0
Smanjenje REG u odnosu na NEREG	**3,4%**	**100%**	**3,9%**	**100%**
Iskorištena energija u baterijama V2G, [GWh]	**1,46**	**1,6**	**1,71**	**2,07**

U odabranom periodu od dva mjeseca imamo pojačanu proizvodnju električne energije iz SE a manju iz VE. Iz rezultata vidimo da je izvoz električne energije značajno niži u odnosu na uvoz, što znači da se proizvedena električna energija iz SE značajno iskoristi. Ako se u sustav uvede regulacija punjenja i pražnjenja EV, proizvedena energija može se u potpunosti iskoristiti kako standardnim tako i brzim punjenjem. Uvoz električne energije je ipak značajno visok. U zimskom periodu imamo povećanu proizvodnju električne energije iz VE a manju iz SE. Stoga se u novom algoritmu usporedila situacija uvođenja modela V2G u sustav za dva mjeseca perioda ljeta i zime za 2030. i 2050. godinu za standardno i brzo punjenje. Za period zime odabrana su dva uzastopna mjeseca studeni i prosinac, kako bi se količina podataka slagala s periodom ljeta. Rezultati za period ljeta za 2030. godinu prikazani su u [Tablica 45], a za 2050. u [Tablica 46]. Rezultati za period zime za 2030. godinu prikazani su u [Tablica 47], a za 2050. u [Tablica 48]. Usporedba scenarija svih odabranih perioda prikazana je dijagramom na [Slika 35].

Tablica 45. Rezultati proračuna u novom algoritmu za lipanj i srpanj 2030. godine za vremenski korak od 1 sat i 10 minuta

Novi model (6_7_2030)	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh]	42,93	1,56	43,39	2,07
REG, [GWh]	41,55	0	41,53	0
Smanjenje REG u odnosu na NEREG	**3,2%**	**100%**	**4,3%**	**100%**
Iskorištena energija u baterijama V2G, [GWh]	**1,38**	**1,56**	**1,86**	**2,07**

Tablica 46. Rezultati proračuna u novom algoritmu za lipanj i srpanj 2050. godine za vremenski korak od 1 sat i 10 minuta

Novi model (6_7_2050)	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh]	41,5	13,88	42,66	15,07
REG, [GWh]	29,3	0,33	29,26	0,33
Smanjenje REG u odnosu na NEREG	**29%**	**98%**	**31%**	**98%**
Iskorištena energija u baterijama V2G, [GWh]	**12,2**	**13,55**	**13,4**	**14,74**

Prema rezultatima se može vidjeti da sustav modeliran za vremenski korak od 10 minuta, kod nereguliranog punjenja, ima veći uvoz i izvoz od satnog. On pruža više detalja o stvarnom stanju sustava. Brzo punjenje, uz regulaciju punjenja i pražnjenja, rezultira većim smanjenjem uvoza i izvoza u postotku, kao i u količini proizvedene električne energije iskorištene baterijama EV. To upućuje na zaključak da brzo punjenje, u modelu sustava baziranog na kratkoročnom vremenskom koraku, pruža više mogućnosti za veću fleksibilnost u sustavu.

U 2050. godini imamo veću instaliranu snagu OIE u sustavu što uzrokuje povećanu proizvodnju električne energije, a time i povećani izvoz. U periodu ljeta regulacija V2G uspješno iskorištava višak proizvodnje i smanjuje uvoz do čak 100%. U zimskom periodu, izvoz je značajno veći zbog veće proizvodnje energije iz VE, a smanjenje izvoza regulacijom kreće se od nekih 50-70%. Količina energije iskorištena baterijama u modelu V2G je značajno veća u 2050. u odnosu na 2030. godinu, zbog povećanog broja EV u sustavu, odnosno većeg kapaciteta baterije koja je na raspolaganju u sustavu. Uvoz električne energije značajno je viši od izvoza, u svim periodima osim zimskog perioda za 2050., što upućuje na potrebu za dodatnim proizvodnim kapacitetima za odabrano područje, odnosno dodatnim ES.

Zimski period 2050. godine ima približno jednaku količinu izvoza i uvoza na godišnjoj razini. Regulacijom punjenja i pražnjenja EV moguće je iskoristiti značajne količine proizvedene električne energije iz OIE i u približno jednakim količinama smanjiti uvoz i izvoz. Razlog tome je povećana proizvodnja iz OIE u 2050. kao i povećan broj EV u sustavu. S obzirom da je isprekidana i nestalna proizvodnja iz VE više zastupljena u zimskom periodu, možemo zaključiti da takvoj proizvodnji ide u prilog povećani broj EV koji će modelom V2G regulirati energetske tokove u sustavu i smanjiti uvoz i izvoz električne energije. Povećavanjem kapaciteta skladišta električne energije povećava se fleksibilnost energetskog sustava i pruža se više mogućnosti za integraciju OIE u sustav, posebice u slučaju brzog punjenja EV.

Tablica 47. Rezultati proračuna u novom algoritmu za studeni i prosinac 2030. godine za vremenski korak od 1 sat i 10 minuta

Novi model (11_12_2030)	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh]	35,35	8,01	36,48	9,16
REG, [GWh]	30,49	2,56	30,51	2,55
Smanjenje REG u odnosu na NEREG	**13,8%**	**68%**	**16,4%**	**72,2%**
Iskorištena energija u baterijama V2G, [GWh]	**4,86**	**5,45**	**5,97**	**6,61**

Tablica 48. Rezultati proračuna u novom algoritmu za studeni i prosinac 2050. godine za vremenski korak od 1 sat i 10 minuta

Novi model (11_12_2050)	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh]	38,33	34,63	40,35	36,71
REG, [GWh]	24,14	18,7	24,09	18,6
Smanjenje REG u odnosu na NEREG	**37%**	**46%**	**40%**	**49%**
Iskorištena energija u baterijama V2G, [GWh]	**14,19**	**15,93**	**16,26**	**18,11**

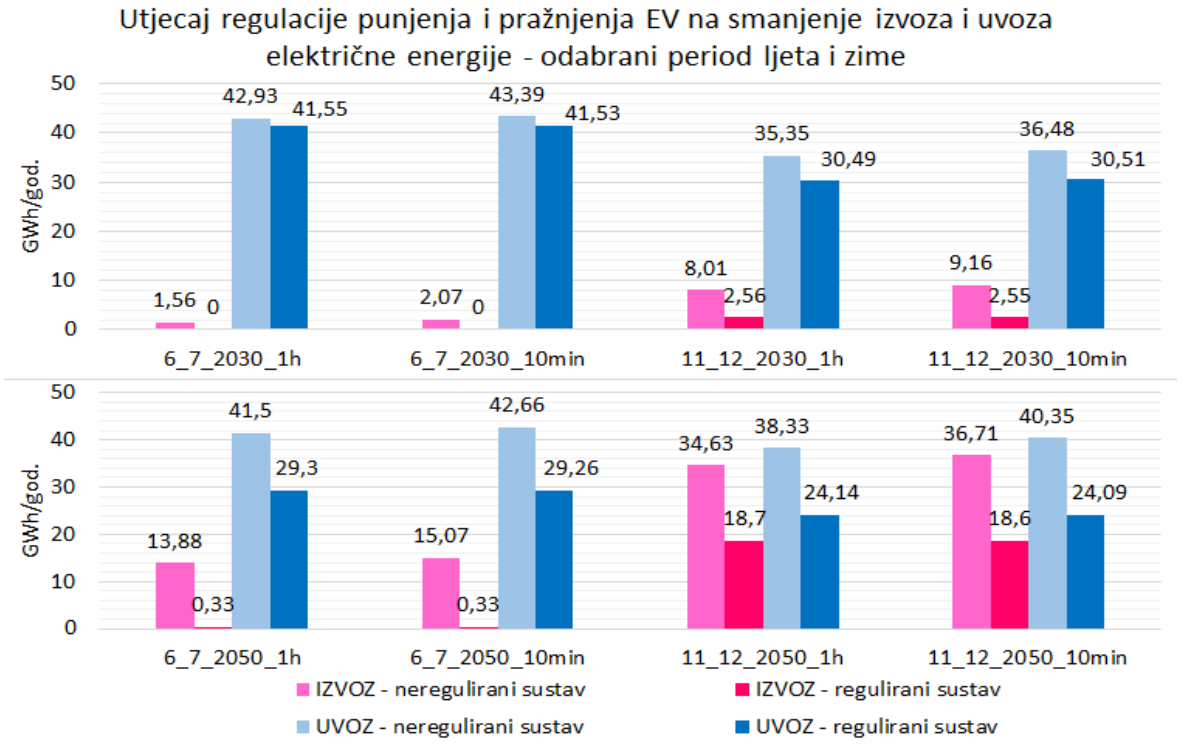

Slika 35. Usporedba rezultata energetskog plana sustava u novom algoritmu s reguliranim i nereguliranim punjenjem i pražnjenjem EV za odabrani ljetni i zimski period za 2030. i 2050. godinu

3.3.1.3 Usporedba rezultata energetskog plana u novom algoritmu za dnevne podatke

Za slučaj S1, gdje imamo maksimalnu bateriju EV na raspolaganju za punjenje i pražnjenje, prikazani su i odabrani dani za 2050. godinu s prikazom energetskih tokova u jednome danu za neregulirani i regulirani sustav. Cilj ovih rezultata je prikaz dnevne usporedbe satnog i 10-minutnog modela sustava, odnosno standardnog i brzog punjenja, i razlika ljetnog i zimskog perioda s obzirom na promjenjivu proizvodnju električne energije iz OIE.

Za usporedbu standardnog i brzog punjenja EV odabrana je treća srijeda u siječnju, 15. siječnja, za scenarij u 2050. godini za vremenski korak od 1 sat i 10 minuta. [Slika 36] prikazuje dijagram za zimski dan u siječnju za vremenski korak od 1 sat i standardno punjenje EV. Vidimo da u nereguliranom sustavu, bez uključenog modela V2G, postoji značajan višak u proizvodnji električne energije iz VE u noćnim i rano jutarnjim satima. Taj višak proizvodnje, uz nedostatak ES, prelazi u izvoz. U poslijepodnevnim i večernjim satima javlja se manjak u proizvodnji električne energije, što zahtjeva uvoz električne energije u sustav, kako bi se zadovoljila potrošnja električne energije iz opće potrošnje (E_{dem}) i za punjenje EV (E_{EVdem}). Ukoliko uvedemo regulaciju punjenja i pražnjenja EV u sustavu, korištenjem modela V2G i G2V, u potpunosti se smanjuje uvoz, dok se izvoz smanji za 50% za odabrani dan. G2V vozila iskorištavaju višak proizvedene energije i spremaju ga u baterije i u periodu manjka proizvodnje nadomještaju nedostatak proizvodnje akumuliranom električnom energijom u baterijama modelom V2G. Iz [Slika 36] vidimo da su se potrebe za uvozom u potpunosti smanjile uvođenjem regulacije punjenja i pražnjenja EV i modela V2G za odabrani dan. Također se uočava i smanjenje izvoza, gdje je dio viška proizvodnje električne energije preusmjeren na BEV.

[Slika 37] prikazuju energetske tokove u BEV i kapacitet baterije u svakom satu za regulirani sustav u kojem je uključen model V2G. Vidimo da je baterija dosegla svoj maksimum napunjenosti, gdje maksimalni kapacitet baterije u ovom scenariju iznosi približno 1165 MWh. Kod punjenja EV, algoritam razlikuje vozila koja se pune uslijed vožnje iz prethodnog sata ($E_{EV,dem,i}$ – EVdem) i vozila koja se pune uslijed viška proizvodnje električne energije iz OIE, G2V vozila, ukoliko su vozila i kapacitet baterije raspoloživi za punjenje. Kod pražnjenja EV razlikuje se pražnjenje baterije uslijed vožnje ($E_{EV,dem,i+1}$ – EVdem-vožnja) i pražnjenje baterije u mrežu za nadomještanje manjka proizvodnje električne energije iz OIE, V2G vozila, ukoliko su vozila i kapacitet baterije raspoloživi za pražnjenje. Pretpostavka u novom algoritmu je da se potrošnja uslijed vožnje za tekući sat puni u sljedećem satu. Krivulja vožnje EV i krivulja punjenja uslijed vožnje prethodno su modelirane i jedan specifičan dan

distribuiran je kroz cijelu godinu. U stvarnosti se ta potrošnja baterije neće nadomještati svaki sat, pa je ova pretpostavka uzeta zbog jednostavnosti proračuna. Iz toga proizlazi da se dio vozila, koji se voze i pune uslijed vožnje, ponašaju prema potrebama i navikama potrošača, vlasnika vozila, i nisu regulirani modelom V2G.

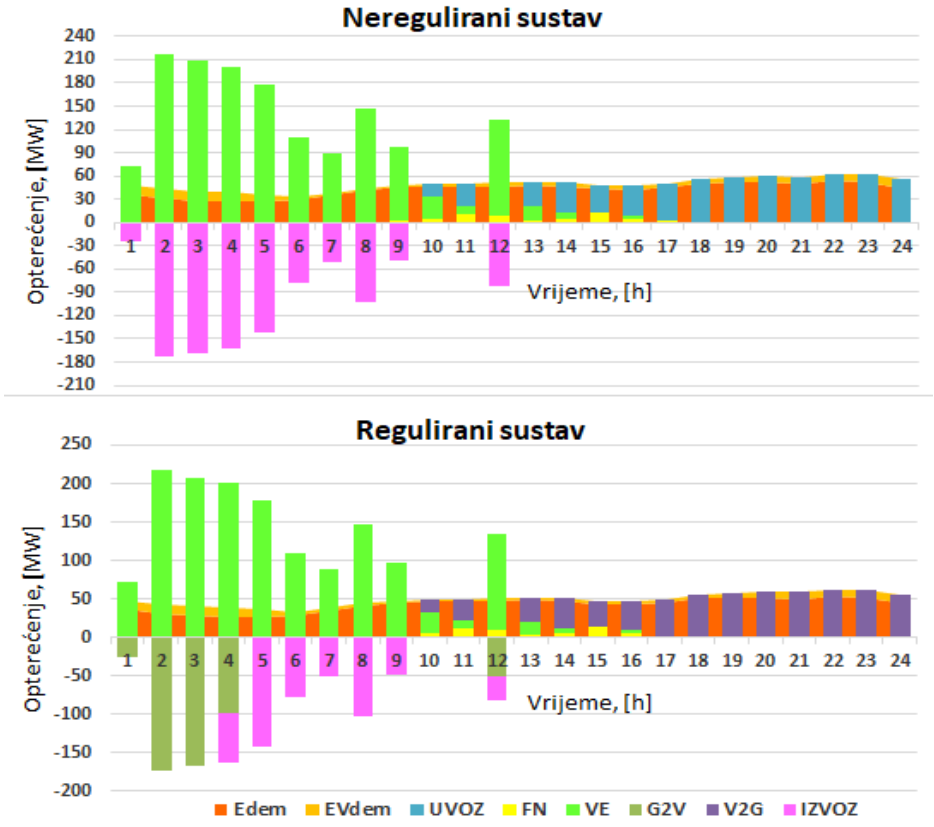

Slika 36. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_1h_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV

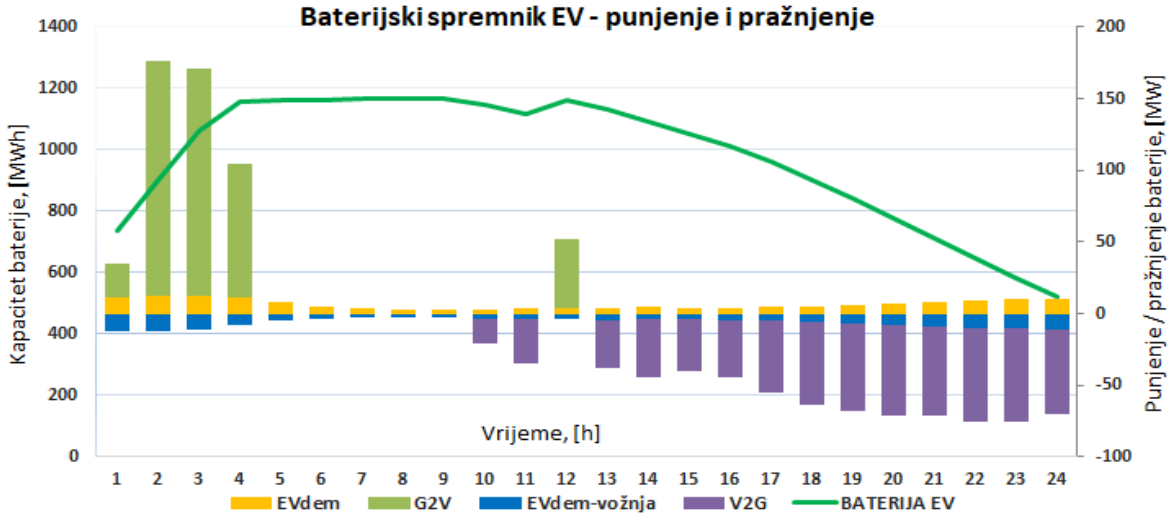

Slika 37. Prikaz energetskih tokova u bateriji EV i kapaciteta baterije za regulirani sustav standardnog punjenja i pražnjenja, 15. siječnja za scenarij 2050_1h_S1.

U [Tablica 49] prikazani su rezultati za odabrane dane. Iz rezultata se vidi da je iskorištena energija u BEV visoka za dan zime i to nešto viša za 10-minutni model. Za odabrani dan ljeta ona je znatno niža, a i izvoz je znatno niži.

Tablica 49. Usporedba scenarija S1 za 2050. godinu za 1 sat i 10 minuta i period ljeta i zime za jedan odabrani dan u godini

Novi model	**15.01.2050._1h**		**15.01.2050._10min**		**16.07.2050._10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [MWh/dan]	646,3	1031,97	694,54	1080,98	815,31	79
REG, [MWh/dan]	0	516,03	0	500,92	744,3	0
Smanjenje REG u odnosu na NEREG	**100%**	**50%**	**100%**	**53,7%**	**8,7%**	**100%**
Iskorištena energija u baterijama V2G, [MWh/dan]	**646,3**	**515,94**	**694,54**	**662,04**	**71,08**	**79**

Za isti odabrani dan u zimskom periodu, prikazani su na [Slika 38] energetski tokovi modela za 10-minutni vremenski korak. Vidimo iz dijagrama da energija u sustavu više varira i pruža više mogućnosti za integraciju OIE. Brzo punjenje time stvara više mogućnosti za fleksibilnost u sustavu. Rezultati su slični onima za vremenski korak od 1 sat i regulacijom EV dolazi do smanjenja uvoza za 100% a izvoza za 53,7%, [Tablica 49]. 10-minutni model ima više zahtjeva za fleksibilnošću u nereguliranom sustavu u odnosu na satni model, što se očituje kroz veći iznos uvoza i izvoza. Međutim, regulacija punjenja i pražnjenja EV pruža nove izvore fleksibilnosti, omogućujući smanjenje uvoza i izvoza, i to izvoza za nešto veći postotak u odnosu na satni model. Iskorištena energija u BEV za brzo punjenje je nešto veća od one za standardno punjenje. [Slika 39] prikazuje dijagram energetskih tokova u BEV i kapacitet baterije u svakom vremenskom koraku. Baterija je također i u ovom scenariju dosegla svoj maksimalni kapacitet koji jednak kao i u standardnom punjenju. U jednom vremenskom trenutku od 10 minuta taj iznos je u dijagramu šest puta veći nego kod standardnog punjenja zbog toga što se ukupna baterija može napuniti u potpunosti u periodu od 10 minuta, što zahtjeva veću snagu punjača, i približno iznosi oko 7000 MW u 10 minuta.

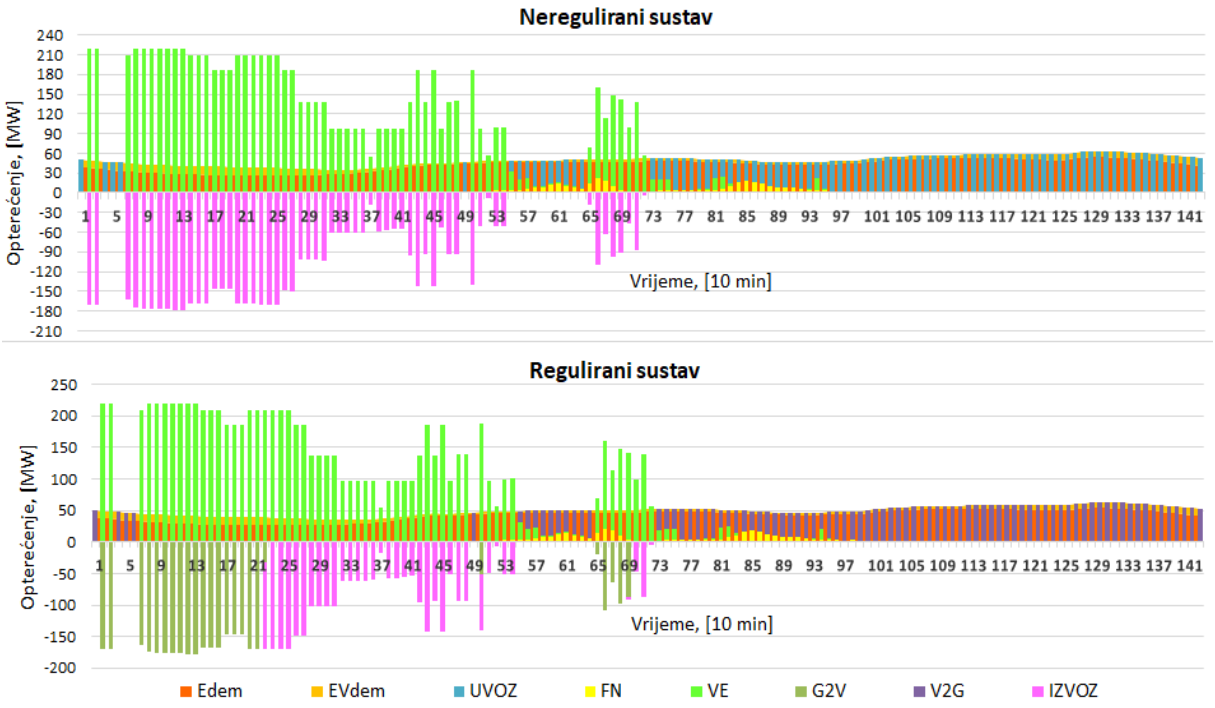

Slika 38. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_10min_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV

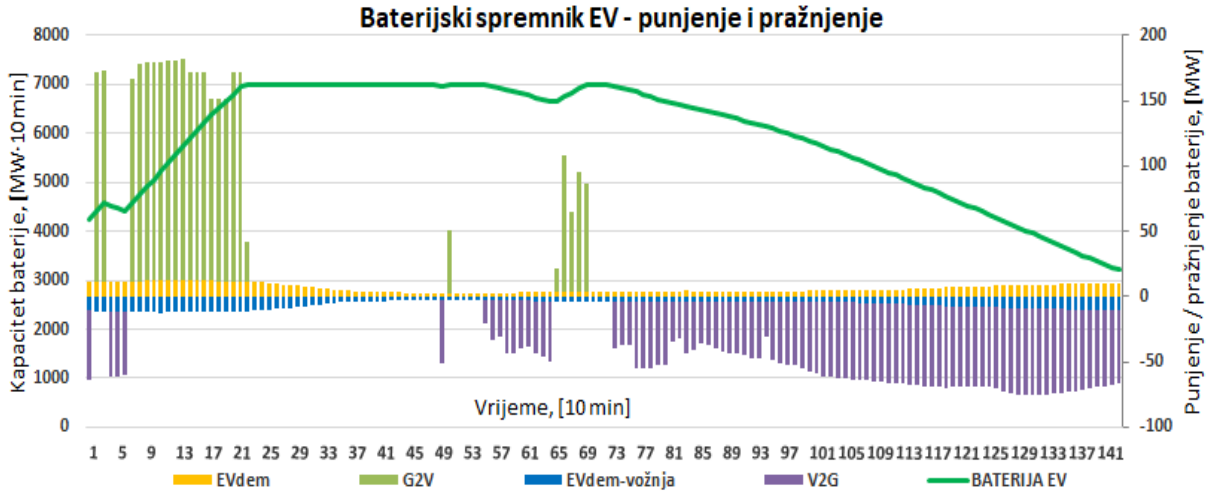

Slika 39. Prikaz energetskih tokova u bateriji EV i kapaciteta baterije za regulirani sustav brzog punjenja i pražnjenja, 15. siječnja za scenarij 2050_10 min_S1.

