Višeagentski sustav za kontekstno usmjeravanje flote električnih vozila

Jelen, Goran

Doctoral thesis / Disertacija

2022

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:168:269571

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-16**

Repository / Repozitorij:

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

Sveučilište u Zagrebu

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Goran Jelen

VIŠEAGENTSKI SUSTAV ZA KONTEKSTNO USMJERAVANJE FLOTE ELEKTRIČNIH VOZILA

DOKTORSKI RAD

Zagreb, 2022.

Sveučilište u Zagrebu

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Goran Jelen

VIŠEAGENTSKI SUSTAV ZA KONTEKSTNO USMJERAVANJE FLOTE ELEKTRIČNIH VOZILA

DOKTORSKI RAD

Mentor: Prof. dr. sc. Vedran Podobnik

Zagreb, 2022.

University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Goran Jelen

MULTI-AGENT SYSTEM FOR CONTEXT-AWARE ROUTING OF ELECTRIC VEHICLE FLEET

DOCTORAL THESIS

Supervisor: Professor Vedran Podobnik, PhD

Zagreb, 2022

Doktorski rad izrađen je na Sveučilištu u Zagrebu Fakultetu elektrotehnike i računarstva, na Zavodu za telekomunikacije

Mentor: prof. dr. sc. Vedran Podobnik

Doktorski rad ima