Kada dan, u periodu zime, usporedimo s danom u periodu ljeta, vidimo da je uvoz za ljetni dan dosta visok, i u usporedbi s danom zime, i uvođenje modela V2G nije dovelo do njegova značajnijeg smanjenja. Uvoz se regulacijom smanji tek za 8,7%, dok se izvoz ipak smanji za 100%, iako je iznos smanjenja izvoza znatno manji nego za zimski dan, [Tablica 49]. Razlog tome je razlika ljeta i zime koju čini proizvodnja električne energije iz OIE. Tokom ljeta imamo povećanu proizvodnju električne energije iz SE (FN), dok je ona iz VE dosta niska,

a u zimskom periodu je obratno, [Slika 40]. Ljeti nije dovoljna instalirana snaga SE da zadovolji potrošnju električne energije, a proizvodnje iz VE je malo, što rezultira potrebama za uvoz električne energije. Višak proizvodnje iz OIE pohranjen je u baterijama i korišten kasnije, međutim nije bio dovoljan pa su porasle potrebe za uvozom. Izvoz se smanjio za 100% uvođenjem regulacije punjenja i pražnjenja u sustav. [Slika 41] prikazuje energetske tokove u BEV, za brzo punjenje i pražnjenje, i kapaciteta baterije za ljetni dan.

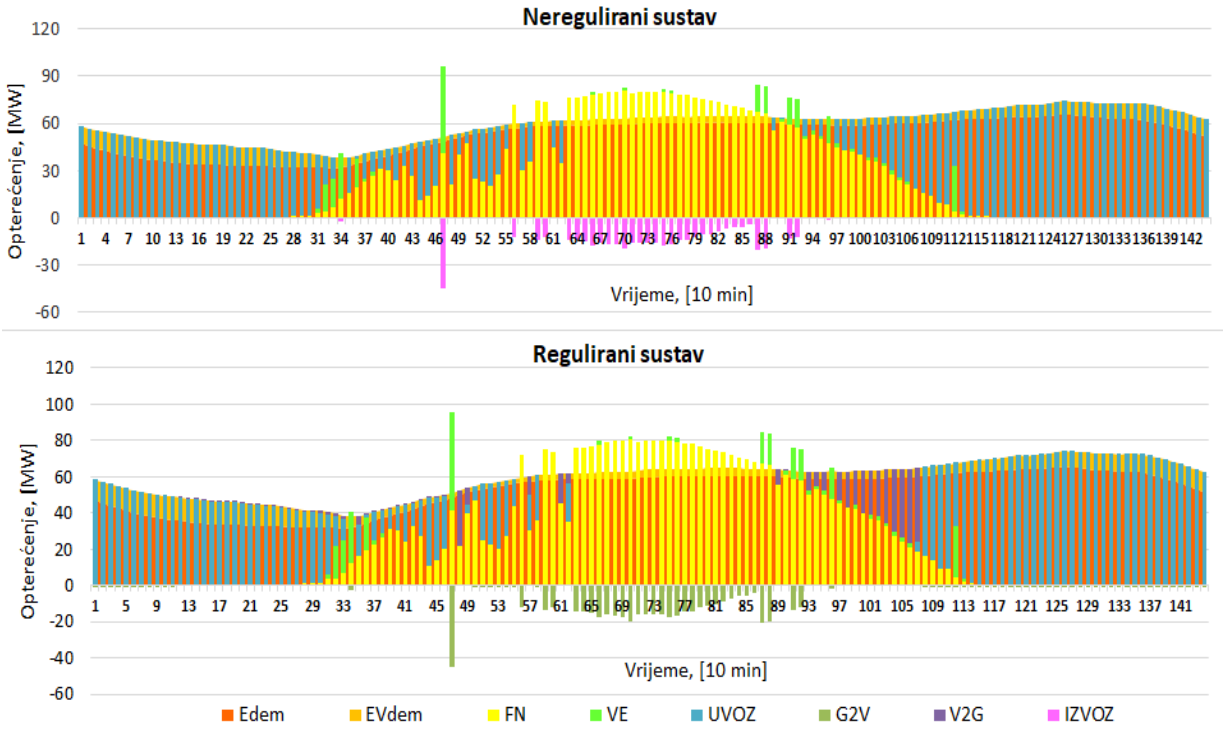

Slika 40. Prikaz energetskih tokova za 16. srpnja za scenarij 2050_10min_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV

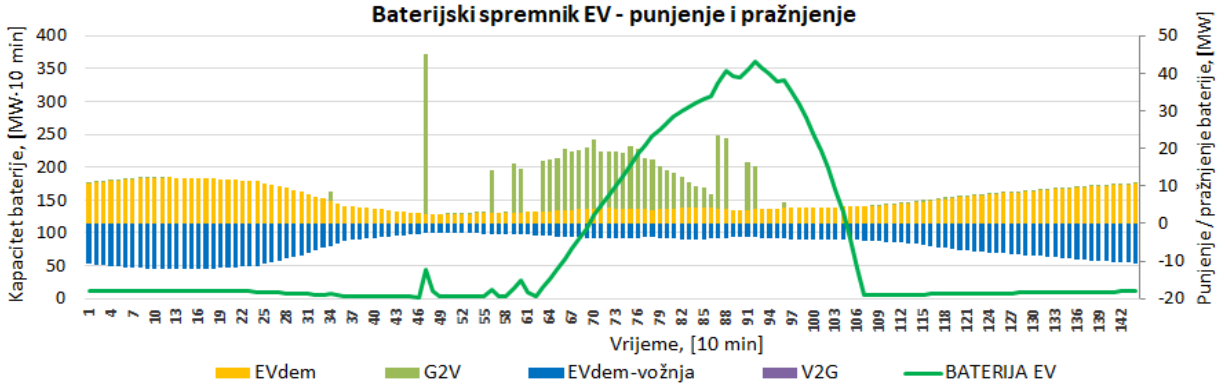

Slika 41. Prikaz energetskih tokova u bateriji EV i kapaciteta baterije za regulirani sustav brzog punjenja i pražnjenja, 16. srpnja za scenarij 2050_10 min_S1.

Vidimo da BEV napuni značajno manji iznos svog kapaciteta u ljetnom danu u usporedbi sa zimskim danom. Također, možemo zaključiti da je proizvodnju električne energije iz SE lakše predvidjeti i ima manja odstupanja od one iz VE, pa bi povećana instalirana snaga značila i smanjenje uvoza korištenjem modela V2G. S druge strane, proizvodnja električne energije iz VE je isprekidana i teško ju je dugoročno predvidjeti. Regulacijom modelom V2G u sustavu može se postići značajno smanjenje uvoza i izvoza, posebice brzim punjenjem. Postoji značajan potencijal kod EV za uspješniju integraciju OIE u energetski sustav, ukoliko je punjenje i pražnjenje EV regulirano, odnosno stimulirano cijenom električne energije.

3.3.2 Rezultati scenarija za slučaj S2

Slučaj S2 uključuje HE Dubrovnik u proizvodnji električne energije odabranog područja, zajedno s VE i SE i njihovim planiranim kapacitetima za 2030. i 2050. godinu. U ovom scenariju također je vrijedila pretpostavka da su sva slobodna vozila na raspolaganju za punjenje u svakom vremenskom trenutku. Analiza je izrađena za maksimalnu bateriju na raspolaganju, odnosno najbolji mogući granični slučaj. U prethodnim scenarijima, koji su uključivali samo VE i SE u proizvodnji električne energije, rezultati su pokazali povećani uvoz u odnosu na izvoz. To upućuje na činjenicu da je u sustavu potrebno još dodatnih instaliranih proizvodnih kapaciteta za snabdijevanje potrošnje. Na odabranom području već postoji instalirana HE Dubrovnik, a u proračunima se koristila njena skalirana distribucija proizvodnje iz 2014. godine prema instaliranoj snazi od 126 MW, i kao takva je ostala u planu za 2030. i 2050. godinu.

Rezultati scenarija S2 za 2030. prikazani su u [Tablica 50], a za 2050. u [Tablica 51]. Rezultati pokazuju da se, uvođenjem HE u sustav, znatno smanjuje uvoz, koji se regulacijom punjenja EV još dodatno smanjuje. Međutim, u tom slučaju dolazi do vrlo visokog porasta izvoza i velikog viška proizvedene električne energije. Tolike viškove EV nisu u mogućnosti uskladištiti u baterijama pa je stoga smanjenje izvoza regulacijom u sustavu jako malo. Usporedba slučaja S1 sa S2 za različite scenarije, prikazana je u dijagramu na [Slika 42]. Iz dijagrama se vidi kako uvođenjem HE uvoz značajno opada dok se izvoz značajno povećava. Obratnu situaciju imali smo u slučaju S1. Za postizanje ravnoteže u sustavu potrebno je mnogo više skladišnih kapaciteta kao i regulacije rada elektrana. To će se pokušati postići integracijom transportnog i toplinskog sektora, te dodatnim skladišnim kapacitetima i integracijom s tržištem električne energije, što će biti analizirano u sljedećim poglavljima u programu Calliope.

Tablica 50. Rezultati slučaja S2 za 2030. godinu za model brzog i standardnog punjenja EV

Slučaj S2_2030. godina	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh/god.]	14,74	694,57	15,09	695,03
REG, [GWh/god.]	6,85	685,26	6,83	685,37
Smanjenje REG u odnosu na NEREG	**53,5%**	**1,3%**	**54,7%**	**1,4%**
Iskorištena energija u baterijama V2G, [GWh/god.]	**7,89**	**9,31**	**8,26**	**9,66**

Tablica 51. Rezultati slučaja S2 za 2050. godinu za model brzog i standardnog punjenja EV

Slučaj S2_2050. godina	**1h**		**10min**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh/god.]	16,07	792,34	16,65	793,19
REG, [GWh/god.]	5,57	779,41	5,52	779,63
Smanjenje REG u odnosu na NEREG	**65,4%**	**1,6%**	**66,8%**	**1,7%**
Iskorištena energija u baterijama V2G, [GWh/god.]	**10,5**	**12,93**	**11,13**	**13,56**

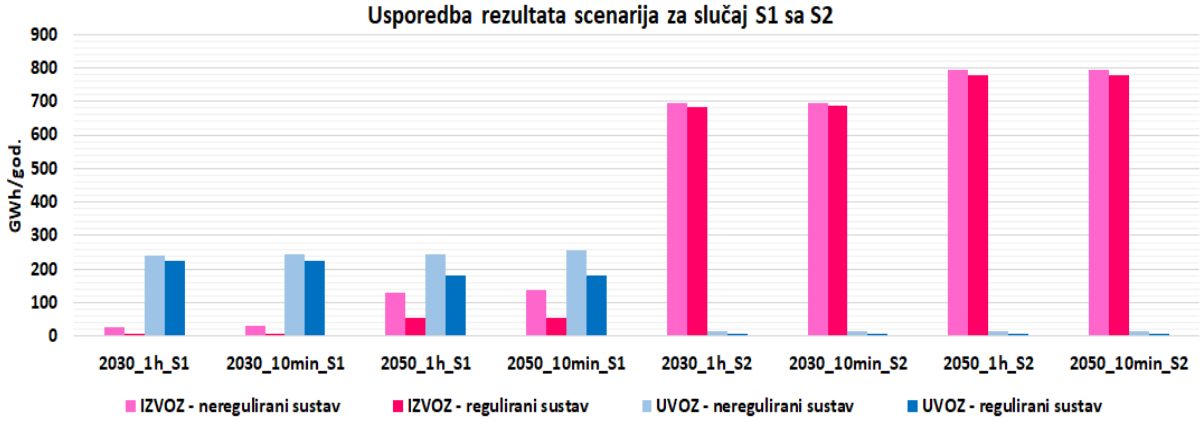

Slika 42. Usporedba rezultata scenarija za slučaj S1 sa S2 za 2030. i 2050. godinu i model brzog i standardnog punjenja

3.3.3 Rezultati scenarija za slučaj S3

Slučaj S3 uključuje ispitivanje minimalne baterije EV, koja mora biti na raspolaganju, da bi se zadovoljio jednak rezultat smanjenja uvoza i izvoza, regulacijom punjenja i pražnjenja EV, kao onaj za pretpostavku da su sva slobodna vozila na raspolaganju za punjenje u svakom vremenskom trenutku. Rezultati su pokazali da, za regulirano iznimno brzo punjenje i pražnjenje EV, već 3% vozila u 2030. i u 2050. godini, na raspolaganju za punjenje i pražnjenje u svakom vremenskom trenutku, daje jednake rezultate pretpostavci da su sva slobodna vozila

na raspolaganju za punjenje i pražnjenje. Kod standardnog punjenja, taj uvjet je zadovoljen s 65% vozila u 2030. i 80% vozila u 2050. godini na raspolaganju za svaki vremenski korak. Može se primijetiti da, kod standardnog punjenja, potreban udio EV raste u 2050. godini kako raste i broj instaliranih kapaciteta OIE, do 100% u proizvodnji električne energije, iako se u 2050. broj EV u sustavu također povećao do 100%. Kod iznimno brzog punjenja to nije slučaj. U 2050. godini također je došlo do povećanja OIE i EV do 100% u sustavu, međutim, minimalno potreban udio EV od 3%, za ostvarenje maksimalno najboljeg rezultata, se održao i u 2050. Rezultati analize prikazani su u [Tablica 52]. Vidimo da je postotak, prema tome i ukupni broj EV, potreban u svakom satu da se ostvari najbolji mogući rezultata, znatno veći kod standardnog punjenje nego kod brzog. Iznimno brzo punjenje će u 2030. i u 2050. s 3% vozila, spojenih na mrežu u svakih 10 minuta, postići najbolji mogući slučaj smanjenja uvoza i izvoza u sustavu, korištenjem reguliranog V2G i G2V modela. Priključna snaga u svakom vremenskom trenutku veća je za brzo punjenje i to za oko 25 MW u 2030. i u 2050. godini. Ako se uzme u obzir usporedba standardnog i iznimno brzog punjenja i pražnjenja EV na satnoj razini, priključna snaga za brzo punjenje je šest puta veća u jednome satu.

Usporedba standardnog i iznimno brzog G2V i V2G modela prikazana je na [Slika 43], za podatke u jednome satu. Vidimo da, za isto vremensko razdoblje, iznimno brzo punjenje i pražnjenje zahtjeva dosta manji broj EV priključenih na mrežu od standardnog punjenja i pražnjenja. Pri tome akumulira veću količinu energije u BEV, međutim, zahtjeva dosta veće priključne snage punjača. Stoga se može zaključiti i po ovoj analizi, da brzo punjenje, uz regulaciju i V2G model, pruža više mogućnosti za fleksibilnost u sustavu od standardnog punjenja. Priključnu snagu EV u svakom vremenskom trenutku možemo usporediti s maksimalnim opterećenjem na TS Komolac uslijed opće potrošnje energije odabranog područja. Prema energetskom planu, ono bi iznosilo 70,84 MW u 2030. i 82,41 MW u 2050. godini. Prema ovoj usporedbi možemo vidjeti za koliko bi se otprilike povećalo opterećenje mreže kod uvođenja EV u sustav, a koje bi, prema modelu, dalo najbolje rezultate.

Tablica 52. Rezultati potrebne minimalne BEV za standardno i brzo punjenje i pražnjenje EV u slučaju S3 za jednak rezultat smanjenja uvoza i izvoza kao u slučaju S1

Vremenski korak	**1h**		**10min**	
Godina	**2030.**	**2050.**	**2030.**	**2050.**
Postotak EV priključenih na mrežu	65%	80%	3%	3%
Broj EV priključen na mrežu	5150	14909	238	559
Priključna snaga iz mreže, [MW]	68,15	197,28	94,07	221,27

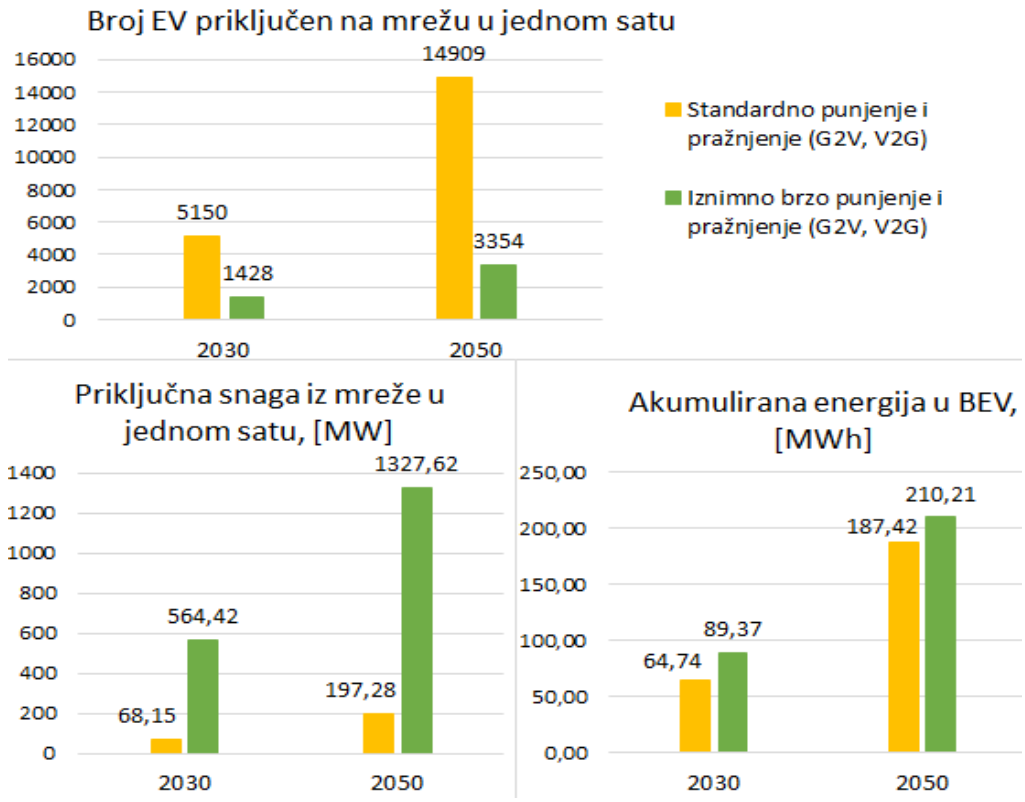

Slika 43. Usporedba rezultata standardnog i iznimno brzog punjenja i pražnjenja EV primjenom reguliranog modela G2V i V2G za jedan sat

U [Tablica 53] dana je usporedba rezultata smanjenja uvoza i izvoza električne energije, regulacijom brzog i standardnog punjenja i pražnjenja, za minimalnu bateriju koja je dobivena za slučaj brzog punjenje.

Tablica 53. Usporedba rezultata za brzo i standardno punjenje i pražnjenje EV kod minimalne baterije na raspolaganju za punjenje i pražnjenje za 2030. godinu

Slučaj S3_2030. godina		**1h**		**10min**	
$Batt_{MIN}$ = 3% x $Batt_{MAX}$	**Regulacija punjenja i pražnjenja EV**	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
	NEREG, [GWh/god.]	238,93	25,02	243,44	29,65
	REG, [GWh/god.]	238,92	24,9	224,44	8,51
	Smanjenje REG u odnosu na NEREG	**0,0%**	**0,5%**	**7,8%**	**71,3%**
	Iskorištena energija u baterijama V2G, [GWh/god.]	**0,01**	**0,12**	**19**	**21,14**

Korištenjem minimalne BEV na raspolaganju, od 3%, za standardno punjenje, vidimo da su rezultati smanjenja uvoza i izvoza iznimno niski. Smanjenje regulacijom u tom slučaju je

minimalno, ili ga zapravo uopće nema. Iako kod standardnog punjenja u tom slučaju imamo malo opterećenje na mreži, 3,15 MW u 2030. i 7,40 MW u 2050., ono ne daje zadovoljavajuće rezultate za integraciju OIE u sustav.

Tablica 54. Usporedba rezultata za brzo i standardno punjenje i pražnjenje EV kod minimalne baterije na raspolaganju za punjenje i pražnjenje za 2050. godinu

Slučaj S3_2050. godina		**1h**		**10min**	
$Batt_{MIN}$ = 3% x $Batt_{MAX}$	**Regulacija punjenja i pražnjenja EV**	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
	NEREG, [GWh/god.]	245,31	127,84	255,33	138,14
	REG, [GWh/god.]	244,95	127,25	180,11	53,5
	Smanjenje REG u odnosu na NEREG	**0,1%**	**0,5%**	**29,5%**	**61,3%**
	Iskorištena energija u baterijama V2G, [GWh/god.]	**0,36**	**0,59**	**75,22**	**84,64**

3.3.4 Rezultati scenarija za slučaj S4

U ovom poglavlju dat će se usporedba P2T modela cijena električne energije s V2T modelom s obzirom na smanjenje uvoza i izvoza električne energije, odnosno poticanje integracije OIE u proizvodnji električne energije u sustav. Pretpostavka je da će V2T model pružiti više mogućnosti za integraciju OIE u proizvodnji električne energije u sustavu.

P2T model cijena električne energije sadrži dvije tarife za cijenu električne energije. Viša tarifa vrijedi za dnevnu potrošnju električne energije i iznosi 0,84 kn/kWh, a niža tarifa vrijedi za noćnu potrošnju i iznosi 0,41 kn/kWh. Cijene su izražene bez PDV-a i preuzete sa HEP ELEKTRA d.o.o. [156] za bijeli model cijena za kućanstva. U ljetnom razdoblju, od 30. ožujka do 30. listopada, viša tarifa se primjenjuje u periodu od 8 do 22 sata, a u zimskom razdoblju, ostatka godine, u periodu od 7 do 21 sat. Regulacija punjenja, G2V, i pražnjenja, V2G, EV u primjeni P2T modela, napravljena je s pretpostavkom da se vozila pune za vrijeme niske tarife, noću, a prazne u vrijeme visoke tarife, danju. S obzirom da je krivulja opće potrošnje niža tokom noći, to bi značila poravnanje krivulje potrošnje punjenjem EV tijekom noći. Tijekom dana bi se vozila praznila i davala energiju sustavu ukoliko postoji manjak u proizvodnji električne energije i ukoliko to dozvoljava raspoloživi kapacitet baterije. Međutim, proizvodnja električne energije iz OIE je nestalna i teško predvidiva, stoga ovakav način regulacije ne odgovara poboljšanju integracije OIE u sustav, već samo poravnanju krivulje potrošnje, ukoliko ostali uvjeti to dozvoljavaju.

Stoga se napravila usporedba P2T i V2T modela cijena električne energije. V2T model je uveden kako bi potaknuo integraciju OIE u sustav, čime su cijene raspodijeljene na način da je viša tarifa zastupljena u periodu manjka proizvodnje električne energije iz OIE, a niža u vrijeme viška proizvodnje električne energije. Time se potiče vlasnike vozila da V2G model koriste u vrijeme visoke cijene i time ostvare zaradu, a modelom G2V se koriste u vrijeme niske cijene i plaćaju manju cijenu električne energije za punjenje vozila. Pretpostavka je da će vlasnici EV svoja vozila, osim za vožnju, koristit kako bi ostvarili zaradu na njima sudjelovanjem u regulaciji energetski tokova. Činjenica je da učestalo pražnjenje i punjenje baterije smanjuje njen vijek trajanja. U ovom radu nije se radila analiza isplativosti već samo korist od V2G modela s obzirom na pretpostavljene cijene. Cijene više i niže tarife u V2T modelu jednake su onima u P2T modelu, kako bi se mogla napraviti valjana usporedba koristi od V2G modela. Usporedbe su napravljene za model standardnog i brzog punjenja za 2050. godinu.

Rezultati za slučaj S4 prikazani su u [Tablica 55]. U analizama su uzeti scenariji za slučaj S1, koji uključuje pretpostavku da su sva slobodna vozila raspoloživa za punjenje i pražnjenje u svakom trenutku, a proizvodnja iz OIE uključuje VE i SE za 2050. godinu. Oni su se usporedili i sa slučajem S3, za minimalno potrebnu bateriju da se ostvari jednak rezultat onome iz S1 slučaja. Minimalna baterija za brzo punjenje iznosila je 3% EV koja su u svakom trenutku raspoloživa za punjenje. Taj postotak je, radi usporedbe, primijenjen i na standardno punjenje. Slučaj S4 analizira utjecaj regulacije punjenja i pražnjenja EV na uvoz i izvoz energije u sustavu u odnosu na neregulirani sustav. Analize su rađene za standardno i brzo punjenje i pražnjenje. Rezultati prikazuju postotak smanjenja uvoza i izvoza uvođenjem regulacije u sustav, kao i količinu električne energije iskorištene u BEV za modele V2G i G2V.

Rezultati za standardno i brzo punjenje su približno jednaki. U slučaju brzog punjenja, veći je postotak smanjenja uvoza i izvoza u odnosu na neregulirani sustav, kao i količina električne energije koja se u baterijama iskoristi za V2G i G2V. Stoga možemo reći da brzo punjenje pruža više mogućnosti za integraciju OIE u sustav. Međutim, u slučaju maksimalno raspoložive baterije su rezultati za standardno i brzo punjenje približno jednaki i ne vidi se veća razlika jer brzo punjenje ne može iskoristiti svoj maksimalni kapacitet. Kada se isti pristup primjeni za slučaj minimalne baterije, slučaj S3, rezultati su u puno većoj mjeri u korist brzog punjenja, kako je to i pokazano u [Tablica 55]. Prema slučaju S3, za primjenu V2T modela regulacije kod standardnog punjenja, vidimo da se uvoz čak povećao za skoro 23%. Smanjenje uvoza i izvoza kod standardnog punjenja, primjenom P2T i V2T modela regulacije prema slučaju S3, su znatno manja nego kod brzog punjenja, a čak postoji i porast. Stoga, možemo

zaključiti da brzo punjenje i u ovom slučaju daje bolje rezultate kod realnog pristupa, odnosno slučaja S3. Naime, kod minimalne baterije za brzo punjenje, koja iznosi 3% vozila koja su u svakom trenutku raspoloživa za punjenje, daje jednake rezultate kao i u slučaju S1, za pretpostavku da su sva vozila raspoloživa za punjenje u svakom vremenskom trenutku, odnosno raspoloživa je maksimalna baterija.

Tablica 55. Rezultati scenarija za 2050. godinu za slučaj S4 – usporedba P2T i V2T modela cijena u regulaciji standardnog i brzog punjenja i pražnjenja EV

Slučaj S4_2050. godina	**1h prema S1**		**1h prema S3**		**10min prema S1 i S3**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh/god.]	245,31	127,84	245,31	127,84	255,33	138,14
REG - P2T, [GWh/god.]	218,98	96,76	245,27	127,7	222,27	100,23
REG - V2T, [GWh/god.]	180,22	53,65	300,7	127,25	180,09	53,46
Smanjenje REG u odnosu na NEREG – P2T	**10,7%**	**24,3%**	**0%**	**0,1%**	**12,9%**	**27,4%**
Smanjenje REG u odnosu na NEREG – V2T	**26,5%**	**58%**	**-22,6%**	**0,5%**	**29,5%**	**61,3%**
Iskorištena energija u baterijama V2G – P2T, [GWh/god.]	**26,33**	**31,08**	**0,04**	**0,14**	**33,06**	**27,91**
Iskorištena energija u baterijama V2G – V2T, [GWh/god.]	**65,09**	**74,19**	**-**	**0,59**	**75,24**	**84,68**

Vidimo iz rezultata da regulacija punjenja i pražnjenja cijenama električne energije, prema P2T modelu cijena, rezultira znatno nižim smanjenjem uvoza i izvoza u odnosu na regulirani sustav prema V2T modelu cijena. Postotak smanjenja uvoza i izvoza, kao i količina akumulirane i iskorištene energije u baterijama EV prema slučaju S1, su za 50% manji za P2T nego V2T, a razlika je još veća kod brzog punjenja. Stoga možemo zaključiti, ukoliko želimo potaknuti integraciju i penetraciju OIE i EV u sustav, regulacija energetskih tokova u sustavu mora biti varijabilna kao što je i sama proizvodnja električne energije iz OIE. Regulaciju energetskih tokova najbolje je postići cijenama električne energije koje će stimulirati kako potrošače tako i proizvođače i skladišta električne energije. U sustavu s visokim udjelom OIE u proizvodnji električne energije bolje bi bilo težiti ka tome da potrošnja bude varijabilna i prati proizvodnju električne energije. Time bi se omogućila bolja integracija OIE u sustav, a to se najbolje može postići varijabilnim cijenama električne energije. Ovdje je razmatran slučaj dvije varijabilne tarife, međutim, može se očekivati da bi varijabilnost cijena na više od dvije razine

dala još bolje rezultate u pogledu regulacije energetskih tokova. U ovom poglavlju taj slučaj nije razmatran.

Dodatnu stimulaciju za porast udjela EV u sustav, također mogu potaknuti varijabilne cijene električne energije koje uz regulaciju u sustavu nude vlasnicima mogućnost da baterije svojih EV, osim za vožnju, koriste i kao izvor dodatne zarade. To se može ostvariti primjenom V2G i G2V modela koji su stimulirani cijenama električne energije. G2V se koristi u vrijeme viška proizvodnje iz OIE, kad je i cijena električne energije niža, i time se smanjuje izvoz a vozila se pune po niskoj cijeni električne energije. V2G se koristi u vrijeme manjka proizvodnje električne energije, kada je cijena visoka, i u mogućnosti su uprihoditi zaradu, prodajući uskladištenu energiju po visokoj cijeni i smanjujući uvoz električne energije u sustav. Takva mogućnost ispitana je u slučaju S4 za odabrane scenarije iz [Tablica 55] i rezultati su prikazani na dijagramu [Slika 44].

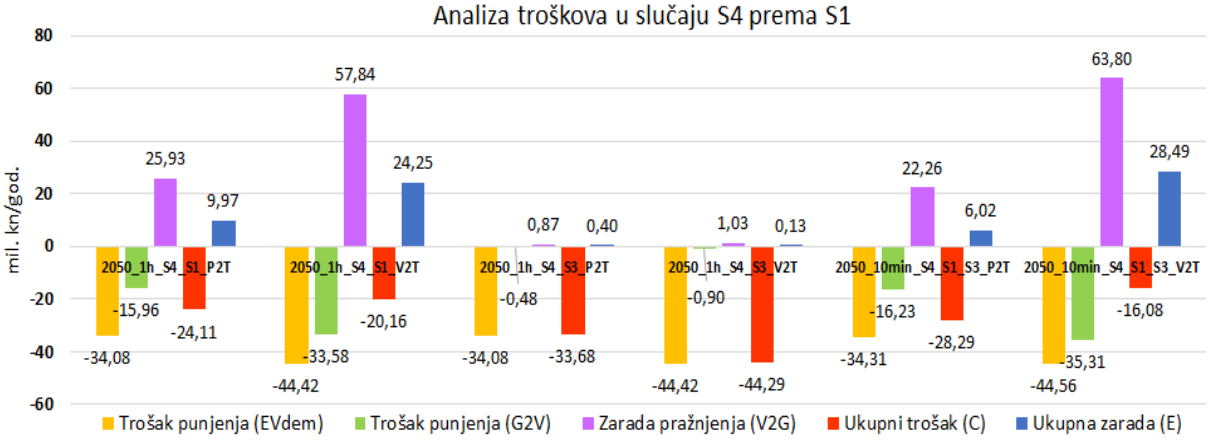

Slika 44. Analiza troškova u slučaju S4 za 2050. godinu prema S1 i S3 – usporedba P2T s V2T modelom cijena električne energije u regulaciji standardnog i brzog punjenja i pražnjenja

Rezultati na [Slika 44] prikazani su kako bi se usporedili troškovi i prihodi standardnog i brzog punjenja i pražnjenja, P2T i V2T modela regulacije, kao i slučaj S4 prema S1 i S3. Iz rezultata na dijagramu vidi se da je trošak punjenja dijela vozila, koji je modeliran prema navikama i potrebama potrošača i nije reguliran cijenama električne energije, EV_{dem}, veći od dijela punjenja prema G2V modelu, koji je reguliran cijenama. Ta razlika je izraženija kod regulacije prema P2T modelu nego kod V2T modela. Razlog tome je varijabilnost cijena u V2T modelu koji EV omogućuje da iskoriste više energije iz viška proizvodnje prema nižoj tarifi prema G2V modelu, čime ukupni trošak raste. Na taj način EV pružaju više mogućnosti za integraciju OIE u sustav. U slučaju S3 za standardno punjenje, trošak za G2V je značajno manji nego u slučaju S1 za standardno punjenje, kao i u oba slučaja za brzo punjenje. To znači da minimalna baterija od 3%, kod standardnog punjenja, nije dovoljna da po nižoj tarifi

omogući skladištenje viška proizvodnje električne energije iz OIE. Najveći trošak uslijed punjenja EV prema G2V modelu je kod brzog punjenja za 10-minutni model s primjenom V2T regulacije.

Zarada V2G modelom, primjenom regulacije prema V2T, je znatno veća nego regulacijom prema P2T. Pa i u ovom slučaju V2G model pruža više opcija za integraciju OIE u sustav kod varijabilnih cijena električne energije. Zarada je najveća za brzo punjenje i pražnjenje i primjenu V2T regulacije. Zarada je znatno manja za slučaj S3 i standardno punjenje, što je i za očekivati jer je broj raspoloživih vozila za pražnjenje znatno manji u svakom trenutku. Ukupna zarada, koju predstavlja plavi stupac na dijagramu, rezultat je razlike zarade od V2G i troška od G2V modela, bez uključivanja troška punjenja od EV_{dem}, a prikazana je i jednadžbom (27). Vidimo da na godišnjoj razini vozila u konačnici ostvaruju zaradu, u svim modelima, ako samo promatramo razliku između zarade od V2G i troška od G2V. Najveća zarada je ostvarena u sustavima s primjenom regulacije V2T modelom cijena električne energije. Ako se uzme u obzir i trošak od EV_{dem}, prema jednadžbi (26), onda na godišnjoj razini vozila ostvaruju trošak, koji je prikazan crvenim stupcem. To je i za očekivat jer se baterije, osim za skladištenje i trgovanje energijom, koriste i u vožnji EV. Međutim, uvođenjem V2T modela regulacije, ukupni trošak za punjenje vozila se znatno smanjuje primjenom V2G modela. Smanjenje je najveće kod regulacije V2T modelom i za slučaj S1. Kod standardnog punjenja i pražnjenja EV ono iznosi 74%, a kod brzog je nešto veće i iznosi 80%.

Ako promatramo samo neregulirani sustav, gdje imamo samo punjenje EV (EVdem), koje je određeno prema navikama i potrebama vozača, u P2T modelu oni ostvaruju manji trošak jer je punjenje vozila povećano tijekom noći, kad su vozila parkirana a cijena električne energije je uređena prema manjoj tarifi. U reguliranom sustavu je trošak ipak veći jer punjenje EV prema EVdem nije regulirano. Uvođenjem modela V2G i G2V, ukupni trošak EV na godišnjoj razini se smanjuje i EV mogu ostvariti uštede, što je i prikazano plavim stupcem. Najveća ušteda ostvaruje se u V2T modelu s brzim punjenjem i iznosi oko 200 EUR/EV god. (1530 kn/EV god.; 214 USD/EV god.). Standardno punjenje ostvaruje oko 170 EUR/EV god (1300 kn/EV god.; 182 USD/EV god.), (tečaj srpanj, 2022. – 1 kn = 0,13 EUR; 1 kn = 0,14 USD). Dobiveni rezultati poklapaju se s rezultatima prethodnih studija o uštedama uvođenjem regulacije punjenja EV u odnosu na neregulirano punjenje [132], [133]. Rezultati iz prethodnih studija odnosili su se samo na analize punjenja EV, dok je u ovom radu promatran V2G model.

Za model regulacije V2T cijenama električne energije, najveća ukupna zarada i najmanji ukupni trošak ostvareni su za brzo punjenje. To dovodi do zaključka da brzom

punjenju, za vremenski korak od 10 minuta, odgovaraju varijabilne cijene električne energije. Suprotno tome, najveću ukupnu zaradu i najmanji ukupni trošak za P2T model cijena, ostvaruje standardno punjenje. Međutim, i kod standardnog punjenja, V2T model cijena električne energije daje bolje rezultate u odnosu na P2T model.

Vlasnici EV svakako mogu ostvariti korist primjenom V2G i G2V modela uz regulaciju energetskih tokova prema V2T modelu cijena u načinu korištenja EV. Takvom primjenom može se potaknuti integraciju OIE u sustav, kao i penetraciju i korištenje EV u transportu. Vlasnici u tom slučaju mogu u bržem roku isplatiti svoja EV, čije su cijene trenutno dosta više u odnosu na KV. Povećano korištenje EV utječe na pad cijene samih vozila pa se otvara više mogućnosti za njihovu primjenu.

3.4 Rezultati energetskog plana u programu Calliope – integracija transportnog i toplinskog sektora

U programu Calliope objedinjeni su svi sudionici odabranog energetskog sustava šireg gradskog područja. Integracija i regulacija transportnog i toplinskog sektor napravljena je u cilju povećanja izvora fleksibilnosti, smanjenja uvoza i izvoza električne energije i bolje integracije OIE u sustav. Napravljena je usporedba planiranog sustava modeliranog za satni i 10-minutni vremenski korak. Regulacija energetskih tokova postignuta je varijabilnim cijenama električne energije, vezom s tržištem električne energije. Pretpostavka je da će sustav, modeliran za 10-minutni vremenski korak i reguliran varijabilnim cijenama električne energije, pružiti više izvora fleksibilnosti u sustavu za bolju integraciju OIE.

3.4.1 Usporedba novog algoritma s programom Calliope za slučaj S1

Za usporedbu novog algoritma i programa Calliope odabran je jedan dan zime, treća srijeda u siječnju, 15.01., a usporedili su se i rezultati na godišnjoj razini. Usporedili su se rezultati za slučaj S1 za 2050. godinu i za vremenski korak od 1 sat i 10 minuta. Ulazni podaci za Calliope su jednaki onima za novi algoritam za slučaj S1. Analiziralo se dnevno i godišnje smanjenje uvoza i izvoza uvođenjem regulacije punjenja i pražnjenja EV u sustav.

3.4.1.1 Rezultati usporedbe satnog modela

U [Tablica 56] prikazani su rezultati usporedbe nereguliranog punjenja EV i reguliranog punjenja i pražnjenja s modelom V2G za vremenski korak od 1 sat. Vidimo iz rezultata da su se uvoz i izvoz, uvođenjem regulacije punjenja i pražnjenja uz V2G, smanjili u jednakom postotku u novom algoritmu i Calliope-u. U rezultatima se uočava razlika između iznosa dnevnog uvoza i izvoza u nereguliranom sustavu u novom algoritmu i Calliopeu. Ta razlika je jednaka za izvoz i uvoz i iznosi oko 74 MWh u danu. Razlika postoji zbog toga što

novi algoritam u nereguliranom sustavu, za svaki vremenski korak, puni BEV za onaj iznos koji je u prethodnom koraku potrošen na vožnju. Calliope, u nereguliranom sustavu, radi na način da vozila puni u vrijeme viška proizvodnje električne energije. Kao rezultat toga manji je izvoz jer se više energije preusmjerilo u BEV, 74 MWh više, dok se uvoz smanjio za taj iznos jer BEV na vožnju troši kapacitet koji je prethodno napunjen u vrijeme viška proizvodnje. Taj iznos odgovara ostatku punjenja EV u novog algoritmu, koje je raspoređeno na sve vremenske korake u danu. Iskorištena energija u baterijama nešto je veća u novom algoritmu nego u programu Calliope, upravo zbog većeg iznosa uvoza i izvoza u novom algoritmu. Iskorištena energija u baterijama zapravo predstavlja razliku između iznosa uvoza u nereguliranom i reguliranom sustavu, kao i razliku izvoza jednog i drugog sustava.

Tablica 56. Usporedba rezultata novog algoritma i programa Calliope za 15.01.2050. godine za slučaj S1 i vremenski korak od 1 sat

Slučaj S1_15_1_2050. godina_1h	**Novi algoritam**		**Calliope**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [MWh/dan]	590,86	1120,66	516,59	1046,9
REG, [MWh/dan]	0	516,03	0	474,5
Smanjenje REG u odnosu na NEREG	**100%**	**54%**	**100%**	**54,7%**
Iskorištena energija u baterijama V2G, [MWh/dan]	**590,86**	**604,63**	**516,59**	**572,4**

[Slika 45] prikazuje energetske tokove u sustavu. Vidimo da uvođenjem regulacije u sustav, uz model V2G, dolazi i do smanjenja uvoza i izvoza u novom algoritmu. Uvoz se smanjio punjenjem EV u vrijeme viška proizvodnje električne energije, G2V, a izvoz pražnjenjem EV u mrežu za vrijeme manjka proizvodnje, V2G. [Slika 46] prikazuje energetske tokove u bateriji i kapacitet baterije u svakom satu za regulirani sustav.

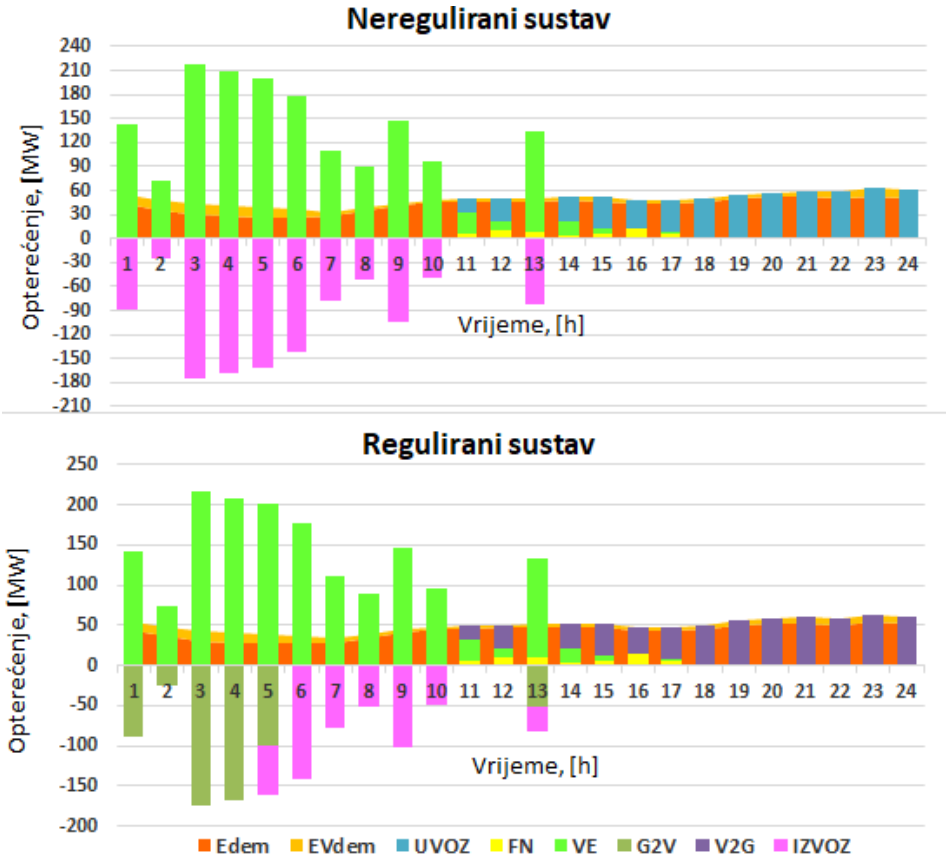

Slika 45. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_1h_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV u novom algoritmu

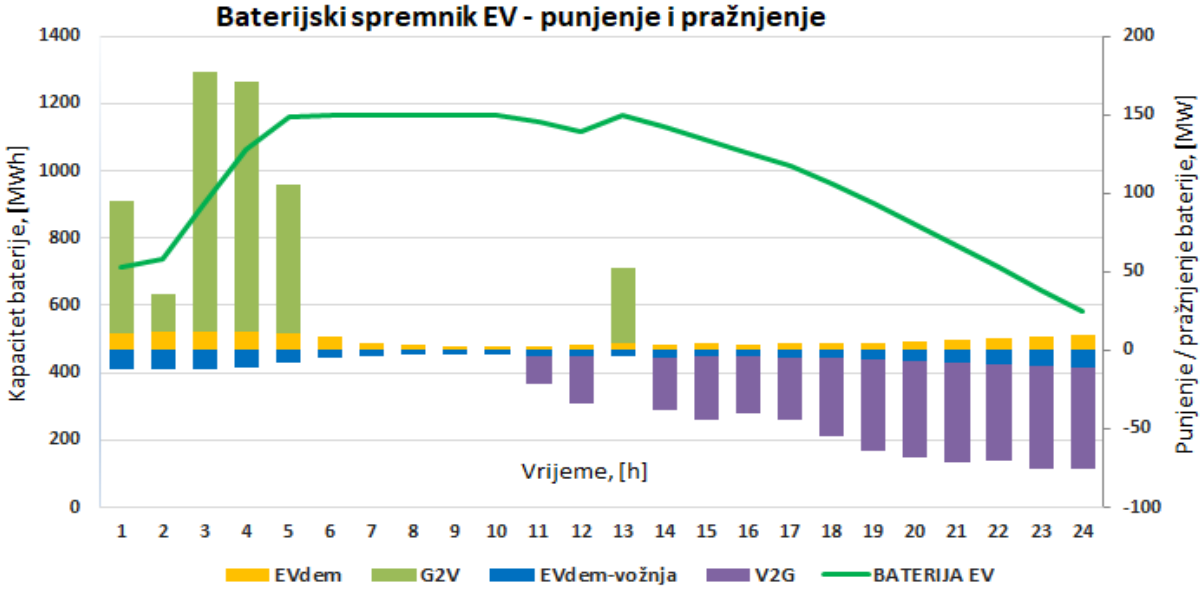

Slika 46. Prikaz energetskih tokova u BEV i kapaciteta baterije za regulirani sustav standardnog punjenja i pražnjenja u novom algoritmu, 15. siječnja za scenarij 2050_1h_S1

[Slika 47] prikazuje energetske tokove u programu Calliope za neregulirani i regulirani sustav. U reguliranom sustavu također se uočava smanjenje uvoza i izvoza u odnosu na neregulirani sustav. [Slika 48] na lijevom dijagramu prikazuje energetski tokovi u bateriji i kapacitet baterije u nereguliranom sustavu, a na desnom u reguliranom sustavu.

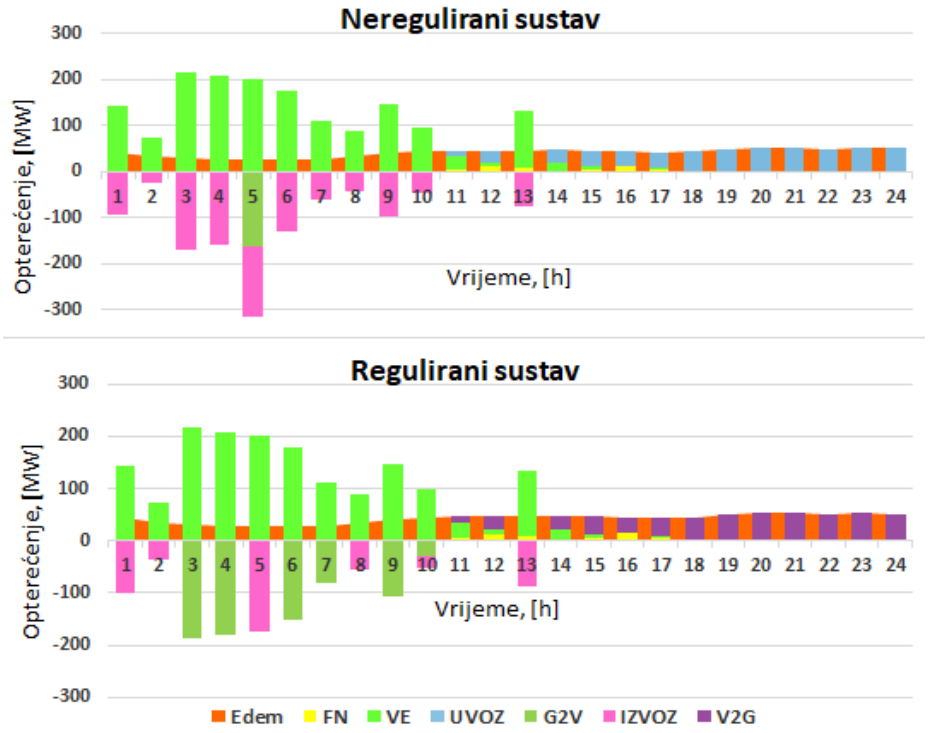

Slika 47. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_1h_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV u programu Calliope

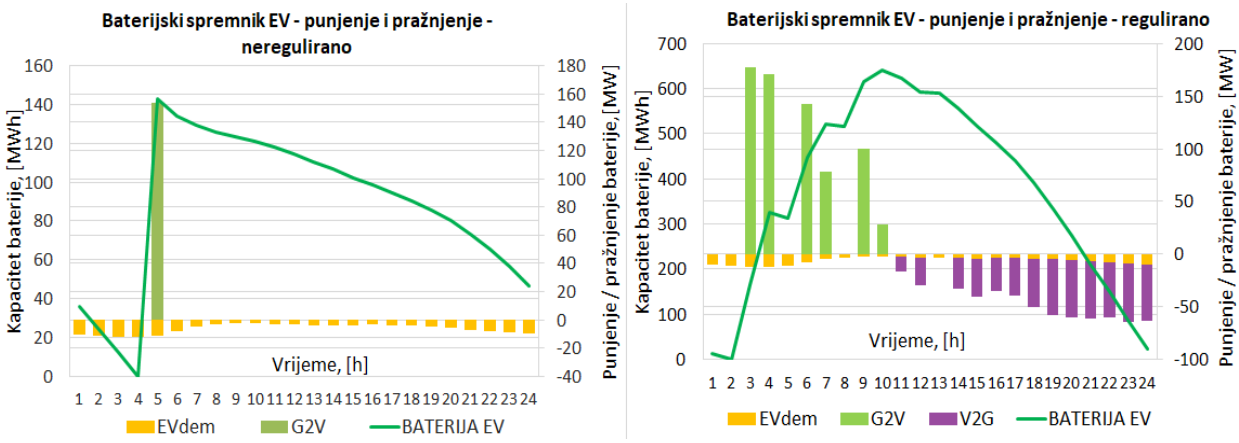

Slika 48. Prikaz energetskih tokova u BEV za neregulirani i regulirani sustav standardnog punjenja i pražnjenja u programu Calliope, dan zime. Lijevi dijagram – neregulirani sustav; desni dijagram – regulirani sustav

Razlika između Calliope-a i novog algoritma je ta što Calliope ima samo jednu potrošnju energije u bateriji, koja predstavlja vozila koja se voze i na [Slika 48] su označeni žutom bojom s negativnim predznakom. U novom algoritmu su također na [Slika 46] prikazana vozila koja se voze plavom bojom s negativnim predznakom, dok je punjenje EV uslijed potrošnje vožnjom pozitivno i prikazano žutom bojom. U novom algoritmu je ono odvojeno od vozila koja se pune u vrijeme viška proizvodnje, G2V, i mijenja se ovisno o vožnji i navikama vozača i nije regulirano. Zbog toga se javlja razlika između rezultata uvoza i rezultata izvoza u novom algoritmu i Calliope-u, koja je jednakog iznosa, i u novom algoritmu predstavlja dodatnu potrošnju na strani mreže, koja je u Calliope-u objedinjena pod G2V. Osim drugačijeg pristupa proračunima između novog algoritma i Calliope-a, pokazano je rezultatima i njihovom usporedbom da se u jednakom postotku smanjuju uvoz i izvoz uvođenjem regulacije punjenja i pražnjenja EV modelom V2G za jedan odabrani dan u godini.

Usporedba novog algoritma s programom Calliope napravljena je i za godišnje podatke za 2050. godinu. Rezultati su prikazani u [Tablica 57]. Iz rezultata se vidi da je godišnji uvoz i izvoz električne energije u nereguliranom sustavu u programu Calliope manji u usporedbi s rezultatima novog algoritma za neregulirani sustav. Razlog tome je što je punjenje vozila u programu Calliope, u nereguliranom sustavu, ipak na neki način regulirano jer se vozila pune u vrijeme viška proizvodnje električne energije iz OIE, što u novom algoritmu nije slučaj. Međutim, rezultati uvoza i izvoza za regulirani sustav, uvođenjem V2G model, daju približno jednake godišnje iznose uvoza i izvoza u reguliranom sustavu u novom algoritmu i Calliope-u. S obzirom na prikazane rezultate i usporedbu novog algoritma i programa Calliope, možemo zaključiti da regulacija sustava, primjenom modela V2G, daje približno jednake rezultate u smanjenju uvoza i izvoza odabranog sustav. Rezultati se ne poklapaju u potpunosti zbog toga što programi imaju drugačiji pristup analizi podataka i izračuna rezultata.

Tablica 57. Usporedba rezultata novog algoritma i programa Calliope za 2050. godinu za slučaj S1 i vremenski korak od 1 sat

Slučaj S1_2050. godina_1h	**Novi algoritam**		**Calliope**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh/god.]	245,31	127,84	201,55	84,14
REG, [GWh/god.]	180,22	53,65	173,98	53,55
Smanjenje REG u odnosu na NEREG	**26,5%**	**58%**	**13,7%**	**36,37%**
Iskorištena energija u baterijama V2G, [GWh/god.]	**65,09**	**74,21**	**27,57**	**30,59**

3.4.1.2 Rezultati usporedbe 10-minutnog modela

Usporedba novog algoritma i programa Calliope napravljena je i za vremenski korak od 10 minuta, za jedan dan i cijelu godinu. Za usporedbu je odabrana treća srijeda u siječnju, 15.01., jednako kao i za satni proračun, za slučaj S1. U [Tablica 58] prikazani su rezultati za odabrani dan za vremenski korak od 10 minuta. Iz rezultata vidimo da se uvoz, u reguliranom sustavu s V2G modelom u programu Calliope, u potpunosti smanjio, što je jednako kao i kod novog algoritma. Izvoz se smanjio za 65%, što je nešto veće od onoga u novom algoritmu. Također vidimo da je uvoz i izvoz u nereguliranom sustavu u Calliope-u manji u odnosu na novi algoritam i to za 86 MWh u danu. Razlog tome je jednak kao i onaj za satni proračun, jer je punjenje G2V vozila ipak regulirano u Calliope-u u nereguliranom sustavu na način da se vozila pune samo u vrijeme viška proizvodnje električne energije iz OIE. To objašnjava jednaku razliku u iznosu uvoza i izvoza rezultata novog algoritma i Calliope-a u nereguliranom sustavu. Calliope model rezultira nešto većim smanjenjem uvoza i izvoza u odnosu na novi algoritam za vremenski korak od 10 minuta, zbog drugačijeg pristupa i načina proračuna. U odnosu na satni proračun u Calliope-u, 10-minutni proračun rezultira većim smanjenjem izvoza, dok je uvoz smanjen u potpunosti u oba proračuna.

Tablica 58. Usporedba rezultata novog algoritma i programa Calliope za 15.01.2050. godine za slučaj S1 i vremenski korak od 10 minuta

Slučaj S1_15_1_2050. godina_10 min	**Novi algoritam**		**Calliope**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [MWh/dan]	685,8	1107,21	599,25	1020,66
REG, [MWh/dan]	0	500,92	0	356,67
Smanjenje REG u odnosu na NEREG	**100%**	**54,8%**	**100%**	**65,1%**
Iskorištena energija u baterijama V2G, [MWh/dan]	**685,8**	**606,3**	**599,25**	**664**

[Slika 49] prikazuje energetske tokove dobivene u novom algoritmu za odabrani dan u mjesecu siječnju. Vidimo da je u noćnim satima pojačana proizvodnja električne energije iz VE, čime je pokrivena potrošnja električne energije u noćnim satima, koja se odnosi na opću potrošnju i potrošnju za punjenje EV uslijed vožnje. U poslijepodnevnim satima se potrošnja energije snabdijeva uvozom električne energije. Uvođenjem modela V2G i regulacijom punjenja i pražnjenja, smanjen je uvoz punjenjem EV u vrijeme viška proizvodnje električne energije, G2V, a ostatak potrošnje se snabdijeva električnom energijom pohranjenom u BEV, V2G, što u potpunosti smanjuje potrebe za uvozom za odabrani dan. [Slika 50] prikazuje energetske tokove u bateriji i kapacitet baterije u svakom vremenskom trenutku.

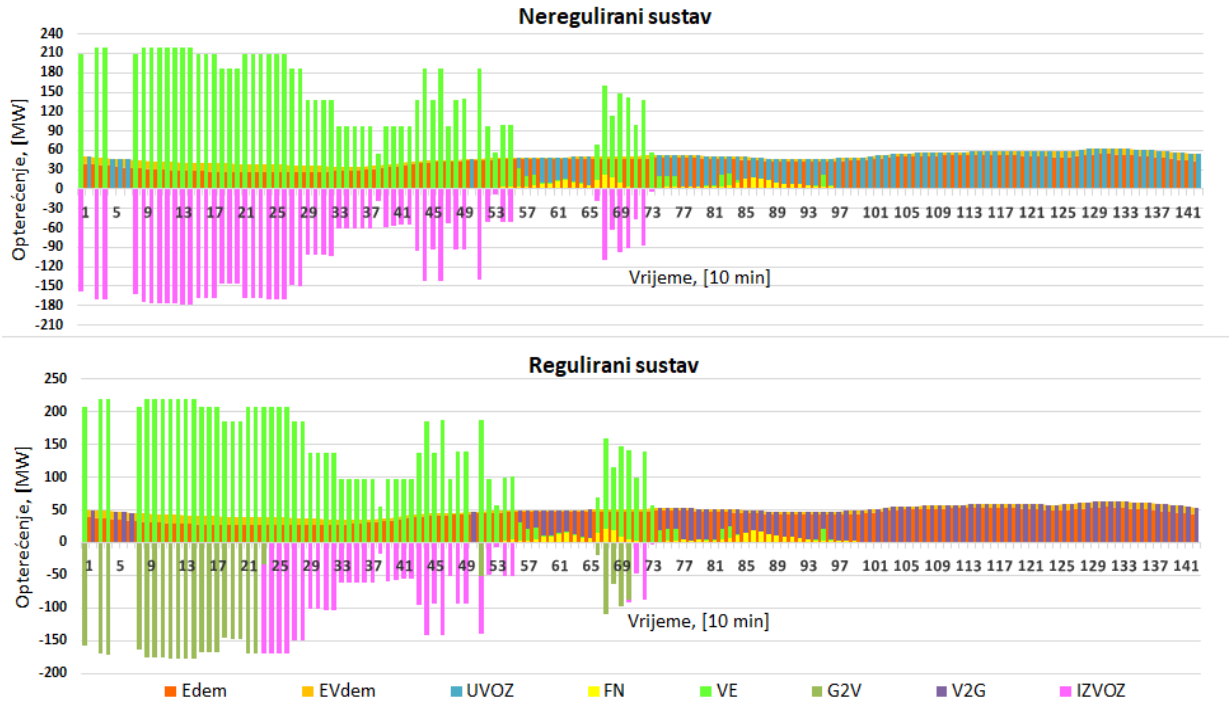

Slika 49. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_10 min_S1 s usporedbom nereguliranog i reguliranog punjenja i pražnjenja EV u novom algoritmu

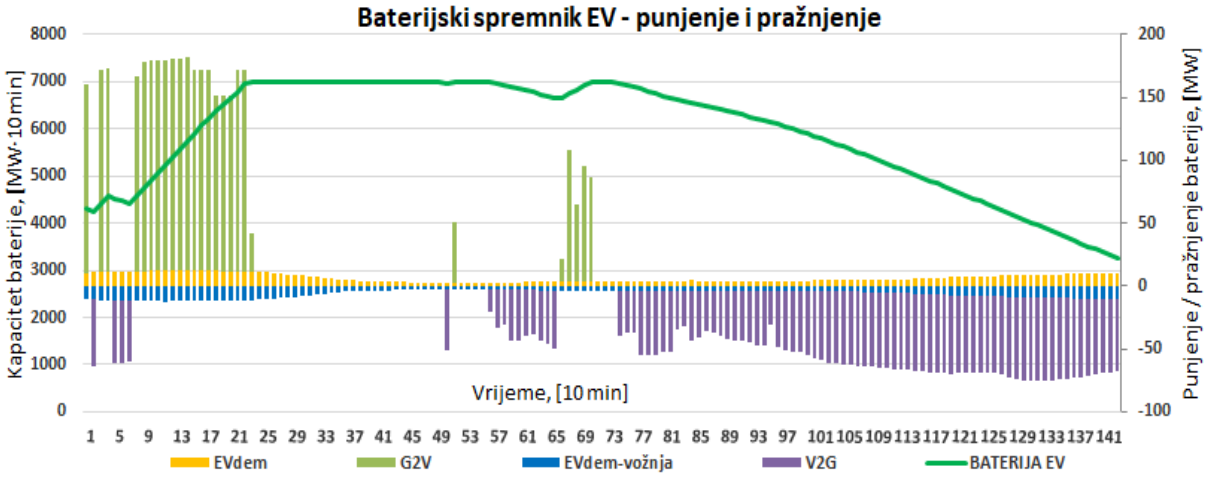

Slika 50. Prikaz energetskih tokova u BEV i kapaciteta baterije za regulirani sustav brzog punjenja i pražnjenja u novom algoritmu, 15. siječnja za scenarij 2050_10 min_S1

[Slika 51] prikazuje rezultate energetskih tokova dobivenih u programu Calliope za neregulirani i regulirani sustav. Vidimo da u nereguliranom sustavu, uz punjenje EV, imamo značajan izvoz električne energije, kao i uvoz u vrijeme manjka proizvodnje električne energije iz OIE. Uvođenjem modela V2G u sustav i regulacijom punjenja i pražnjenja EV, dolazi do značajnog smanjenja izvoza i potpunog smanjenja uvoza. BEV višak energije skladište i u

vrijeme manjka proizvodnje električne energije snabdijevaju potrebe za električnom energijom za odabrani dan. [Slika 52] prikazuje energetske tokove u bateriji EV za neregulirani i regulirani sustav punjenja i pražnjenja. Vidimo da se korišteni kapacitet baterije značajno povećava u reguliranom sustavu zbog uvođenja modela V2G.

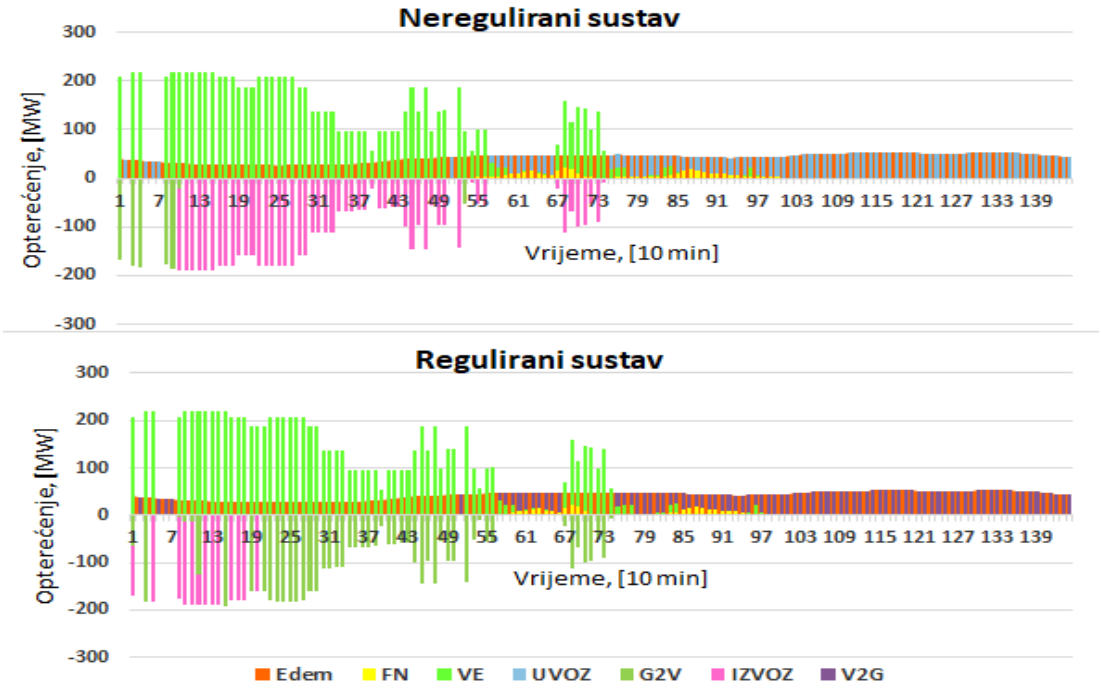

Slika 51. Prikaz energetskih tokova za 15. siječnja za scenarij 2050_10 min_S1 s usporedbom neregulirano i reguliranog punjenja i pražnjenja EV u programu Calliope

U [Tablica 59] dani su rezultati godišnjeg proračuna za vremenski korak od 10 minuta i usporedba rezultata novog algoritma i programa Calliope. Rezultati prikazuju smanjenje uvoza i izvoza uvođenjem regulacije punjenja i pražnjenja EV u sustav u odnosu na neregulirano punjenje EV. U odnosu na novi algoritam, rezultati godišnjeg uvoza i izvoza u Calliope-u, za neregulirani sustav, su znatno niži i sustav ima manje uvoza i izvoza. Razlog tome je što je u Calliope-u punjenje EV ipak regulirano na način da se vozila pune samo u vrijeme visoke proizvodnje iz OIE, dok se u novom algoritmu punjenje vozila vrši u svakom koraku za iznos vožnje iz prethodnog koraka. Oba algoritma pokazuju smanjenje uvoza i izvoza uvođenjem regulacije u sustav i dodavanjem modela V2G. U Calliope-u je ono manje u postotku u odnosu na neregulirani sustav zbog nižeg uvoza i izvoza u nereguliranom sustavu. Međutim, konačni rezultati iznosa uvoza i izvoza, uvođenjem regulacije i modela V2G, su približno jednaki, što znači da u konačnici oba algoritma daju jednake rezultate na godišnjoj razini u reguliranom sustavu.

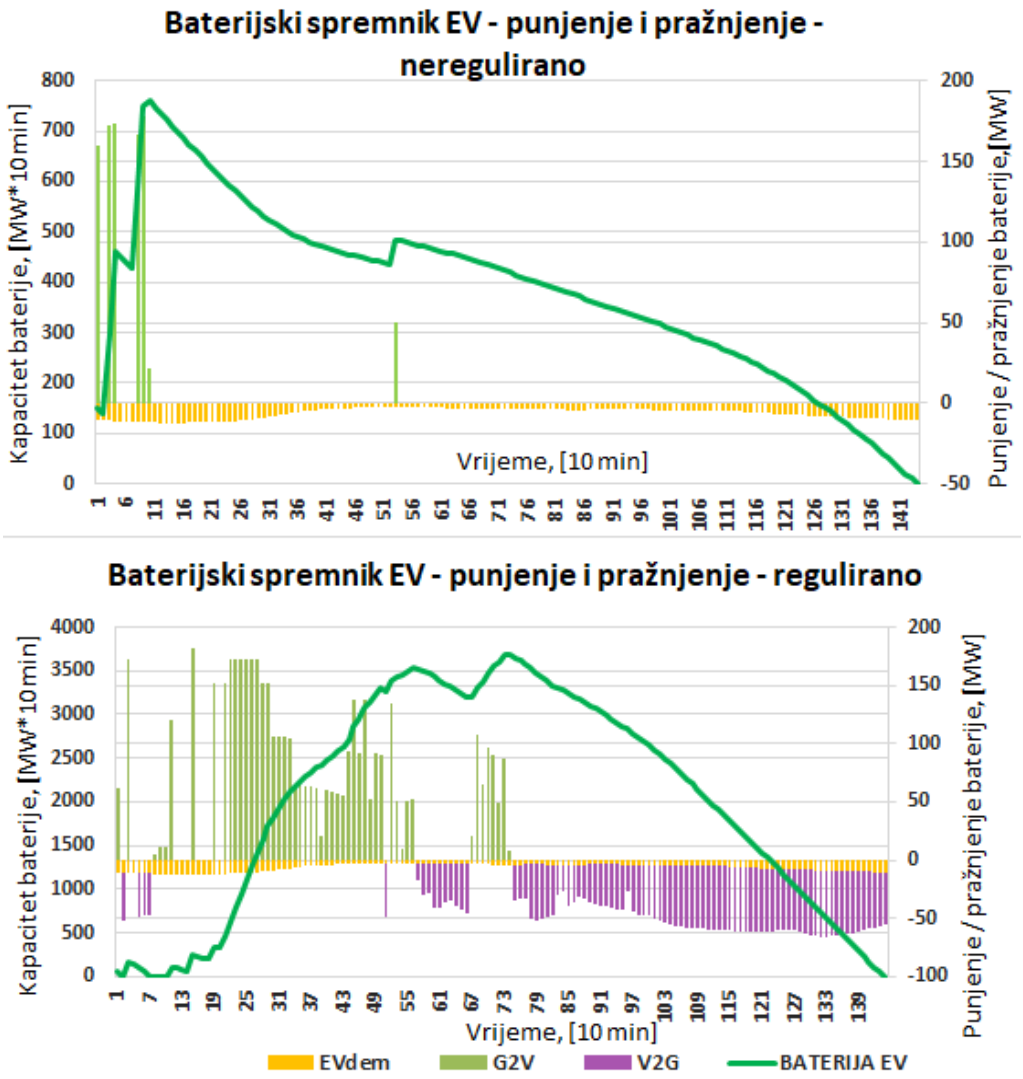

Slika 52. Prikaz energetskih tokova u BEV i kapaciteta baterije za neregulirani i regulirani sustav punjenja i pražnjenja u programu Calliope, 15. siječnja za scenarij 2050_10 min_S1

Iz rezultata se da zaključiti da analizom i usporedbom jednog dana u novom algoritmu i Calliope-u dobijemo jednake postotke smanjenja uvoza i izvoza uvođenjem regulacije i modela V2G u sustav i za satni i 10-minutni proračun. Analizom i usporedbom novog algoritma i programa Calliope na godišnjoj razini, dobiveni su jednaki rezultati u iznosu uvoza i izvoza u reguliranom sustavu. Dnevni rezultati se podudaraju u postotku zbog razlike u načinu snabdijevanja potrošnje energije baterije uslijed vožnje, pa iz tog razloga iznosi izvoza i uvoza nisu jednaki ni za satni ni za 10-minutni vremenski korak. Analizom i usporedbom godišnjih podataka može se reći da uvođenje regulacije i modela V2G daje približno jednak rezultate iznosa uvoza i izvoza u novom algoritmu i programu Calliope i za satni i 10-minutni vremenski korak.

Tablica 59. Usporedba rezultata novog algoritma i programa Calliope za 2050. godinu za slučaj S1 i vremenski korak od 10 minuta

Slučaj S1_2050. godina_10 min	**Novi algoritam**		**Calliope**	
Regulacija punjenja i pražnjenja EV	**UVOZ**	**IZVOZ**	**UVOZ**	**IZVOZ**
NEREG, [GWh/god.]	255,33	138,14	209,84	92,62
REG, [GWh/god.]	180,09	53,46	174,6	53,5
Smanjenje REG u odnosu na NEREG	**29,5%**	**61,3%**	**16,8%**	**42,2%**
Iskorištena energija u baterijama V2G, [GWh/god.]	**75,24**	**84,68**	**35,24**	**39,12**

3.4.2 Rezultati modela 100% obnovljivog energetskog sustava šireg gradskog područja u programu Calliope

U programu Calliope izradio se energetski plan 100% obnovljivog energetskog sustava šireg gradskog područja. Za izradu plana odabrano je područje grada Dubrovnika sa širom okolicom. Od proizvodnje energije u sustavu koristili su se 100% obnovljivi izvori energije za koje odabrano područje ima povoljne resurse. Koristili su se postojeći izvori, kao što je postojeća HE Dubrovnika, i planirane SE i VE do 2050. godine unutar granica sustava. Pretpostavka je da će do 2050. godine sva osobna KV biti zamijenjena s EV s modelom V2G, kao i da će svi objekti na krovovima imati instalirane FN sustave za proizvodnju električne energije. Sustavi grijanja i hlađenja, koji koriste konvencionalne izvore energije, zamijenjeni su DTMV s dodatnim TES i RES sustavima. S obzirom da se radi o manjem energetskom sustavu, on zahtjeva i više izvora fleksibilnosti kako bi se omogućila integracija 100% OIE u sustav. Stoga su u sustav dodani dodatni skladišni kapaciteti kao izvori fleksibilnosti. Pretpostavka je da će se BEV, nakon svog životnog vijeka u EV, koristiti kao stacionarni spremnici električne energije u funkciji B2U. Dodani su i SEV sustavi za proizvodnju i skladištenja vodika, pomoću elektrolize vode, u svrhu skladištenja viška proizvodnje energije i opskrbe sustava energijom u vrijeme manjka proizvodnje iz OIE. Sustav je povezan sa tržištem električne energije s varijabilnim cijenama. Usporedili su se rezultati proračuna i analize sustava modeliranog za vremenski korak od 1 sat, koji uključuje standardno punjenje EV s modelom V2G, sa energetskim sustavom modeliranim za kratkoročan vremenski korak, koji uključuje iznimno brzo punjenje EV s modelom V2G.

Rezultati proračuna za vremenski korak od 1 sat i 10 minuta, za jedan odabrani dan u godini, 15. 01., treća srijeda u mjesecu siječnju, prikazani su u [Tablica 60] i na [Slika 53] [Slika 54] i [Slika 55].

Tablica 60. Rezultati proračuna i analize 100% obnovljivog energetskog sustava šireg gradskog područja u programu Calliope, za vremenski korak od 1 sat i 10 minuta za jedan odabrani dan u godini

Calliope_15_1_2050. godina	**1h**	**10min**
VE, [MW]	217,18	219
SE, [MW]	7,1	11,04
FN, [MW]	6,73	10,52
HE, [MW]	62,13	50
Uvoz, [MW]	0	13,9
Maksimalno opterećenje općom potrošnjom električne energije, [MW]	47,81	48,81
Maksimalno opterećenje potrošnjom električne energije za punjenje EV, [MW]	12,26	12,24
Maksimalno opterećenje potrošnjom toplinske energije za grijanje, [MW]	42,84	44,5
TES, [MW]	27,2	11,33
TES, [MWh]	105	65,72
B2U, [MW]	0	18,23
B2U, [MWh]	0	46,77
UVOZ, [MWh/dan]	**0**	**56,78**
IZVOZ, [MWh/dan]	**1401,3**	**1158,02**

U [Tablica 60] prikazani su rezultati proračuna 100% obnovljivog energetskog sustava za jedan odabrani dan u 2050. godini. Rezultati su se usporedili za vremenski korak proračuna na satnoj i 10-minutnoj bazi. Iz rezultata se vidi da sustav, modeliran za kraći vremenski korak od 10 minuta, za razliku od satnog proračuna, koristi dodatne skladišne kapacitete B2U, više instalirane snage OIE, manje kapacitete i instalirane snage TES i manje je izvoza, dok u sustavu ima i uvoza. Da se zaključiti da sustav, modeliran za kraći vremenski korak, pruža više mogućnosti za integraciju više različitih izvora fleksibilnosti. U TES koristi i stacionarne B2U kako bi se povećala fleksibilnost sustava. Veća instalirana snaga OIE u sustavu znači i bolju mogućnost u iskorištavanju proizvodnje električne energije iz OIE u odnosu na satni proračun. Satni proračun nema uvoza za odabrani dan, međutim, izvoz je veći nego kod 10-minutnog modela. U konačnici, 10-minutni model ima manji iznos prekograničnih kapaciteta električne energije. Stoga, možemo reći da model sustava baziran na kratkoročnom vremenskom koraku nudi više mogućnosti za povećanje fleksibilnosti i bolju integraciju OIE u sustav, uz ukupno smanjenje prekograničnih kapaciteta prijenosa električne energije u susjedne energetske sustave u iznosu od 186,5 MWh/dan manje od satnog.

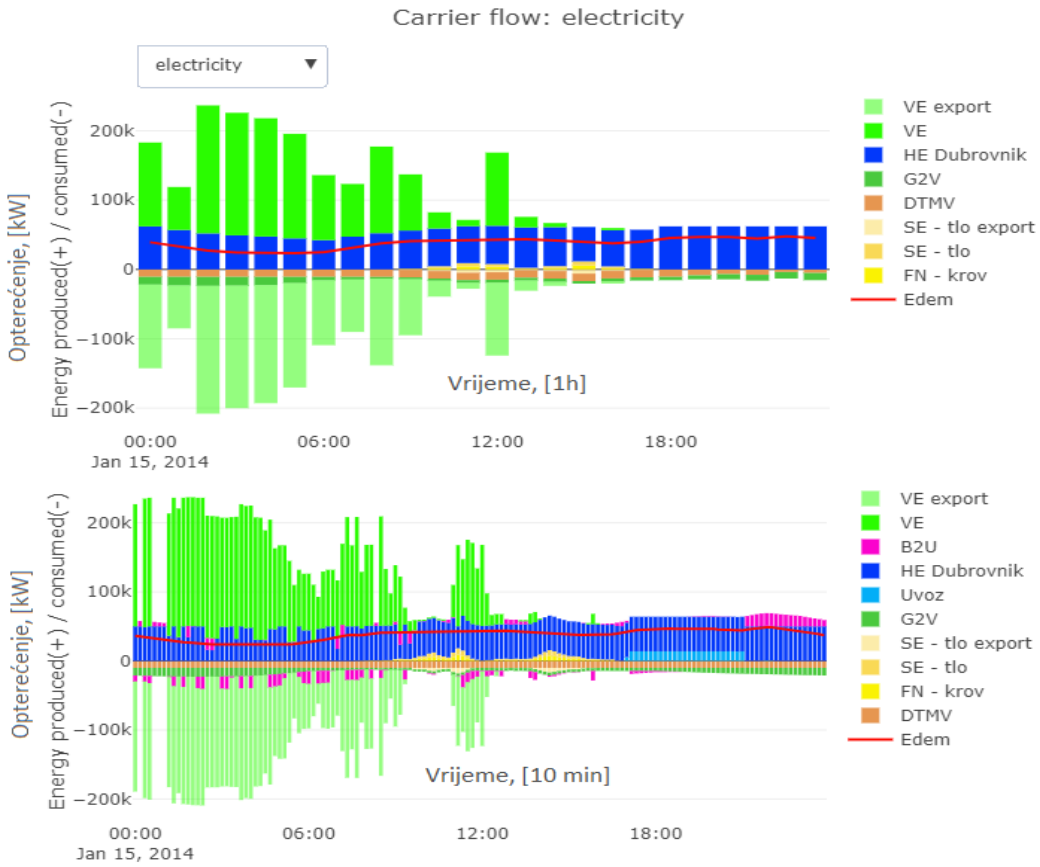

Slika 53. Prikaz tokova električne energije prema mreži za jedan odabrani dan za satni i 10-minutni model proračuna u programu Calliope

Na dijagramima dobivenima u programu Calliope, na [Slika 53], prikazani su tokovi električne energije prema mreži od svih sudionika sustava za odabrani dan. Vidimo da sustav, modeliran za vremenski korak od 10 minuta, pruža više detalja o radu sustava jer je veća varijabilnost i promjenjivost distribucije energetskih tokova, što znači i bolji uvid u samo stanje i promjene u sustavu.

[Slika 54] prikazuje energetske tokove toplinske energije i električne energije u BEV za jedan dan. Vidimo da, u sustavu s kraćim vremenskim korakom, DTMV radi stalnom snagom i snabdijeva toplinske potrebe, dok se višak proizvedene toplinske energije sprema u TES u vrijeme povećane proizvodnje električne energije iz OIE. Ta ista energija koristi se naknadno za snabdijevanje toplinskih potreba u vrijeme manjka proizvodnje iz OIE. Slično se događa i u sustavu na satnoj bazi, međutim, DTMV ne radi jednakom snagom u svim satima. Satni model koristi više kapaciteta i snage TES umjesto drugih skladišnih kapaciteta, kao što je B2U. Model V2G se nije pokazao isplativim u sustavu i EV se samo pune iz mreže svaki sat prema navikama potrošača, kako je to bilo i opisanu u novom algoritmu za neregulirani model punjenja EV. U sustavu je postignuta integracija toplinskog i transportnog sektora, međutim,

model V2G nije korišten nego je potrošnja EV pratila potrebe i navike vozača. Distribucija potrošnje jednaka je i za satni i 10-minutni model.

Slika 54. Prikaz energetskih tokova toplinske energije i električne energije u EV za satni i 10-minutni model u programu Calliope

[Slika 55] prikazuje energetske tokove za sustave spremnika. U satnom modelu, sustav koristi samo TES za skladištenje toplinske energije. Energija se skladišti u vrijeme viška proizvodnje električne energije iz OIE a prazni u vrijeme manjka proizvodnje, smanjujući tako uvozne i izvozne kapacitete. Za razliku od satnog modela, 10-minutni model je pružio više detalja o stvarnom stanju energetskih tokova u sustavu i pružio mogućnost integracije dodatnih izvora fleksibilnosti. Koristi više različitih spremnika energije, TES i B2U, međutim, u približno jednakim snagama i kapacitetima spremnika ukupno. Takav sustav zahtjeva jednak broja spremnika, različite vrste, kako bi povećao potrebnu fleksibilnost u sustavu. Spremnici se također pune u vrijeme viška proizvodnje iz OIE a prazne u vrijeme manjka proizvodnje. Sustav nije koristio SEV s elektrolizatorima i gorivnim člancima. Optimizacijom satnog i 10 minutnog modela, odabrana tehnologija skladištenja vodika se nije pokazala isplativom i efikasnom u odabranom sustavu.

Slika 55. Energetski tokovi u i kapaciteti skladišta energije u satnom i 10-minutnom modelu dobiveni u programu Calliope

[Tablica 61] prikazuje rezultate godišnjeg proračuna energetskog sustava za vremenski korak od 1 sat i 10 minuta. Usporedbom rezultata satnog modela s rezultatima 10-minutnog modela 100% obnovljivog energetskog sustava u [Tablica 61], vidimo da se u 10-minutnom modelu izvoz smanjio za skoro 110 GWh/god, što je približno 72% smanjenja izvoza. Uvoz se povećao za približno 11 GWh/god, odnosno za 50%. Ukupno smanjenje prekograničnih kapaciteta u 10-minutnom modelu u odnosu na satni model iznosi približno 98 GWh/god., što predstavlja smanjenje za 60,8%. Također se može uočiti da razlika između potrebnog uvoza i izvoza energije u satnom modelu sustava iznosi približno 140 GWh/god., dok kod 10-minutnog modela iznosi svega 20 GWh/god. Energetski sustav modeliran za kratkoročan vremenski korak pruža bolju stabilnost sustava što se očituje u manjoj razlici potrebnih prijenosnih kapaciteta i značajno manjem iznosu izvoza. Rezultatima se pokazalo da na godišnjoj razini model sustava, baziran na kratkoročnom vremenskom koraku, pruža bolje uvjete za dodatne izvore fleksibilnosti koji omogućuju bolje iskorištavanje energije proizvedene iz varijabilnih OIE, kao i veću stabilnost i sigurnost samog sustava. Instalirana snaga TES i RES u 10-

minutnom modelu smanjena je za 10 MW, uz dodatno korištenih 16 MW B2U stacionarnih spremnika energije. Time je u sustavu povećana ukupna instalirana snaga ES za približno 6 MW.

Tablica 61. Rezultati proračuna i analize 100% obnovljivog energetskog sustava šireg gradskog područja u programu Calliope, za vremenski korak od 1 sat i 10 minuta za 2050. godinu

Calliope_2050. godina	**1h**	**10min**
VE, [MW]	219	219
SE, [MW]	43,01	43,01
FN, [MW]	41,99	41,99
HE, [MW]	57,94	50
Uvoz, [MW]	29,93	33,21
Maksimalno opterećenje općom potrošnjom električne energije, [MW]	77,66	78,34
Maksimalno opterećenje potrošnjom električne energije za punjenje EV, [MW]	12,26	12,24
Maksimalno opterećenje potrošnjom toplinske energije za grijanje, [MW]	84,75	86,78
Maksimalno opterećenje potrošnjom rashladne energije za hlađenje, [MW]	103,33	105,47
TES, [MW]	44,8	38,67
TES, [MWh]	105	105
RES, [MW]	47,55	44,05
RES, [MWh]	105	100,81
B2U, [MW]	0	16,58
B2U, [MWh]	0	5,93
UVOZ, [GWh/god.]	**10,75**	**21,54**
IZVOZ, [GWh/god.]	**150,04**	**41,41**

Prema rezultatima se da zaključiti da je proširenje sustava, dodavanjem sudionika kao što su dodatna skladišta energije, u značajnoj mjeri smanjilo izvoz energije u sustavu. To se može vidjeti iz usporedbe rezultata modela Calliope sa rezultatima novog modela za slučaj S1 i S2 za scenarij 2050. godine. [Slika 56] prikazuje usporedbu iznosa uvoza i izvoza u sustavu za sva tri slučaja, za proračun baziran na satnom i 10-minutnom vremenskom koraku. Vidimo da se, proširenjem sustava i nadogradnjom novog modela u Calliope modelu, postiglo značajno smanjenje prekograničnih kapacitet uz ujednačavanje kapaciteta izvoza i uvoza na godišnjoj razni. Integracija i elektrifikacija transportnog i toplinskog sektora doprinijele su smanjenju prekograničnih kapaciteta. Integracija s tržištem električne energije omogućila je vrednovanje izvora fleksibilnosti. Povoljnije vrednovanje pružio je 10-minutni model korištenjem više različitih izvora fleksibilnosti i pružio više detalja za razvoj tržišta.

Kada se usporede rezultati novog modela za slučaj S2 i S1, gdje je u sustavu bilo manje sudionika, vidimo da je kod novih rezultata izvoz značajno manji. U scenariju za slučaj S2 izvoz je iznosio približno 800 GWh/god., a u proširenom sustavu u Calliope-u, za vremenski korak od 1 sat, smanjen je na 150 GWh/god. Dodatni izvori fleksibilnosti utjecali su na bolju iskoristivost električne energije proizvedene iz OIE. Međutim, dodatan razlog smanjenja uvoza je i instalirana snaga HE Dubrovnik, gdje je u novom algoritmu u proizvodnju električne energije bila uključena maksimalna instalirana snaga od 126 MW, a u modelu u programu Calliope postavljena je mogućnost da HE možete raditi i za minimalnu snagu od 50 MW. Prema rezultatima modela u programu Calliope vidimo da nije korišten maksimalni kapacitet HE Dubrovnik. Optimizacijom u programu Calliope se to pokazalo kao povoljnija opcija za sustav. Također, uvoz električne energije se smanjio sa 16 na približno 11 GWh/god.

10- minutni model u programu Calliope rezultirao je smanjenjem uvoza u odnosu na slučaj S1 i S2. Uvoz se povećao u odnosu na slučaj S2, međutim došlo je do značajnog ujednačavanja prekograničnih kapaciteta. U ukupnom iznosu oni su znatno smanjeni u odnosu na S1 i S2. Možemo reći da se modelom u programu Calliope postigla stabilnost i samodostatnost energetskog sustava šireg gradskog područja uz sigurniju integraciju 100% udjel OIE u proizvodnji električne energije.

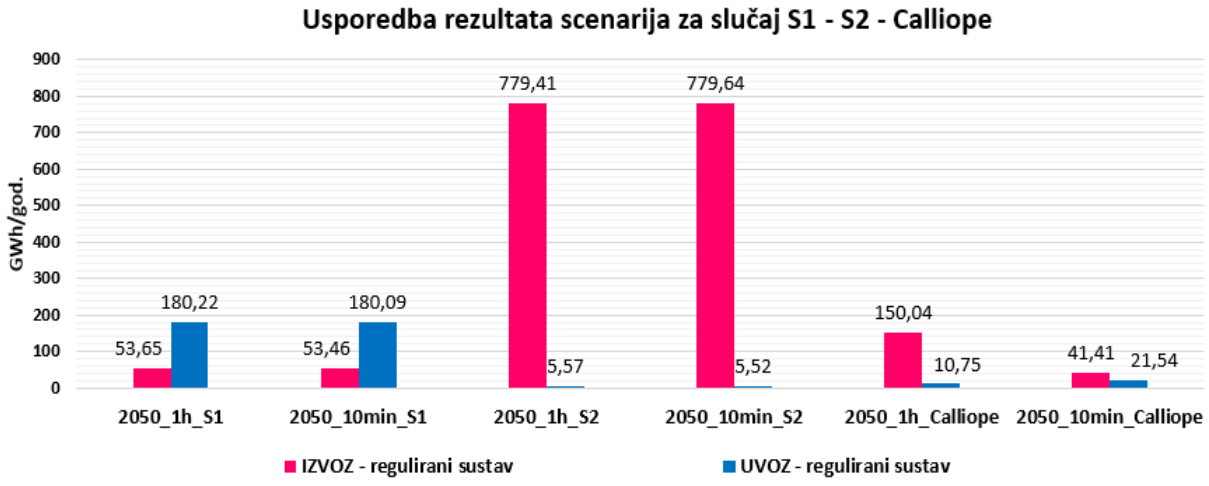

Slika 56. Usporedba rezultata novog modela za slučaj S1 i S2, te Calliope modela za scenarij 2050. godine za vremenski korak od 1 h i 10 minuta

4 ZAKLJUČAK I PREPORUKE

Cilj doktorskog rada je razvoj novog modela naprednog energetskog planiranja samodostatnog 100% obnovljivog energetskog sustava baziranog na kratkoročnom vremenskom koraku od 10 minuta. Razvijen je novi algoritam po uzoru na EnergyPLAN i usporedili su se rezultati novog algoritma i postojećih računalnih alata korištenih u području energetskog planiranja, EnergyPLAN i Calliope. Rezultati analiza pokazali su da novi model pruža više mogućnosti za dodatne izvore fleksibilnosti u sustavu, bolju integraciju OIE u proizvodnji električne energije, stabilnost energetskog sustava, kao i više detalja za razvoj tržišta električnom energijom. Povezanost sa susjednim energetskim sustavima kroz otvoreno tržište električne energije osigurava samodostatnost energetskog sustav šireg gradskog područja, dok će upotreba IKT alata omogućiti aktivo i ekonomično sudjelovanje svih sudionika sustava. U radu su definirane granice šireg gradskog područja i svi sudionici sustava koji spadaju unutar granica sustava. Za izradu analiza i proračuna odabrano je manje područje zbog toga što ono ima veće zahtjeve za fleksibilnošću unutar energetskog sustava.

Istraživanje je doprinijelo izradi algoritma za vremenski korak od 10 minuta što je rezultiralo smanjenjem potreba za dodatnom fleksibilnošću i pružilo više mogućnosti za sigurniju integraciju 100% udjela OIE u sustavu. Razvijen je i regulirani V2G model iznimno brzog punjenja i pražnjenja EV, koji se pokazao boljim u integraciji OIE u sustavu u odnosu na neregulirani sustav bez V2G modela i u odnosu na sustav sa standardnim punjenjem i pražnjenjem EV po modelu V2G. Povezivanje sustava sa susjednim energetskim sustavim i tržištem električnom energijom s varijabilnim cijenama osigurava stabilnost i regulaciju energetskih tokova, te omogućuje tržišno vrednovanje izvora fleksibilnosti u sustavu.

4.1 Komplementarnost OIE u proizvodnji električne energije – energija vjetra i sunčeva energija

U radu su napravljene analize linearne korelacije i regresije za podatke brzine vjetra, sunčeva zračenja, temperature zraka i potrošnje električne energije odabranog područja za tri uzastopne godine. Cilj analiza jest pokazati komplementarnost odabranih OIE za kratkoročan vremenski korak od 10 minuta, što je u dosadašnjoj literaturi jako slabo obrađeno ili nije uopće. Analizama s podacima o temperaturi zraka i potrošnji električne energije dao se uvid u moguće prognoze buduće proizvodnje energije iz OIE za kratkoročan vremenski korak i njihova komplementarnost s potrošnjom električne energije na odabranom području.

Rezultati su pokazali slabije korelacijske veze za kratkoročan vremenski korak između odabranih podataka unutar jedne godine. To ukazuje na potrebu za većim naporima u planiranju energetskih sustava modeliranih na kratkoročnom vremenskom koraku. Međutim,

takvi sustavi pružaju i više detalja o stvarnom stanju sustava i omogućuju točnije prognoze i planiranja. Podaci o brzini vjetra i sunčevom zračenju rezultirali su negativnim korelacijama, kako za dulji tako i za kratkoročan vremenski korak, što potvrđuje činjenicu da su ta dva izvora energije u kombinaciji povoljan odabir OIE u proizvodnji električne energije u sustavu. Podaci o vanjskoj temperaturi zraka pokazali su da ona predstavlja varijablu kojom se može opisati i prognozirati potrošnja električne energije kao i proizvodnja energije iz Sunca, dok je vjetar jako teško predvidjeti, posebice za kraći vremenski korak.

4.2 Integracija visokog udjela OIE proizvodnji električne energije uvođenjem sustava DTMV s ES

Toplinski sektor zauzima veliki udio u emisijama stakleničkih plinova korištenjem fosilnih izvora energije u proizvodnji energije, čime predstavlja jedan od primarnih sektor za uvođenje OIE u proizvodnji energije. Dosadašnja literatura, a i praksa, pokazale su da dobar put u tome mogu ponuditi sustavi DGH s DT. Dodatni ES mogu pružiti dodatnu sigurnost i stabilnost takvim sustavima, u integraciji OIE u proizvodnji energije kao i ekonomičniji rad samih DT. Stoga se u radu napravila analiza sustava DTMV s dodatnim ES za područje Starog grada Dubrovnika i ispitale su se mogućnosti integracije visokog udjela OIE u proizvodnji električne energije. Od OIE u proizvodnji električne energije odabrani su FN sustavi i VE. Za dodatne ES dala se usporedba TES i BES.

Rezultati su pokazali da je, u samostalnom radu sustava DTMV, moguće 67% potrošnje sustava, za proizvodnju toplinske i rashladne energije, opskrbiti proizvodnjom iz OIE i to u kombinaciji proizvodnje iz FN i VE. Ostatak rada sustava potrebno je osigurati kroz dodatne ES. Najveća iskoristivost proizvodnje električne energije postigla se kombiniranom proizvodnjom FN sustava i VE, dok su FN sustavi i VE zasebno rezultirale manjom iskoristivošću proizvodnje. Sustav modeliran za kratkoročan vremenski korak rezultirao je s do 8% manjom iskoristivošću proizvodnje u odnosu na sustav na satnoj bazi. Dodavanjem ES sustavu DTMV, omogućila se bolja integracija visokog udjel OIE u sustavu što je dovelo do smanjenja emisija CO_2 u iznosu od 430 tCO_2/god. Usporedba BES i TES pokazala je da je uvođenje BES zahtjeva 13 puta veći trošak, međutim, zahtjeva manje kapacitete spremnika kao i volumen manji i do 40 puta. I ovdje se pokazalo da sustavi s kombiniranom proizvodnjom električne energije iz FN i VE, u slučaju C, omogućuju bolju integraciju OIE u proizvodnji električne energije . Kapacitet skladišta, investicijski trošak i volumen TES i BES u slučaju C su se smanjili za 78% u usporedbi sa slučajem A, a za 60% u usporedbi sa slučajem B.

4.3 Integracija visokog udjela OIE u proizvodnji električne energije uvođenjem EV i reguliranog modela V2G – usporedba standardnog i iznimno brzog punjenja EV

Transportni sektor, jednako kao i toplinski sektor, jedan je od glavnih uzročnika povećanih emisija stakleničkih plinova. Uvođenje EV u sustave s visokim udjelom OIE može pružiti dodatnu sigurnost i stabilnost sustava i omogućiti bolju integraciju OIE. Porast udjela EV u svijetu raste, iako nailaze na mnoge prepreke koje je potrebno savladati kako bi se nastavio rast korištenja EV. Neke od glavnih prepreka su još uvijek visoke cijene BEV i samim time EV, nedovoljan razvoj infrastrukture za punjenje EV kao i vrijeme potrebno da se vozilo napuni. U ovom radu ponuđena su rješenja za savladavanje navedenih prepreka i poticaja za porast udjela EV. Razvijen je V2G model koji se bazira na iznimno brzom punjenju i pražnjenju EV u trajanju od 10 minuta, što EV čini prihvatljivijim za korisnike, posebice za dulja putovanja koja iziskuju više od jednoga punjenja. Pokazalo se da se reguliranim V2G modelom mogu ostvariti uštede za EV na godišnjoj razini. Uvođenje modela B2U dovelo bi do produljenja korisnog vijeka BEV što bi utjecalo i na smanjenje cijene EV, a EV učinilo prihvatljivijima za korisnike. Ulaganje u infrastrukturu s brzim punjačima za EV jedan je od bitnih faktor za povećanje porasta udjela EV u energetske sustave.

4.3.1 Integracija VE i SE u proizvodnji električne energije uz 100% EV i regulirani model V2G

Razvijen je novi algoritam za napredno planiranje energetskih sustava kroz razvoj pametnog energetskog sustava. Model energetskog sustava izrađen je prema planu za 2050. godinu, za šire područje grada Dubrovnika, a koji uključuje 100% proizvodnju električne energije iz OIE i potpunu zamjenu osobnih KV s EV. Validacija novog algoritma provela se analizama i usporedbama s postojećim računalnim alatima EnergyPLAN i Calliope. U obzir su uzete pretpostavke prema scenariju S1, koje uključuju proizvodnju električne energije iz SE i VE unutar granica šireg gradskog područja i mogućnost priključka svih raspoloživih EV za punjenje i pražnjenje u jednom vremenskom trenutku.

Rezultati analiza su pokazali da novi algoritam daje jednake rezultate kao i već korišteni računalni alati. Usporedbom nereguliranog sustava punjenja EV, koje je modelirano prema potrebama i navikama vozača, i reguliranog sustava punjenja i pražnjenja EV s V2G modelom, pokazalo se da regulacijom dolazi do znatnog smanjenja uvoznih i izvoznih kapaciteta električne energije u sustavu. Rezultati su bili nešto bolji za sustave s iznimno brzim punjenjem i pražnjenjem EV, u sustavu s reguliranim V2G modelom, u odnosu na standardno punjenje i

pražnjenje EV. Može se zaključiti da uvođenje reguliranog V2G modela pridonosi boljoj integraciji OIE u sustav i pruža više mogućnosti za povećanje fleksibilnosti u sustavu.

4.3.2 Integracija VE, SE i HE Dubrovnik u proizvodnji električne energije uz 100% EV i regulirani model V2G

U novom algoritmu ispitao se slučaj 100% proizvodnje električne energije koji, osim VE i SE, uključuje i postojeću HE Dubrovnik u proizvodnji električne energije na odabranom području u scenariju S2. Scenarij S2 se temelji na pretpostavkama scenarija S1 uz nadogradnju s postojećom HE Dubrovnik.

Povećanje proizvodnje električne energije u S2 dovelo je do znatnog smanjenja uvoza električne energije uz primjenu reguliranog V2G modela i na satnoj i 10-minutnoj bazi. U scenariju S1 uvoz je iznosio oko 180 GWh/god., a u scenariju S2 je smanjen na oko 5 GWh/god. Može se zaključiti da je kombinacija VE, SE i HE Dubrovnik, s planom za 2050. godinu, dostatna za odabrani sustav. Međutim, količine izvoza su se znatno povećale u odnosu na scenarij S1. U scenariju S1 izvoz je iznosio oko 54 GWh/god., da bi se uvođenjem HE povećao na oko 780 GWh/god. Iako je kombinacija OIE u proizvodnji električne energije, u scenariju S2, rezultirala povećanjem samodostatnosti u sustavu, rezultirala je znatnim povećanjem viška proizvodnje električne energije koji nije znatno smanjen EV i reguliranim modelom V2G. Stoga je potrebno u sustav uvesti dodatne skladišne kapacitete kako bi se osigurala stabilnost i sigurnost 100% obnovljivog sustava.

4.3.3 Usporedba standardnog i iznimno brzog punjenja EV uvođenjem reguliranog modela V2G u integraciji 100% OIE u proizvodnji električne energije

U scenarijima S1 i S2 odredila se pretpostavka da sva EV, raspoloživa u svakom vremenskom trenutku, imaju mogućnost priključka na mrežu za punjenje ili pražnjenje u satnom i 10-minutnom modelu. Takva pretpostavka predstavlja najbolji mogući scenarij o granični slučaj koji se ne temelji se na stvarnoj i mogućoj situaciji. Stoga se u scenariju S3 ispitao minimalno potreban broj EV, priključen na mrežu u svakom trenutku, da bi se dobio jednak rezultat pretpostavci iz scenarija S1.

U scenarijima S1 i S2 satni i 10-minutni model, odnosno standardno i iznimno brzo punjenje, polučili su približno jednake rezultate. Usporedbom rezultata iz scenarija S3 je zapravo vidljiva razlika između standardnog i brzog punjenja EV, gdje su rezultati, u slučaju brzog punjenja i sustava modeliranog za vremenski korak od 10 minuta, pokazali da takav model sustava može pružiti znatno veću fleksibilnost od satnog modela. Pokazalo se da je, kod iznimno brzog punjenja, dovoljno samo 3% V2G vozila spojenih na mrežu, u svakom

vremenskom trenutku, da bi se dobio rezultat jednak onome za najbolji mogući slučaj. Kod standardnog punjenja, postotak vozila u 2030. godini iznosio je 65%, da bi se u 2050. godini povećao na 80% EV spojenih na mrežu. Usporedbom rezultata satnog i 10-minutnog modela na satnoj osnovi, pokazalo se da iznimno brzo punjenje zahtjeva 6,7 puta veću priključnu snagu na mrežu u danom trenutku uz 4,5 puta manji broj spojenih EV. Nudi znatno veću mogućnost za bolju integraciju OIE u sustav s nešto većom akumulacijom energije u BEV u jednom satu. Stoga možemo zaključiti da sustavi bazirani na vremenskom koraku od 10 minuta, koji uključuju iznimno brzo punjenje i pražnjenje EV uz uvođenje reguliranog modela V2G, pružaju znatno više fleksibilnosti i sigurniju integraciju OIE unutar sustava. Međutim, u isto vrijeme uzrokuju i znatno veća opterećenja na mreži, zahtijevaju mrežu visokog napona, a imaju i negativan utjecaj na životni vijek baterije. Potrebno je provesti detaljnije tehno-ekonomske analize i ispitati isplativost modela V2G kao mogućeg izvora fleksibilnosti.

4.3.4 Usporedba P2T i V2T modela cijena električne energije

Analizama u scenariju S4, u novom algoritmu, ispitalo se kakve dobrobiti za korisnike EV može donijeti uvođenje modela V2G. Također, usporedila se i regulacija modela V2G cijenama električne energije prema P2T i V2T modelu, uz usporedbu standardnog i iznimno brzog punjenja i pražnjenja EV.

Usporedba P2T i V2T modela cijena električne energije pokazala je da V2T model nudi više mogućnosti za integraciju OIE u sustava kao i veće uštede korisnicima EV, uz uvođenje modela V2G. To dovodi do zaključka da je u sustavu, s promjenjivom proizvodnjom električne energije iz OIE, bolji izbor varijabilni model cijena električne energije koje će se modelirati prema proizvodnji energije iz OIE, čime će se potaknuti potrošače da potrošnjom energije prate proizvodnju u cilju bolje integracije OIE u sustav. Takav model omogućit će ekonomično i aktivno sudjelovanje svih sudionika unutar sustava, ponuditi dodatnu sigurnost i stabilnost sustavu uz povećanje fleksibilnosti, uz primjenu IKT alata za komunikaciju među sudionicima. Uvođenjem V2T modela cijena električne energije, kojima se regulirao model V2G, polučio je najveće uštede za model sustava baziranog na vremenskom koraku od 10 minuta koji uključuje iznimno brzo punjenje i pražnjenje EV. Pokazalo se da uštede za korisnike mogu iznositi i do 200 EUR/EV god.

4.4 100% obnovljiv energetski sustav šireg gradskog područja

Integracijom transportnog i toplinskog sektora, u cilju postizanja samodostatnog energetskog sustava, izrađen je 100% obnovljiv energetski sustav, razradom modela naprednog energetskog planiranja u računalnom programu Calliope, kroz razvoj pametnog energetskog

sustava šireg gradskog područja. Rezultatima scenarija S2, u novom algoritmu, pokazalo se da sustav zahtjeva dodatne ES kako bi se postigla sigurnost i stabilnost sustava, uz smanjenje viškova proizvodnje električne energije. Stoga su se sustavu, u scenariju S2, dodali dodatni sudionici i ES. U toplinskom sektoru su se konvencionalni izvori, u proizvodnji toplinske energije, zamijenili sustavim na električnu energiju, uvođenjem DTMV uz dodatne TES i RES. Dodale su se i stacionarne baterije koje su u EV završile svoj životni vijek, prema modelu B2U. SEV sustavi za proizvodnju vodika elektrolizom vode i njegovo skladištenje također su dodani u sustav kao dodatan izvor fleksibilnosti. Sustav se povezao sa susjednim energetskim sustavima kroz tržište električne energije, uz varijabilne cijene energije, što je omogućilo tržišno vrednovanje izvora fleksibilnosti. Usporedio se model energetskog sustava za vremenski korak od 1 sat i 10 minuta.

Rezultati su pokazali da model sustava za vremenski korak od 10 minuta zahtjeva približno jednake kapacitete izvora fleksibilnosti kao i sustav na satnoj bazi, te pruža mogućnost korištenja različitih vrsta izvora fleksibilnosti. Pokazalo se da model sustava s kraćim vremenski korakom pruža više detalja o stvarnom stanju u sustavu čime omogućuje bolju integraciju različitih izvora fleksibilnosti i njihovo povoljnije tržišno vrednovanje. Pruža više detalja za razvoj tržišta električne energije. Omogućuje sigurniju integraciju OIE u sustavu, što se očitovalo u smanjenju ukupnih prekograničnih prijenosnih kapaciteta. Samim time nudi bolju stabilnost i fleksibilnost unutar sustav koju zahtijevaju manji sustavi kao što je energetski sustav šireg gradskog područja. U odnosu na satni model, model sustava za kratkoročan vremenski korak smanjio je izvoz za približno 110 GWh/god, odnosno za 72%. Uvoz se povećao za približno 11 GWh/god, odnosno za 50%, što je doprinijelo ujednačavanju prijenosnih kapaciteta uvoza i izvoza u sustavu, te rezultiralo boljom stabilnošću i sigurnošću rada sustava. Ukupno smanjenje prekograničnih kapaciteta iznosi približno 98 GWh/god., što predstavlja smanjenje za 60,8%. Korišteno je dodatnih 16 MW B2U stacionarnih spremnika energije, čime je u sustavu povećana ukupna instalirana snaga ES za približno 6 MW.

4.5 Preporuke za računalne alate i modele naprednog energetskog planiranja

Detaljni proračuni i razrađene analize u radu dovele su i do određenih preporuka i prijedloga za napredno planiranje pametnih energetskih sustava. Računalni modeli za energetsko planiranje zahtijevaju dodatna poboljšanja i dorade za proračune bazirane na kratkoročnom vremenskom koraku od 10 minuta. Za program EnergyPLAN, koji već ima dobro razvijen model na satnoj osnovi unosa podataka, predlaže se nadogradnja modela za vremenski korak od 10 minuta, s obzirom da se pokazalo da planiranje, bazirano na kraćem vremenskom koraku, uz iznimno brzo punjenje i pražnjenje EV modelom V2G, pruža više

detalja za bolju integraciju svih sudionika u sustavu. Program Calliope nije ograničen količinom ulaznih podataka i nudi mogućnost proračuna za različite vremenske korak. Međutim, korisnik mora uložiti dodatne napore kako bi prilagodio podatke za kraći vremenski korak. Novi algoritam, razvijen u ovom radu, obuhvaća samo dio mogućnosti koje pruža napredno energetsko planiranje i potrebna je njegova daljnja razrada i razvoj.

Za izradu što točnijeg energetskog plana za buduća razdoblja, potrebno je poboljšati modele predviđanja potrošnje energije, posebice kod transportnog i toplinskog sektora, te je potrebna detaljnija obrada podataka. Predlaže se poticanje V2G modela, uz iznimno brzo punjenje i pražnjenje EV, što će omogućiti veću penetraciju EV i donijeti dobrobiti za vlasnike EV kao i pridonijeti fleksibilnosti obnovljivog energetskog sustava. Predlažu se i detaljnije tehno-ekonomske analize model V2G. Predlaže se daljnji razvoj i planiranje B2U modela koji će doprinijeti smanjenju cijena EV i pružiti dodatnu fleksibilnost sustavu. Jačanje i nadogradnja infrastrukture od velike je važnosti za obnovljive sustave, što uključuje nadogradnju prijenosnih kapaciteta i izgradnju infrastrukture za EV. Modeli varijabilnih cijena električne energije i povezanost sa tržištima, uz period trgovanja na vremenskom koraku od 10 minuta, omogućit će tržišno vrednovanje svih sudionika u sustavu, te osigurati njihovo ekonomično i aktivno sudjelovanje. To je iznimno važno kod 100% obnovljivih energetskih sustava, kako bi se postigla regulacija energetskih tokova u cilju da potrošnja prati proizvodnju. Razvoj i primjena IKT alat važni su za ostvarivanju komunikacije među sudionicima sustav i od iznimne su važnosti u regulaciji energetskih tokova koja osigurava stabilnost i sigurnost sustav sa 100% udjela OIE u proizvodnje električne energije.

LITERATURA

[1] Europska unija, "Pariški sporazum," *Službeni List Eur. unije*, pp. 4–18, 2016.

[2] A. Šare, G. Krajačić, T. Pukšec, and N. Duić, "The integration of renewable energy sources and electric vehicles into the power system of the Dubrovnik region," *Energy. Sustain. Soc.*, vol. 5, no. 1, 2015, doi: 10.1186/s13705-015-0055-7.

[3] Á. Cunha *et al.*, "Assessment of the use of vanadium redox flow batteries for energy storage and fast charging of electric vehicles in gas stations," *Energy*, vol. 115, pp. 1478–1494, 2016, doi: 10.1016/j.energy.2016.02.118.

[4] European Parliament, "Directive 2009/30/EC of the European Parliament and of the Council," *Off. J. Eur. Union*, no. April, p. L140/88-L140/113, 2009, doi: 10.3000/17252555.L_2009.140.eng.

[5] European Parlament, "European Directive 2012/27 EU," no. October, pp. 1–56, 2012, [Online]. Available: https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32012L0027&from=EN.

[6] Europska unija, "REPowerEU," 22AD. https://ec.europa.eu/info/strategy/priorities-2019-2024/european-green-deal/repowereu-affordable-secure-and-sustainable-energy-europe_hr.

[7] Europsko vijeće and Vijeće Europske Unije, "Spremni za 55%," 2022. https://www.consilium.europa.eu/hr/policies/green-deal/fit-for-55-the-eu-plan-for-a-green-transition/.

[8] M. A. Sayegh, P. Jadwiszczak, B. P. Axcell, E. Niemierka, K. Bryś, and H. Jouhara, "Heat pump placement, connection and operational modes in European district heating," *Energy Build.*, vol. 166, pp. 122–144, 2018, doi: 10.1016/j.enbuild.2018.02.006.

[9] M. Rämä and M. Wahlroos, "Introduction of new decentralised renewable heat supply in an existing district heating system," *Energy*, vol. 154, pp. 68–79, 2018, doi: 10.1016/j.energy.2018.03.105.

[10] Europski parlament i vijeće Europske unije, "DIREKTIVA (EU) 2018/844 EUROPSKOG PARLAMENTA I VIJEĆA," *Službeni List Eur. unije*, vol. 156, pp. 75–91, 2018.

[11] HRVATSKI SABOR, "Strategija Energetskog Razvoja Republike Hrvatske," *Hrvat. Sabor*, vol. 53, no. 9, pp. 1689–1699, 2009, doi: 10.1017/CBO9781107415324.004.

[12] HRVATSKI SABOR, "STRATEGIJA ENERGETSKOG RAZVOJA REPUBLIKE HRVATSKE DO 2030. S POGLEDOM NA 2050. GODINU," *Nar. novine*, vol. 25/20, pp. 1–188, 2020.

[13] B. P. Heard, B. W. Brook, T. M. L. Wigley, and C. J. A. Bradshaw, “Burden of proof: A comprehensive review of the feasibility of 100% renewable-electricity systems,” *Renew. Sustain. Energy Rev.*, vol. 76, no. April, pp. 1122–1133, 2017, doi: 10.1016/j.rser.2017.03.114.

[14] T. W. Brown, T. Bischof-Niemz, K. Blok, C. Breyer, H. Lund, and B. V. Mathiesen, “Response to ‘Burden of proof: A comprehensive review of the feasibility of 100% renewable-electricity systems,’” *Renew. Sustain. Energy Rev.*, vol. 92, no. April, pp. 834–847, 2018, doi: 10.1016/j.rser.2018.04.113.

[15] B. Ćosić, N. Markovska, V. Taseska, G. Krajačić, and N. Duić, “Increasing the renewable energy sources absorption capacity of the Macedonian energy system Increasing the renewable energy sources absorption capacity of the Macedonian energy system,” *J. Renew. Sustain. Energy*, vol. 5, no. 041805, pp. 1–8, 2013, doi: 10.1063/1.4812999.

[16] I. Batas Bjelić, N. Rajaković, B. Ćosić, and N. Duić, “Increasing wind power penetration into the existing Serbian energy system,” *Energy*, vol. 57, pp. 30–37, 2013, doi: 10.1016/j.energy.2013.03.043.

[17] B. Ćosić, G. Krajačić, and N. Duić, “A 100% renewable energy system in the year 2050: The case of Macedonia,” *Energy*, vol. 48, no. 1, pp. 80–87, 2012, doi: 10.1016/j.energy.2012.06.078.

[18] G. Krajačić, N. Duić, Z. Zmijarević, B. V. Mathiesen, A. A. Vučinić, and M. Da Graa Carvalho, “Planning for a 100% independent energy system based on smart energy storage for integration of renewables and CO2emissions reduction,” *Appl. Therm. Eng.*, vol. 31, no. 13, pp. 2073–2083, 2011, doi: 10.1016/j.applthermaleng.2011.03.014.

[19] G. Krajačić, N. Duić, and M. da G. Carvalho, “How to achieve a 100% RES electricity supply for Portugal?,” *Appl. Energy*, vol. 88, no. 2, pp. 508–517, 2011, doi: 10.1016/j.apenergy.2010.09.006.

[20] R. Segurado, G. Krajačić, N. Duić, and L. Alves, “Increasing the penetration of renewable energy resources in S . Vicente , Cape Verde ˇ ic,” *Appl. Energy*, vol. 88, pp. 466–472, 2011, doi: 10.1016/j.apenergy.2010.07.005.

[21] Z. Bačelić Medić, B. Ćosić, and N. Duić, “Sustainability of remote communities : 100 % renewable island of Hvar,” *J. Renew. Sustain. Energy*, vol. 5, no. 041806, pp. 1–9, 2013, doi: 10.1063/1.4813000.

[22] N. Duić, G. Krajačić, and M. da G. Carvalho, “RenewIslands methodology for sustainable energy and resource planning for islands,” vol. 12, pp. 1032–1062, 2008,

doi: 10.1016/j.rser.2006.10.015.

[23] G. Krajačić, N. Duić, and M. da G. Carvalho, “H2RES , Energy planning tool for island energy systems – The case of the Island of Mljet,” *Int. J. Hydrogen Energy*, vol. 34, pp. 7015–7026, 2009, doi: 10.1016/j.ijhydene.2008.12.054.

[24] G. Krajačić, “The role of energy storage in planning of 100% renewable energy systems,” University of Zagreb, 2012.

[25] X. Chen, J. Xiao, J. Yuan, Z. Xiao, and W. Gang, “Application and performance analysis of 100% renewable energy systems serving low-density communities,” *Renew. Energy*, vol. 176, pp. 433–446, 2021, doi: 10.1016/j.renene.2021.05.117.

[26] J. Z. Thellufsen *et al.*, “Smart energy cities in a 100% renewable energy context,” *Renew. Sustain. Energy Rev.*, vol. 129, no. May, 2020, doi: 10.1016/j.rser.2020.109922.

[27] K. Hansen, B. V. Mathiesen, and I. R. Skov, “Full energy system transition towards 100% renewable energy in Germany in 2050,” *Renew. Sustain. Energy Rev.*, vol. 102, no. October 2018, pp. 1–13, 2019, doi: 10.1016/j.rser.2018.11.038.

[28] A. Blatiak, F. Bellizio, L. Badesa, and G. Strbac, “Value of optimal trip and charging scheduling of commercial electric vehicle fleets with Vehicle-to-Grid in future low inertia systems,” *Sustain. Energy, Grids Networks*, vol. 31, p. 100738, 2022, doi: 10.1016/j.segan.2022.100738.

[29] B. Wang *et al.*, “Scenario analysis, management, and optimization of a new Vehicle-to-Micro-Grid (V2μG) network based on off-grid renewable building energy systems,” *Appl. Energy*, vol. 325, no. April, p. 119873, 2022, doi: 10.1016/j.apenergy.2022.119873.

[30] D. O’Neill, B. Yildiz, and J. I. Bilbao, “An assessment of electric vehicles and vehicle to grid operations for residential microgrids,” *Energy Reports*, vol. 8, pp. 4104–4116, 2022, doi: 10.1016/j.egyr.2022.02.302.

[31] M. De Gennaro, E. Paffumi, and G. Martini, “Customer-driven design of the recharge infrastructure and Vehicle-to- Grid in urban areas : A large-scale application for electric vehicles deployment,” *Energy*, vol. 82, pp. 294–311, 2015, doi: 10.1016/j.energy.2015.01.039.

[32] M. Neaimeh *et al.*, “A probabilistic approach to combining smart meter and electric vehicle charging data to investigate distribution network impacts,” *Appl. Energy*, vol. 157, pp. 688–698, 2015, doi: 10.1016/j.apenergy.2015.01.144.

[33] D. Steen, L. A. Tuan, O. Carlson, and L. Bertling, “Assessment of Electric Vehicle Charging Scenarios Based on Demographical Data,” vol. 3, no. 3, pp. 1457–1468, 2012.

[34] R. Halvgaard *et al.*, “Electric Vehicle Charge Planning using Economic Model Predictive Control,” in *IEEE International Electric Vehicle Conference*, 2012, p. 6, doi: 10.1109/IEVC.2012.6183173.

[35] P. Prebeg, G. Gasparovic, G. Krajacic, and N. Duic, “Long-term energy planning of Croatian power system using multi-objective optimization with focus on renewable energy and integration of electric vehicles,” *Appl. Energy*, vol. 184, pp. 1493–1507, 2016, doi: 10.1016/j.apenergy.2016.03.086.

[36] Oikon, “Plan korištenja obnovljivih izvora energije na području Dubrovačko-neretvanske županije,” 2015.

[37] Ires ekologija, “Strateška studija utjecaja na okoliš Plana korištenja obnovljivih izvora energije na području Dubrovačko - neretvanske županije,” 2015.

[38] P. Kayal and C. K. Chanda, “A multi-objective approach to integrate solar and wind energy sources with electrical distribution network,” *Sol. Energy*, vol. 112, pp. 397–410, 2015, doi: 10.1016/j.solener.2014.12.012.

[39] G. Tsekouras and D. Koutsoyiannis, “Stochastic analysis and simulation of hydrometeorological processes associated with wind and solar energy,” *Renew. Energy*, vol. 63, pp. 624–633, 2014, doi: 10.1016/j.renene.2013.10.018.

[40] P. Kayal and C. K. Chanda, “Optimal mix of solar and wind distributed generations considering performance improvement of electrical distribution network,” *Renew. Energy*, vol. 75, pp. 173–186, 2015, doi: 10.1016/j.renene.2014.10.003.

[41] A. Purvins, I. T. Papaioannou, I. Oleinikova, and E. Tzimas, “Effects of variable renewable power on a country-scale electricity system : High penetration of hydro power plants and wind farms in electricity generation,” *Energy*, vol. 43, no. 1, pp. 225–236, 2012, doi: 10.1016/j.energy.2012.04.038.

[42] J. Silvente, G. M. Kopanos, E. N. Pistikopoulos, and A. Espuña, “A rolling horizon optimization framework for the simultaneous energy supply and demand planning in microgrids,” *Appl. Energy*, vol. 155, pp. 485–501, 2015, doi: 10.1016/j.apenergy.2015.05.090.

[43] A. Mahesh and K. S. Sandhu, “Hybrid wind/photovoltaic energy system developments: Critical review and findings,” vol. 52, pp. 1135–1147, 2015, doi: 10.1016/j.rser.2015.08.008.

[44] Pérez-Navarro *et al.*, “Experimental verification of hybrid renewable systems as feasible energy sources,” vol. 86, pp. 384–391, 2016, doi: 10.1016/j.renene.2015.08.030.

[45] S. Krajcar and P. Mesarić, “Home demand side management integrated with electric

vehicles and renewable energy sources," *Energy Build.*, vol. 108, pp. 1–9, 2015, doi: 10.1016/j.enbuild.2015.09.001.

[46] Z. Cai *et al.*, "Application of Battery Storage for Compensation of Forecast Errors of Wind Power Generation in 2050," *Energy Procedia*, vol. 73, pp. 208–217, 2015, doi: 10.1016/j.egypro.2015.07.673.

[47] A. M. Foley, P. G. Leahy, A. Marvuglia, and E. J. McKeogh, "Current methods and advances in forecasting of wind power generation," *Renew. Energy*, vol. 37, no. 1, pp. 1–8, 2012, doi: 10.1016/j.renene.2011.05.033.

[48] A. Rasheed, J. Kristoffer Süld, and T. Kvamsdal, "A Multiscale Wind and Power Forecast System for Wind Farms," vol. 53, no. 1876, pp. 290–299, 2014, doi: 10.1016/j.egypro.2014.07.238.

[49] X. Wang, P. Guo, and X. Huang, "Energy Procedia A Review of Wind Power Forecasting Models," *Energy Procedia*, vol. 12, pp. 770–778, 2011, doi: 10.1016/j.egypro.2011.10.103.

[50] M. G. De Giorgi, A. Ficarella, and M. Tarantino, "Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods," *Energy*, vol. 36, no. 7, pp. 3968–3978, 2011, doi: 10.1016/j.energy.2011.05.006.

[51] X. Zhao, S. Wang, and T. Li, "Review of Evaluation Criteria and Main Methods of Wind Power Forecasting," *Energy Procedia*, vol. 12, pp. 761–769, 2011, doi: 10.1016/j.egypro.2011.10.102.

[52] S. Alessandrini, L. D. Monache, S. Sperati, and J. N. Nissen, "A novel application of an analog ensemble for short-term wind power forecasting," *Renew. Energy*, vol. 76, pp. 768–781, 2015, doi: 10.1016/j.renene.2014.11.061.

[53] Y.-Y. Hong, H.-L. Chang, and C.-S. Chiu, "Hour-ahead wind power and speed forecasting using simultaneous perturbation stochastic approximation (SPSA) algorithm and neural network with fuzzy inputs," *Energy*, vol. 35, no. 9, pp. 3870–3876, 2010, doi: 10.1016/j.energy.2010.05.041.

[54] J. Alonso-montesinos and F. J. Batlles, "Solar radiation forecasting in the short- and medium-term under all sky conditions," *Energy*, vol. 83, pp. 387–393, 2015, doi: 10.1016/j.energy.2015.02.036.

[55] R. A. Gupta, R. Kumar, and A. Kumar Bansal, "BBO-based small autonomous hybrid power system optimization incorporating wind speed and solar radiation forecasting," *Renew. Sustain. Energy Rev.*, vol. 41, pp. 1366–1375, 2015, doi: 10.1016/j.rser.2014.09.017.

[56] A. Tascikaraoglu, O. Erdinc, M. Uzunoglu, and A. Karakas, “An adaptive load dispatching and forecasting strategy for a virtual power plant including renewable energy conversion units,” *Appl. Energy*, vol. 119, pp. 445–453, 2014, doi: 10.1016/j.apenergy.2014.01.020.

[57] W. He, “Deep neural network based load forecast,” *Comput. Model. New Technol.*, vol. 18, no. 3, pp. 258–262, 2014.

[58] F. Monforti, T. Huld, K. Bódis, L. Vitali, M. D’Isidoro, and R. Lacal-arántegui, “Assessing complementarity of wind and solar resources for energy production in Italy . A Monte Carlo approach,” *Renew. Energy*, vol. 63, no. 2014, pp. 576–586, 2020, doi: 10.1016/j.renene.2013.10.028.

[59] M. H. Alham, M. Elshahed, D. K. Ibrahim, and E. E. D. A. El Zahab, “Optimal operation of power system incorporating wind energy with demand side management,” *AIN SHAMS Eng. J.*, vol. 8, no. 1, pp. 1–7, 2017, doi: 10.1016/j.asej.2015.07.004.

[60] H. Guan *et al.*, “Urban Climate Response of office building electricity consumption to urban weather in Adelaide , South Australia,” *Urban Clim.*, vol. 10, pp. 42–55, 2014, doi: 10.1016/j.uclim.2014.09.005.

[61] P. De Jong, A. S. Sánchez, K. Esquerre, R. A. Kalid, and E. A. Torres, “Solar and wind energy production in relation to the electricity load curve and hydroelectricity in the northeast region of Brazil,” *Renew. Sustain. Energy Rev.*, vol. 23, pp. 526–535, 2013, doi: 10.1016/j.rser.2013.01.050.

[62] M. Huber, D. Dimkova, and T. Hamacher, “Integration of wind and solar power in Europe : Assessment of fl exibility requirements,” *Energy*, vol. 69, pp. 236–246, 2014, doi: 10.1016/j.energy.2014.02.109.

[63] C. S. E. Bale, L. Varga, and T. J. Foxon, “Energy and complexity : New ways forward,” *Appl. Energy*, vol. 138, pp. 150–159, 2015, doi: 10.1016/j.apenergy.2014.10.057.

[64] A. M. Foley, B. P. Ó Gallachóir, E. J. McKeogh, D. Milborrow, and P. G. Leahy, “Addressing the technical and market challenges to high wind power integration in Ireland,” *Renew. Sustain. Energy Rev.*, vol. 19, pp. 692–703, 2013, doi: 10.1016/j.rser.2012.11.039.

[65] M. Jaradat, M. Jarrah, A. Bousselham, Y. Jararweh, and M. Al-Ayyoub, “The internet of energy: Smart sensor networks and big data management for smart grid,” *Procedia Comput. Sci.*, vol. 56, no. 1, pp. 592–597, 2015, doi: 10.1016/j.procs.2015.07.250.

[66] A. Gaviano, K. Weber, and C. Dirmeier, “Challenges and integration of PV and wind energy facilities from a smart grid point of view,” *Energy Procedia*, vol. 25, pp. 118–

125, 2012, doi: 10.1016/j.egypro.2012.07.016.

[67] M. Mourshed *et al.*, “Smart Grid Futures: Perspectives on the Integration of Energy and ICT Services,” *Energy Procedia*, vol. 75, pp. 1132–1137, 2015, doi: 10.1016/j.egypro.2015.07.531.

[68] H. Lund, A. N. Andersen, P. A. Østergaard, B. V. Mathiesen, and D. Connolly, “From electricity smart grids to smart energy systems - A market operation based approach and understanding,” *Energy*, vol. 42, no. 1, pp. 96–102, 2012, doi: 10.1016/j.energy.2012.04.003.

[69] H. Lund, B. Vad Mathiesen, D. Connolly, and P. A. Østergaarda, “Renewable energy systems - A smart energy systems approach to the choice and modelling of 100 % renewable solutions,” *Chem. Eng. Trans.*, vol. 39, no. Special Issue, pp. 1–6, 2014, doi: 10.3303/CET1439001.

[70] International Energy Agency, *Harnessing Variable Renewables: A Guide to the Balancing Challenge*. 2011.

[71] ENTSO-E, “ENTSO-E Position Paper on Electric Vehicle Integration into Power Grids,” no. March, pp. 4–60, 2021.

[72] A. G. Olabi *et al.*, “Battery electric vehicles: Progress, power electronic converters, strength (S), weakness (W), opportunity (O), and threats (T),” *Int. J. Thermofluids*, vol. 16, no. June, 2022, doi: 10.1016/j.ijft.2022.100212.

[73] J. Johnson, M. Chowdhury, Y. He, and J. Taiber, “Utilizing real-time information transferring potentials to vehicles to improve the fast-charging process in electric vehicles,” *Transp. Res. Part C Emerg. Technol.*, vol. 26, pp. 352–366, 2013, doi: 10.1016/j.trc.2012.10.009.

[74] R. Philipsen, T. Schmidt, and M. Ziefle, “A Charging Place to Be - Users’ Evaluation Criteria for the Positioning of Fast-charging Infrastructure for Electro Mobility,” *Procedia Manuf.*, vol. 3, no. Ahfe, pp. 2792–2799, 2015, doi: 10.1016/j.promfg.2015.07.742.

[75] S. Ahmed *et al.*, “Enabling fast charging – A battery technology gap assessment,” *J. Power Sources*, vol. 367, pp. 250–262, 2017, doi: 10.1016/j.jpowsour.2017.06.055.

[76] Y. Motoaki and M. G. Shirk, “Consumer behavioral adaption in EV fast charging through pricing,” *Energy Policy*, vol. 108, no. March, pp. 178–183, 2017, doi: 10.1016/j.enpol.2017.05.051.

[77] M. Neaimeh, S. D. Salisbury, G. A. Hill, P. T. Blythe, D. R. Scoffield, and J. E. Francfort, “Analysing the usage and evidencing the importance of fast chargers for the

adoption of battery electric vehicles," *Energy Policy*, vol. 108, no. April, pp. 474–486, 2017, doi: 10.1016/j.enpol.2017.06.033.

[78] J. Y. Yong, V. K. Ramachandaramurthy, K. M. Tan, and N. Mithulananthan, "Bi-directional electric vehicle fast charging station with novel reactive power compensation for voltage regulation," *Int. J. Electr. Power Energy Syst.*, vol. 64, pp. 300–310, 2015, doi: 10.1016/j.ijepes.2014.07.025.

[79] S. Li, Y. Huang, and S. J. Mason, "A multi-period optimization model for the deployment of public electric vehicle charging stations on network," *Transp. Res. Part C Emerg. Technol.*, vol. 65, pp. 128–143, 2016, doi: 10.1016/j.trc.2016.01.008.

[80] P. Morrissey, P. Weldon, and M. O'Mahony, "Future standard and fast charging infrastructure planning: An analysis of electric vehicle charging behaviour," *Energy Policy*, vol. 89, pp. 257–270, 2016, doi: 10.1016/j.enpol.2015.12.001.

[81] A. Zhang, J. E. Kang, and C. Kwon, "Incorporating demand dynamics in multi-period capacitated fast-charging location planning for electric vehicles," *Transp. Res. Part B Methodol.*, vol. 103, pp. 5–29, 2017, doi: 10.1016/j.trb.2017.04.016.

[82] C. Madina, I. Zamora, and E. Zabala, "Methodology for assessing electric vehicle charging infrastructure business models," *Energy Policy*, vol. 89, pp. 284–293, 2016, doi: 10.1016/j.enpol.2015.12.007.

[83] A. Schroeder and T. Traber, "The economics of fast charging infrastructure for electric vehicles," *Energy Policy*, vol. 43, pp. 136–144, 2012, doi: 10.1016/j.enpol.2011.12.041.

[84] A. Burnham *et al.*, "Enabling fast charging – Infrastructure and economic considerations," *J. Power Sources*, vol. 367, pp. 237–249, 2017, doi: 10.1016/j.jpowsour.2017.06.079.

[85] T. G. San Román, I. Momber, M. R. Abbad, and Á. Sánchez Miralles, "Regulatory framework and business models for charging plug-in electric vehicles: Infrastructure, agents, and commercial relationships," *Energy Policy*, vol. 39, no. 10, pp. 6360–6375, 2011, doi: 10.1016/j.enpol.2011.07.037.

[86] H. Lund *et al.*, "4th Generation District Heating (4GDH). Integrating smart thermal grids into future sustainable energy systems.," *Energy*, vol. 68, pp. 1–11, 2014, doi: 10.1016/j.energy.2014.02.089.

[87] G. Baccino, S. Lo, G. Taddia, and V. Verda, "ENERGY AND ENVIRONMENTAL ANALYSIS OF AN OPEN-LOOP GROUND-WATER HEAT PUMP SYSTEM IN AN URBAN AREA by," *Therm. Sci.*, vol. 14, no. 3, pp. 693–706, 2010, doi: 10.2298/TSCI1003693B.

[88] Y. Gong, C. Lou, Z. Lu, Y. Yao, and W. Ma, “DEVELOPMENT OF A COMPRESSION-ABSORPTION HEAT PUMP SYSTEM FOR UTILIZING LOW TEMPERATURE GEOTHERMAL WATER,” *Therm. Sci.*, vol. 23, no. 2, pp. 791–799, 2019, doi: https://doi.org/10.2298/TSCI170826241G.

[89] F. Levihn, “CHP and heat pumps to balance renewable power production: Lessons from the district heating network in Stockholm,” *Energy*, vol. 137, pp. 670–678, 2017, doi: 10.1016/j.energy.2017.01.118.

[90] M. B. Blarke and H. Lund, “LARGE-SCALE HEAT PUMPS IN SUSTAINABLE ENERGY SYSTEMS : SYSTEM AND PROJECT PERSPECTIVES by,” *Therm. Sci.*, vol. 11, no. 3, pp. 143–152, 2007, doi: 10.2298/TSCI0703143B.

[91] D. Fischer and H. Madani, “On heat pumps in smart grids: A review,” *Renew. Sustain. Energy Rev.*, vol. 70, no. October 2016, pp. 342–357, 2017, doi: 10.1016/j.rser.2016.11.182.

[92] D. Lauka, J. Gusca, and D. Blumberga, “Heat pumps integration trends in district heating networks of the Baltic States,” *Procedia Comput. Sci.*, vol. 52, no. 1, pp. 835–842, 2015, doi: 10.1016/j.procs.2015.05.140.

[93] Y. Shakir, B. Saparova, Y. Belyayev, A. Kaltayev, M. Murugesan, and J. Simon, “NUMERICAL SIMULATION OF A HEAT PUMP ASSISTED REGENERATIVE SOLAR STILL WITH PCM HEAT STORAGE,” *Therm. Sci.*, vol. 21, pp. 411–418, 2017, doi: https://doi.org/10.2298/TSCI17S2411S.

[94] D. Testi, E. Schito, and P. Conti, “Cost-optimal Sizing of Solar Thermal and Photovoltaic Systems for the Heating and Cooling Needs of a Nearly Zero-Energy Building: The Case Study of a Farm Hostel in Italy,” *Energy Procedia*, vol. 91, pp. 528–536, 2016, doi: 10.1016/j.egypro.2016.06.286.

[95] E. L. Niederhäuser, N. Huguelet, M. Rouge, P. Guiol, and D. Orlando, “Novel Approach for Heating/Cooling Systems for Buildings Based on Photovoltaic-heat Pump: Concept and Evaluation,” *Energy Procedia*, vol. 70, pp. 480–485, 2015, doi: 10.1016/j.egypro.2015.02.151.

[96] P. Di Liddo, P. Lazzeroni, S. Olivero, M. Repetto, and V. A. Ricci, “Application of optimization procedure to the management of renewable based household heating & cooling systems,” *Energy Procedia*, vol. 62, pp. 329–336, 2014, doi: 10.1016/j.egypro.2014.12.394.

[97] C. Schellenberg, J. Lohan, and L. Dimache, “OPERATIONAL OPTIMISATION OF A HEAT PUMP SYSTEM WITH SENSIBLE THERMAL ENERGY STORAGE USING

GENETIC ALGORITHM," *Therm. Sci.*, vol. 22, no. 5, pp. 2189–2202, 2020, doi: https://doi.org/10.2298/TSCI171231272S.

[98] E. L. Niederhäuser, M. Rouge, A. Delley, H. Brülhart, and C. Tinguely, "New Innovative Solar Heating System (Cooling/Heating) Production," *Energy Procedia*, vol. 70, pp. 293–299, 2015, doi: 10.1016/j.egypro.2015.02.126.

[99] X. Guo *et al.*, "Volume design of the heat storage tank of solar assisted water-source heat pump space heating system," *Procedia Eng.*, vol. 205, pp. 2691–2697, 2017, doi: 10.1016/j.proeng.2017.10.196.

[100] P. A. Østergaard and A. N. Andersen, "Economic feasibility of booster heat pumps in heat pump-based district heating systems," *Energy*, vol. 155, pp. 921–929, 2018, doi: 10.1016/j.energy.2018.05.076.

[101] J. Tamasauskas, J. Candanedo, and M. Kegel, "An analysis of the impact of heat pump systems on load matching and grid interaction in the Canadian context," *Energy Procedia*, vol. 78, pp. 2124–2129, 2015, doi: 10.1016/j.egypro.2015.11.284.

[102] C. Ellerbrok, "Potentials of demand side management using heat pumps with building mass as a thermal storage," *Energy Procedia*, vol. 46, no. 0, pp. 214–219, 2014, doi: 10.1016/j.egypro.2014.01.175.

[103] M. Ban, G. Krajačić, M. Grozdek, T. Ćurko, and N. Duić, "The role of cool thermal energy storage (CTES) in the integration of renewable energy sources (RES) and peak load reduction," *Energy*, vol. 48, no. 1, pp. 108–117, 2012, doi: 10.1016/j.energy.2012.06.070.

[104] D. F. Dominković and G. Krajačić, "District cooling versus individual cooling in urban energy systems: The impact of district energy share in cities on the optimal storage sizing," *Energies*, vol. 12, no. 3, 2019, doi: 10.3390/en12030407.

[105] C. Carmo, N. Detlefsen, and M. Nielsen, "Smart Grid enabled heat pumps: An empirical platform for investigating how residential heat pumps can support largescale integration of intermittent renewables," *Energy Procedia*, vol. 61, pp. 1695–1698, 2014, doi: 10.1016/j.egypro.2014.12.194.

[106] Y. J. Baik, M. Kim, K. C. Chang, Y. S. Lee, and H. S. Ra, "Potential to enhance performance of seawater-source heat pump by series operation," *Renew. Energy*, vol. 65, pp. 236–244, 2014, doi: 10.1016/j.renene.2013.09.021.

[107] L. Zhen, D. M. Lin, H. W. Shu, S. Jiang, and Y. X. Zhu, "District cooling and heating with seawater as heat source and sink in Dalian, China," *Renew. Energy*, vol. 32, no. 15, pp. 2603–2616, 2007, doi: 10.1016/j.renene.2006.12.015.

[108] A. C. V. Marques and W. Dos Santos Oliveira, “Technological forecasting: Heat pumps and the synergy with renewable energy,” *Energy Procedia*, vol. 48, pp. 1650–1657, 2014, doi: 10.1016/j.egypro.2014.02.186.

[109] International Energy Agency, “The Future of Cooling,” 2018.

[110] International Energy Agency, “The Future of Cooling in China suistainable air conditioning,” no. June, 2019.

[111] H. Averfalk, P. Ingvarsson, U. Persson, M. Gong, and S. Werner, “Large heat pumps in Swedish district heating systems,” *Renew. Sustain. Energy Rev.*, vol. 79, no. June 2016, pp. 1275–1284, 2017, doi: 10.1016/j.rser.2017.05.135.

[112] X. Jia, L. Duanmu, and H. Shu, “Multifactor analysis on beach well infiltration intake system for seawater source heat pump,” *Energy Build.*, vol. 154, pp. 244–253, 2017, doi: 10.1016/j.enbuild.2017.08.063.

[113] S. Haiwen, D. Lin, L. Xiangli, and Z. Yingxin, “Quasi-dynamic energy-saving judgment of electric-driven seawater source heat pump district heating system over boiler house district heating system,” *Energy Build.*, vol. 42, no. 12, pp. 2424–2430, 2010, doi: 10.1016/j.enbuild.2010.08.012.

[114] X. Zheng, S. You, J. Yang, and G. Chen, “Seepage and heat transfer modeling on beach well infiltration intake system in seawater source heat pump,” *Energy Build.*, vol. 68, no. PARTA, pp. 147–155, 2014, doi: 10.1016/j.enbuild.2013.09.005.

[115] M. Li, M. Feng, D. Luo, and Z. Chen, “Fast Charging Li-Ion Batteries for a New Era of Electric Vehicles,” *Cell Reports Phys. Sci.*, vol. 1, no. 10, pp. 1–16, 2020, doi: 10.1016/j.xcrp.2020.100212.

[116] J. Du *et al.*, “Impact of high-power charging on the durability and safety of lithium batteries used in long-range battery electric vehicles,” *Appl. Energy*, vol. 255, no. August, pp. 1–10, 2019, doi: 10.1016/j.apenergy.2019.113793.

[117] M. Keyser *et al.*, “Enabling fast charging – Battery thermal considerations,” *J. Power Sources*, vol. 367, pp. 228–236, 2017, doi: 10.1016/j.jpowsour.2017.07.009.

[118] R. Lund and U. Persson, “Mapping of potential heat sources for heat pumps for district heating in Denmark,” *Energy*, vol. 110, pp. 129–138, 2016, doi: 10.1016/j.energy.2015.12.127.

[119] J. Wen, D. Zhao, and C. Zhang, “An overview of electricity powered vehicles: Lithium-ion battery energy storage density and energy conversion efficiency,” *Renew. Energy*, vol. 162, pp. 1629–1648, 2020, doi: 10.1016/j.renene.2020.09.055.

[120] N. Lutsey and M. Nicholas, “Update on electric vehicle costs in the United States

through 2030," *Int. Counc. Clean Transp.*, pp. 1–12, 2019, [Online]. Available: https://theicct.org/sites/default/files/publications/EV_cost_2020_2030_20190401.pdf.

[121] P. García-Triviño, J. P. Torreglosa, L. M. Fernández-Ramírez, and F. Jurado, "Control and operation of power sources in a medium-voltage direct-current microgrid for an electric vehicle fast charging station with a photovoltaic and a battery energy storage system," *Energy*, vol. 115, pp. 38–48, 2016, doi: 10.1016/j.energy.2016.08.099.

[122] C. Capasso and O. Veneri, "Experimental study of a DC charging station for full electric and plug in hybrid vehicles," *Appl. Energy*, vol. 152, pp. 131–142, 2015, doi: 10.1016/j.apenergy.2015.04.040.

[123] H. Ding, Z. Hu, and Y. Song, "Value of the energy storage system in an electric bus fast charging station," *Appl. Energy*, vol. 157, pp. 630–639, 2015, doi: 10.1016/j.apenergy.2015.01.058.

[124] D. Sbordone, I. Bertini, B. Di Pietra, M. C. Falvo, A. Genovese, and L. Martirano, "EV fast charging stations and energy storage technologies: A real implementation in the smart micro grid paradigm," *Electr. Power Syst. Res.*, vol. 120, pp. 96–108, 2015, doi: 10.1016/j.epsr.2014.07.033.

[125] M. Aziz, T. Oda, T. Mitani, Y. Watanabe, and T. Kashiwagi, "Utilization of Electric Vehicles and Their Used Batteries for Peak-Load Shifting," *Energies*, vol. 8, no. May, pp. 3720–3738, 2015, doi: 10.3390/en8053720.

[126] F. Deflorio, P. Guglielmi, I. Pinna, L. Castello, and S. Marfull, "Modeling and analysis of wireless 'charge while driving' operations for fully electric vehicles," *Transp. Res. Procedia*, vol. 5, pp. 161–174, 2015, doi: 10.1016/j.trpro.2015.01.008.

[127] Z. Chen, W. Liu, and Y. Yin, "Deployment of stationary and dynamic charging infrastructure for electric vehicles along traffic corridors," *Transp. Res. Part C Emerg. Technol.*, vol. 77, pp. 185–206, 2017, doi: 10.1016/j.trc.2017.01.021.

[128] P. Mirchandani, J. Adler, and O. B. G. Madsen, "New Logistical Issues in Using Electric Vehicle Fleets with Battery Exchange Infrastructure," *Procedia - Soc. Behav. Sci.*, vol. 108, pp. 3–14, 2014, doi: 10.1016/j.sbspro.2013.12.815.

[129] A. R. Bhatti, Z. Salam, M. J. B. A. Aziz, K. P. Yee, and R. H. Ashique, "Electric vehicles charging using photovoltaic: Status and technological review," *Renew. Sustain. Energy Rev.*, vol. 54, pp. 34–47, 2016, doi: 10.1016/j.rser.2015.09.091.

[130] J. Dixon, W. Bukhsh, K. Bell, and C. Brand, "Vehicle to grid: driver plug-in patterns, their impact on the cost and carbon of charging, and implications for system flexibility," *eTransportation*, vol. 13, p. 100180, 2022, doi: 10.1016/j.etran.2022.100180.

[131] C. Gschwendtner and K. Krauss, “Coupling transport and electricity: How can vehicle-to-grid boost the attractiveness of carsharing?,” *Transp. Res. Part D Transp. Environ.*, vol. 106, no. April, 2022, doi: 10.1016/j.trd.2022.103261.

[132] B. Li *et al.*, “Integration of battery electric vehicles in a regional hydro–wind–thermal power system,” *Energy Reports*, vol. 6, pp. 1199–1205, 2020, doi: 10.1016/j.egyr.2020.11.054.

[133] M. Schwarz, Q. Auzepy, and C. Knoeri, “Can electricity pricing leverage electric vehicles and battery storage to integrate high shares of solar photovoltaics?,” *Appl. Energy*, vol. 277, no. June, pp. 1–16, 2020, doi: 10.1016/j.apenergy.2020.115548.

[134] J. P. Skeete, P. Wells, X. Dong, O. Heidrich, and G. Harper, “Beyond the EVent horizon: Battery waste, recycling, and sustainability in the United Kingdom electric vehicle transition,” *Energy Res. Soc. Sci.*, vol. 69, no. May, pp. 1–15, 2020, doi: 10.1016/j.erss.2020.101581.

[135] W. Chen, J. Liang, Z. Yang, and G. Li, “A review of lithium-ion battery for electric vehicle applications and beyond,” *Energy Procedia*, vol. 158, pp. 4363–4368, 2019, doi: 10.1016/j.egypro.2019.01.783.

[136] H. Rallo, G. Benveniste, I. Gestoso, and B. Amante, “Economic analysis of the disassembling activities to the reuse of electric vehicles Li-ion batteries,” *Resour. Conserv. Recycl.*, vol. 159, no. October 2019, pp. 1–11, 2020, doi: 10.1016/j.resconrec.2020.104785.

[137] M. Abdelbaky, J. R. Peeters, J. R. Duflou, and W. Dewulf, “Forecasting the EU recycling potential for batteries from electric vehicles,” *Procedia CIRP*, vol. 90, pp. 432–436, 2020, doi: 10.1016/j.procir.2020.01.109.

[138] M. A. Cusenza, F. Guarino, S. Longo, M. Ferraro, and M. Cellura, “Energy and environmental benefits of circular economy strategies: The case study of reusing used batteries from electric vehicles,” *J. Energy Storage*, vol. 25, no. July, pp. 1–11, 2019, doi: 10.1016/j.est.2019.100845.

[139] B. Sun *et al.*, “Economic analysis of lithium-ion batteries recycled from electric vehicles for secondary use in power load peak shaving in China,” *J. Clean. Prod.*, vol. 276, pp. 1–17, 2020, doi: 10.1016/j.jclepro.2020.123327.

[140] P. Zhou *et al.*, “A rapid classification method of the retired LiCoxNiyMn1−x−yO2 batteries for electric vehicles,” *Energy Reports*, vol. 6, pp. 672–683, 2020, doi: 10.1016/j.egyr.2020.03.013.

[141] Y. Choi and S. W. Rhee, “Current status and perspectives on recycling of end-of-life

battery of electric vehicle in Korea (Republic of)," *Waste Manag.*, vol. 106, pp. 261–270, 2020, doi: 10.1016/j.wasman.2020.03.015.

[142] W. Wu, B. Lin, C. Xie, R. J. R. Elliott, and J. Radcliffe, "Does energy storage provide a profitable second life for electric vehicle batteries?," *Energy Econ.*, vol. 92, p. 105010, 2020, doi: 10.1016/j.eneco.2020.105010.

[143] C. Tarhan and M. A. Çil, "A study on hydrogen, the clean energy of the future: Hydrogen storage methods," *J. Energy Storage*, vol. 40, no. March, pp. 1–10, 2021, doi: 10.1016/j.est.2021.102676.

[144] N. S. Muhammed, B. Haq, D. Al Shehri, A. Al-Ahmed, M. M. Rahman, and E. Zaman, "A review on underground hydrogen storage: Insight into geological sites, influencing factors and future outlook," *Energy Reports*, vol. 8, pp. 461–499, 2022, doi: 10.1016/j.egyr.2021.12.002.

[145] C. Jin, J. Xiao, J. Hou, X. Wu, J. Zhang, and E. Du, "Flexibility improvement evaluation of hydrogen storage based on electricity–hydrogen coupled energy model," *Glob. Energy Interconnect.*, vol. 4, no. 4, pp. 371–383, 2021, doi: 10.1016/j.gloei.2021.09.004.

[146] I. A. Hassan, H. S. Ramadan, M. A. Saleh, and D. Hissel, "Hydrogen storage technologies for stationary and mobile applications: Review, analysis and perspectives," *Renew. Sustain. Energy Rev.*, vol. 149, no. December 2020, pp. 1–27, 2021, doi: 10.1016/j.rser.2021.111311.

[147] N. A. Ali and M. Ismail, "Advanced hydrogen storage of the Mg–Na–Al system: A review," *J. Magnes. Alloy.*, vol. 9, no. 4, pp. 1111–1122, 2021, doi: 10.1016/j.jma.2021.03.031.

[148] Z. Li, H. Dong, S. Hou, L. Cheng, and H. Sun, "Coordinated control scheme of a hybrid renewable power system based on hydrogen energy storage," *Energy Reports*, vol. 7, pp. 5597–5611, 2021, doi: 10.1016/j.egyr.2021.08.176.

[149] A. M. Elberry, J. Thakur, and J. Veysey, "Seasonal hydrogen storage for sustainable renewable energy integration in the electricity sector: A case study of Finland," *J. Energy Storage*, vol. 44, no. PB, pp. 1–14, 2021, doi: 10.1016/j.est.2021.103474.

[150] European Commission, "Quarterly Report on European Electricity Markets - Q1," Bruxelles, 2018. [Online]. Available: https://circabc.europa.eu/ui/group/3ef9355f-1ffe-4c82-ba19-f60a3ed2f652/library/55a10a96-a12c-48cc-ac38-e3104240f39a?p=1&n=10&sort=modified_DESC.

[151] European Commission, "Quarterly Report on European Electricity Martkets - Q2,"

Bruxelles, 2018. [Online]. Available: https://circabc.europa.eu/ui/group/3ef9355f-1ffe-4c82-ba19-f60a3ed2f652/library/55a10a96-a12c-48cc-ac38-e3104240f39a?p=1&n=10&sort=modified_DESC.

[152] European Commission, "Quarterly Report on European Electricity Markets - Q3," Bruxelles, 2018. [Online]. Available: https://circabc.europa.eu/ui/group/3ef9355f-1ffe-4c82-ba19-f60a3ed2f652/library/55a10a96-a12c-48cc-ac38-e3104240f39a?p=1&n=10&sort=modified_DESC.

[153] European Commission, "Quarterly Report on European Electricity Markets - Q4," Bruxelles, 2018. [Online]. Available: https://circabc.europa.eu/ui/group/3ef9355f-1ffe-4c82-ba19-f60a3ed2f652/library/55a10a96-a12c-48cc-ac38-e3104240f39a?p=1&n=10&sort=modified_DESC.

[154] T. Radica, *Dubrovnik i okolica*, First. Zagreb: Meridijani, 2015.

[155] "Hotmaps." https://www.hotmaps.eu/map.

[156] "HEP ELEKTRA." https://www.hep.hr/elektra/kucanstvo/tarifne-stavke-cijene/1547.

[157] "Wikipedija," 2020. .

[158] Cannon-Libertas Co . d . o . o, "ELABORAT ZAŠTITE OKOLIŠA ZA OCJENU O POTREBI PROCJENE UTJECAJA NA OKOLIŠ ZA IZMJENU ZAHVATA VJETROELEKTRANE „ KONAVOSKA BRDA ", OPĆINA KONAVLE," Zagreb, 2020.

[159] "Hrvatska elektroprivreda d.d., HEP proizvodnja." .

[160] Hrvatska elektroprivreda d.d., *Hidroelektrane u Hrvatskoj*. PRINTERA d.o.o.

[161] U. Vidović *et al.*, "Plan Održive Urbane Mobilnosti (SUMP) Draft Dubrovnik," 2019.

[162] A. Šare, "UTJECAJ ELEKTRIFIKACIJE TRANSPORTA NA KRIVULJU POTROŠNJE ELEKTRIČNE ENERGIJE I INTEGRACIJU OBNOVLJIVIH IZVORA ENERGIJE U DUBROVAČKOJ REGIJI," Sveučilište u Zagrebu, 2012.

[163] T. Pukšec, Z. Lulić, B. V. Mathiesen, and N. Duić, "Energy Policy and Long Term Energy Demand of a Transport Sector: Case Study Croatia," 2012, [Online]. Available: https://www.bib.irb.hr/586997?&rad=586997.

[164] M. Lizačić-Vidaković, F. Kulić, D. Vidaković, T. Šnidaršić, and D. Vidaković, "Zajednički akcijski plan energetski održivog razvitka i klimatskih promjena (JointSECAP) za područje Grada Dubrovnika, Općine Konavle, Općine Župa dubrovačka, Općine Dubrovačko primorje i Općine Ston," Osijek, 2020.

[165] "Hrvatski operator prijenosnog sustava," 2022. www.hops.hr.

[166] Statsoft, "Statistica Quick Reference," *19.Noviembre-2013*, pp. 1–298, 2011.

[167] “DHMZ - Državni hidrometeorološki zavod.” https://meteo.hr/.

[168] Državni hidrometeorološki zavod, “Naputak za opažanja i mjerenja na glavnim meteorološkim postajama,” Zagreb, 2008.

[169] “Elektrojug Dubrovnik – HEP ODS d.o.o.” .

[170] D. M. Vedran Krstulović, Margareta Zidar, Dražen Balić, Ivan Bačan, “Studija optimalnog rješenja sustava grijanja i hlađenja u povijesnoj jezgri Dubrovnika,” 2018.

[171] L. Schibuola and M. Scarpa, “Experimental analysis of the performances of a surface water source heat pump,” *Energy Build.*, vol. 113, pp. 182–188, 2016, doi: 10.1016/j.enbuild.2015.12.048.

[172] S. Hiawen, W. Tingyu, J. Xin, R. Zhiyong, Y. Haiyang, and L. Duanmu, “Energy Efficiency Enhancement Potential of the Heat Pump Unit in a Seawater Source Heat Pump District Heating System,” *Procedia Eng.*, vol. 146, pp. 134–138, 2016, doi: 10.1016/j.proeng.2016.06.363.

[173] “SOLVIS d.o.o.,” 2021. https://solvis.hr/.

[174] “SOLVIS Fotonaponski moduli MODEL SV72 E.” Varaždin, 2019, [Online]. Available: https://solvis.hr/wp-content/uploads/2020/10/LQSOLVIS-DS-HR-SV72_E_5BB-1981x1000x40-375-390-20190902.pdf.

[175] L. M. Miller and D. W. Keith, “Observation-based solar and wind power capacity factors and power densities,” *Environ. Res. Lett.*, vol. 14, no. 7, 2019, doi: 10.1088/1748-9326/ab12a2.

[176] H. Wirth, “Recent facts about photovoltaics in Germany,” 2021. [Online]. Available: http://pschuetzenduebe.webclient5.de/wp-content/uploads/130912-Recent-Facts-PV-Germany.pdf.

[177] T. Trondle, “Supply-side options to reduce land requirements of fully renewable electricity in Europe,” *PLoS One*, vol. 15, no. 8 August, pp. 1–19, 2020, doi: 10.1371/journal.pone.0236958.

[178] Energetski institut Hrvoje Požar, *Analize i podloge za izradu energetske strategije Republike Hrvatske ZELENA KNJIGA*. Zagreb, 2019.

[179] “Državni zavod za statistiku.” https://www.dzs.hr/.

[180] A. Falkoni, A. Pfeifer, and G. Krajačić, “Vehicle-to-Grid in Standard and Fast Electric Vehicle Charging: Comparison of Renewable Energy Source Utilization and Charging Costs,” *Energies*, vol. 13, no. 6, p. 1510, 2020, doi: 10.3390/en13061510.

[181] “Centra za vozila Hrvatske,” 2020. .

[182] J. Dixon and K. Bell, “Electric vehicles: Battery capacity, charger power, access to

charging and the impacts on distribution networks," *eTransportation*, vol. 4, p. 100059, 2020, doi: 10.1016/j.etran.2020.100059.

[183] H. Lund, J. Z. Thellufsen, P. A. Østergaard, P. Sorknæs, I. R. Skov, and B. V. Mathiesen, "EnergyPLAN – Advanced analysis of smart energy systems," *Smart Energy*, vol. 1, p. 100007, 2021, doi: 10.1016/j.segy.2021.100007.

[184] S. Pfenninger and B. Pickering, "Calliope: a multi-scale energy systems modelling framework," *J. Open Source Softw.*, vol. 3, no. 29, p. 825, 2018, doi: 10.21105/joss.00825.

[185] Danish Energy Agency, "Danish Energy Agency," 2022. https://ens.dk/en/our-services/projections-and-models/technology-data.

[186] A. Falkoni and G. Krajačić, "Linear correlation and regression between the meteorological data and the electricity demand of the Dubrovnik region in a short-term scale," *Therm. Sci.*, vol. 20, no. 4, pp. 1073–1089, 2016, doi: 10.2298/TSCI151209157F.

[187] A. Falkoni, V. Soldo, G. Krajacic, M. Bupic, and I. Bertovic, "Utilization of RES using seawater source heat pump with and without energy storage: Comparison of Thermal and Battery Energy Storage," *Therm. Sci.*, vol. 24, no. 6 Part A, pp. 3589–3600, 2020, doi: 10.2298/tsci200324279f.

[188] Ministry of Environment and Energy, "Energy in Croatia - Annual Energy Report 2018," p. 246, 2019, [Online]. Available: http://www.eihp.hr/wp-content/uploads/2019/12/Energija2018.pdf.

PRILOG 1

Model 100% obnovljivog energetskog sustava šireg gradskog područja za 2050. godinu i vremenski korak od 1 sat u programu Calliope:

```
import:  # Import other files from paths relative to this file, or absolute paths
   - 'model_config/techs.yaml'
   - 'model_config/locations.yaml'
   - 'scenarios.yaml'

model:
   name: DubrovnikEnergySystem_1h_2050 model
   # What version of Calliope this model is intended for calliope_version: 0.6.6

   # Time series data path - can either be a path relative to this file, or an absolute path
   timeseries_data_path: 'timeseries_data'

   subset_time: ['2014-01-01', '2014-12-31']  # Subset of timesteps
run:
   mode: plan  # Choices: plan, operate
   solver: gurobi
   ensure_feasibility: true # Switching on unmet demand
   bigM: 1e6 # setting the scale of unmet demand, which cannot be too high, otherwise the optimisation will not converge
   objective_options.cost_class: {monetary: 1}

locations:
   # X1-start
   X1: #Komolac trafostanica
      techs:
         hp:
         pv:
         G2V:
         V2G:
         ev_battery:
         B2U:
         Electrolyzer:
         SEV:
         Fuel cell:
         TES:
         RES:
         demand_electricity:
            constraints.resource: file=demand_electricity.csv
         demand_electricity_ev:
            constraints.resource: file=demand_electricity_ev.csv
         demand_heat:
            constraints.resource: file=demand_heat.csv
         demand_cooling:
            constraints.resource: file=demand_cooling.csv
```

```
    # X1-end
    # other-locs-start
    X2: # VE Mravinjac i Konavoska brda
      techs:
        B2U:
        Electrolyzer:
        SEV:
        Fuel cell:
        ve:
    X3: # SE Zadubravica, Ravne glavice, Mokri Do, Dubok dol, Dugažica, Čulev dol
      techs:
        B2U:
        Electrolyzer:
        SEV:
        Fuel cell:
        se:
    X4: # HE Dubrovnik
      techs:
        B2U:
        Electrolyzer:
        SEV:
        Fuel cell:
        hydro:
    X5: # Import
      techs:
        supply_grid_power:
    # other-locs-end

links:
    # links-start
    X1,X2:
      techs:
        power_lines:
          distance: 25 # km
          constraints:
            energy_cap_max: 220000 # kW
    X1,X3:
      techs:
        power_lines:
          distance: 25 # km
          constraints:
            energy_cap_max: 45000 # kW
    X1,X4:
      techs:
        power_lines:
          distance: 20 # km
          constraints:
            energy_cap_max: 130000 # kW
    X1,X5:
      techs:
```

```
        power_lines:
          distance: 27 # km
          constraints:
            energy_cap_max: 400000 # kW
  X4,X5:
    techs:
      power_lines:
        distance: 30 # km
        constraints:
          energy_cap_max: 114000 # kW
  # links-end

##
# TECHNOLOGY DEFINITIONS
##
# Note: '-start' and '-end' is used in tutorial documentation only

# supply_power_plus-start
tech_groups:
  supply_power_plus:
    essentials:
      parent: supply_plus
      carrier: electricity
# supply_power_plus-end

techs:
##-GRID SUPPLY-## zeleno
  # supply-start zeleno
  supply_grid_power:
    essentials:
      name: 'Uvoz'
      color: '#02aef7'
      parent: supply
      carrier: electricity
    constraints:
      resource: inf
      energy_cap_max: 400000 #kW
      lifetime: 25
    costs:
      monetary:
        interest_rate: 0.10
        om_prod: file=export_power_CROPEX_X5.csv # EUR/kWh
        energy_cap: 15 # EUR/kW
        om_con: 0.1 # 10p/kWh electricity price #ppt
  # supply-end

##-Renewables-##
  # pv-start
  pv:
    essentials:
```

```
        name: 'FN - krov'
        color: '#faf202'
        parent: supply_power_plus
    constraints:
        export_carrier: electricity
        resource: file=pv_production.csv  # Already accounts for panel efficiency - kWh/m2
        resource_unit: energy # kWh
        parasitic_eff: 0.85 # inverter losses
        energy_cap_max: 41000 # kW
        force_resource: true
        lifetime: 40
    costs:
        monetary:
            interest_rate: 0.10
            energy_cap: 590 # EUR/kW
            om_annual: 9.135 # EUR/kW/y
# pv-end

# se-start
se:
    essentials:
        name: 'SE - tlo'
        color: '#F9D956'
        parent: supply_power_plus
    constraints:
        export_carrier: electricity
        resource: file=se_production.csv  # Already accounts for panel efficiency - kWh/m2
        resource_unit: energy # kWh
        parasitic_eff: 0.85 # inverter losses
        energy_cap_max: 44000 # kW
        force_resource: true
        lifetime: 40
    costs:
        monetary:
            interest_rate: 0.10
            energy_cap: 590 # EUR/kW
            om_annual: 9.135 # EUR/kW/y
# se-end

# hydro-start
hydro:
    essentials:
        name: 'HE Dubrovnik'
        color: '#0238fa'
        parent: supply_power_plus
        carrier_out: electricity
    constraints:
        export_carrier: electricity
        resource: inf
        resource_unit: energy
```

```
        energy_cap_max: 126000 # kW
        energy_cap_min: 50000 # kW
        storage_cap_max: inf
        energy_cap_per_storage_cap_max: 1
        energy_eff: 0.87  # Based on {dinorwig_report}, to get ~0.75 round-trip efficiency
        lifetime: 50
      costs:
        monetary:
          energy_cap: 400  # EUR/kW
          storage_cap: 2 # EUR per kWh storage capacity
          om_annual: 9  # EUR/kW/y
          interest_rate: 0.10
   #hydro-end

  # ve-start
   ve:
      essentials:
        name: 'VE'
        color: '#2afc00'
        parent: supply_power_plus
      constraints:
        export_carrier: electricity
        resource: file=ve_production.csv  # kWh
        resource_unit: energy
        parasitic_eff: 0.85 # inverter losses
        energy_cap_max: 219000 # kW
        force_resource: true
        lifetime: 30
      costs:
        monetary:
          interest_rate: 0.10
          energy_cap: 960 # EUR/kW
          om_annual: 11.34  # EUR/kW/y
  # ve-end

# Conversion
  # G2V-start
  G2V:
      essentials:
        name: 'G2V'
        color: '#4ac93e'
        parent: conversion
        carrier_in: electricity
        carrier_out: electricity_ev
      constraints:
        energy_eff: 0.95
        lifetime: 25
        energy_cap_max: 214866 # kW
      costs:
        monetary:
```

```
            energy_cap: 0
            interest_rate: 0.10
#G2V-end

# V2G-start
V2G:
   essentials:
      name: 'V2G'
      color: '#992ab8'
      parent: conversion
      carrier_in: electricity_ev
      carrier_out: electricity
   constraints:
      energy_eff: 0.95
      lifetime: 25
      energy_cap_max: 203504 # kW
   costs:
      monetary:
         energy_cap: 0
         interest_rate: 0.10
#V2G-end

# Electrolyzer-start
Electrolyzer:
   essentials:
      name: 'Elektrolizator'
      color: '#03fcca'
      parent: conversion
      carrier_in: electricity
      carrier_out: hydrogen
   constraints:
      energy_eff: 0.8
      lifetime: 35 #
      energy_cap_max: 50000 # kW
   costs:
      monetary:
         energy_cap: 250 # EUR/kW
         interest_rate: 0.10
#Electrolyzer-end

# Fuel cell-start
Fuel cell:
   essentials:
      name: 'Gorivni članak'
      color: '#fa8a02'
      parent: conversion
      carrier_in: hydrogen
      carrier_out: electricity
   constraints:
      energy_eff: 0.7
```

```
        lifetime: 10
        energy_cap_max: 27000 # kW
      costs:
        monetary:
          energy_cap: 800 # EUR/kW
          interest_rate: 0.10
  #Fuel cell-end

# Conversion_plus
  # hp-start
  hp:
    essentials:
      name: 'DTMV'
      color: '#e69650'
      parent: conversion_plus
      carrier_in: electricity
      carrier_out: [heat,cooling]
      primary_carrier_out: heat
    constraints:
      energy_cap_max: 105000 # kW
      energy_eff: 1
      carrier_ratios:
        carrier_out:
          heat: 3.3
          cooling: 6.3
      lifetime: 25
    costs:
      monetary:
        interest_rate: 0.10
        energy_cap: 380 # EUR/kW
        om_prod: 0.004  # .4p/kWh for 4500 operating hours/year
        om_annual: 4  # EUR/kW/y
  # hp-end

##-STORAGE-##
  # storage-start
  ev_battery:
    essentials:
      name: 'BEV'
      color: '#024f05'
      parent: storage
      carrier: electricity_ev
    constraints:
      storage_cap_max: 1167760 # kWh
      energy_eff: 1
      storage_loss: 0  # No loss over time assumed
      lifetime: 10
    costs:
      monetary:
        interest_rate: 0.1
```

```
        storage_cap: 255 # EUR/kWh
        om_annual: 0.54 # EUR/kW/y

B2U:
  essentials:
    name: 'B2U'
    color: '#fa02cd'
    parent: storage
    carrier: electricity
  constraints:
    energy_cap_max: 33284.6 # kW
    storage_cap_max: 166423  # kWh
    energy_eff: 0.95  # 0.95 * 0.95 = 0.9025 round trip efficiency
    storage_loss: 0  # No loss over time assumed
    lifetime: 10
  costs:
    monetary:
      interest_rate: 0.10
      storage_cap: 116  # EUR per kWh storage capacity
      om_annual: 0.54 # EUR/kW/y

SEV:
  essentials:
    name: 'SEV'
    color: '#a1cf91'
    parent: storage
    carrier: hydrogen
  constraints:
    energy_cap_max: 40000  # kW
    storage_cap_max: 40000  # kWh
    energy_eff: 0.97  # 0.97 * 0.97 = 0.985 round trip efficiency
    storage_loss: 0  # No loss over time assumed
    lifetime: 30
  costs:
    monetary:
      interest_rate: 0.10
      storage_cap: 21  # EUR per kWh storage capacity
      om_annual: 0.4 # EUR/kW/y

TES:
  essentials:
    name: 'TES'
    color: '#fc0b03'
    parent: storage
    carrier: heat
  constraints:
    energy_cap_max: 105000 # kW
    storage_cap_max: 105000  # kWh
    energy_eff: 0.99 # 0.99 * 0.99 = 0.98 round trip efficiency
    lifetime: 40
```

```
      costs:
        monetary:
          interest_rate: 0.10
          storage_cap: 3  # EUR per kWh storage capacity
          om_annual: 0.0086 # EUR/kW/y

  RES:
    essentials:
      name: 'RES'
      color: '#020ff7'
      parent: storage
      carrier: cooling
    constraints:
      energy_cap_max: 105000 # kW
      storage_cap_max: 105000  # kWh
      energy_eff: 0.99 # 0.99 * 0.99 = 0.98 round trip efficiency
      lifetime: 40
    costs:
      monetary:
        interest_rate: 0.10
        storage_cap: 3  # EUR per kWh storage capacity
        om_annual: 0.0086 # EUR/kW/y
  # storage-end

##-DEMAND-##
  # demand-start
  demand_electricity:
    essentials:
      name: 'Edem'
      color: '#fc0b03'
      parent: demand
      carrier: electricity

  demand_electricity_ev:
    essentials:
      name: 'EVdem'
      color: '#ffb803'
      parent: demand
      carrier: electricity_ev

  demand_heat:
    essentials:
      name: 'Heat demand'
      color: '#910609'
      parent: demand
      carrier: heat

  demand_cooling:
    essentials:
      name: 'Cooling demand'
```

```
        color: '#171aa6'
        parent: demand
        carrier: cooling
    # demand-end

##-DISTRIBUTION-##
    # transmission-start
    power_lines:
      essentials:
        name: 'Distribucija električne energije'
        color: '#900cad'
        parent: transmission
        carrier: electricity
      constraints:
        energy_eff: 0.98
        lifetime: 40
      costs:
        monetary:
          interest_rate: 0.10
          energy_cap_per_distance: 0.01 # EUR/kW/km
          om_annual: 0.0212 # EUR/kW/km/y
    # transmission-end
```

ŽIVOTOPIS

Anamarija Falkoni (rođ. Šare), mag. ing. mech., rođena je u Dubrovniku 1987. godine. Završila je osnovnu školu i Opću gimnaziju u Dubrovniku. Diplomirala je na Fakultetu strojarstva i brodogradnje, Sveučilišta u Zagrebu, 2012. godine. 2013. godine zaposlila se na Pomorskom odjelu, Sveučilišta u Dubrovniku, u zvanju asistentice, gdje je i dalje zaposlena. Na Pomorskom odjelu izvodi nastavu na ukupno sedam redovnih kolegija preddiplomskog studija Brodostrojarstvo i Pomorske tehnologije jahta i marina.

2012. i 2013. godine sudjelovala je na HRZZ projektu ICT - podržana integracija električnih vozila u energetske sustave s visokim udjelom obnovljivih izvora energije (i-RESEV, *"ICT-aided integration of Electric Vehicles into the Energy Systems with a high share of Renewable Energy Sources"* (HRZZ - 09/128)).

Objavila je 4 znanstvena rada u časopisima indeksiranim CC/SCI bazi podataka, koji su citirani više od 60 puta. Sudjelovala je i izlagala na 6 međunarodno priznatih konferencija. Pregledava i radi recenzije radova za časopise Energy, International Journal of Electrical Power and Energy Systems i Naše more.

Popis objavljenih radova:

1. Falkoni, Anamarija; Soldo, Vladimir; Krajačić, Goran; Bupić, Matko; Bertović, Iva "Utilization of res using seawater source heat pump with and without energy storage; comparison of thermal and battery energy storage." // Thermal science, 24 (2020), 6A; 1-12doi:10.2298/TSCI (međunarodna recenzija, članak, znanstveni)
2. Falkoni, Anamarija; Pfeifer, Antun; Krajačić, Goran "Vehicle-to-Grid in Standard and Fast Electric Vehicle Charging: Comparison of Renewable Energy Source Utilization and Charging Costs." // Energies, 13 (2020), 6; 1510, 22 doi:10.3390/en13061510 (međunarodna recenzija, članak, znanstveni)
3. Falkoni, Anamarija; Koboević, Nikša; Koboević, Žarko; Krajačić, Goran "OPPORTUNITIES FOR ALL-ELECTRIC SHIPS IN SMART ENERGY SYSTEMS." // Conference Proceedings of 1st International Conference of Maritime Science & Technology, Naše more / Koboević, Žarko (ur.). Dubrovnik: University of Dubrovnik, Maritime Department, 2019. str. 114-127 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
4. Falkoni, Anamarija; Soldo, Vladimir; Krajačić, Goran; Bupić, Matko "Renewable energy integration using seawater source heat pump in the Old city of Dubrovnik." // Digital proceedings of 14th Conference on Sustainable Development of Energy, Water and

Environment Systems (SDEWES) BOOK OF ABSTRACTS Dubrovnik, Hrvatska, 2019. 0214, 14 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

5. Falkoni, Anamarija; Krajačić, Goran "Standard vs. fast charging of electric vehicles in self-sufficient wider urban areas." // Digital proceeding of 3rd South east European conference on sustainable development of energy, water and environment systems Novi Sad, Srbija, 2018. 0024, 17 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
6. Falkoni, Anamarija; Krajačić, Goran "Linear correlation and regression between the meteorological data and the electricity demand." // Thermal science, 20 (2016), 4; 1073-1889 doi:10.2298/tsci151209157f (podatak o recenziji nije dostupan, članak, znanstveni)
7. Falkoni, Anamarija; Krajačić, Goran "The Analysis of the Correlation between Wind Speed, Solar Radiation, Air Temperature and Electricity Demand of the Dubrovnik Region." // Digital Proceedings of the 10th Conference on Sustainable Development of Energy, Water and Environment Systems – SDEWES / Ban, Marko .... [et al.] (ur.). - (ur.). Zagreb: Fakultet strojarstva i brodogradnje, Zagreb, 2015. 0602-1, 14 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
8. Šare, Anamarija; Krajačić, Goran; Pukšec, Tomislav; Duić, Neven "The integration of renewable energy sources and electric vehicles into the power system of the Dubrovnik region." // Energy, sustainability and society, 5 (2015), 1; 1-16 doi:10.1186/s13705-015-0055-7 (međunarodna recenzija, kratko priopćenje, znanstveni)
9. Goran Gašparović, Goran Krajačić, Anamarija Šare, Neven Duić "Advanced modelling of an electric vehicle module in the H2RES energy planning software." // Digital Proceedings of The 8th Conference on Sustainable Development of Energy, Water and Environment Systems in SDEWES Conference / Ban, Marko .... [et al.] (ur.). - (ur.). Zagreb, 2013. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
10. Šare, Anamarija; Krajačić, Goran; Pukšec, Tomislav; Duić, Neven "The Impact of Electrification in the Transport Sector on the Power Curve, and the Integration of Renewable Energy Sources in to the Power Systems of the Dubrovnik Region." // Digital Proceedings of 8th Conference on Sustainable Development of Energy, Water and Environment Systems – SDEWES Conference / Ban, Marko .... [et al.] (ur.). - (ur.).- Zagreb : University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture , 2013. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)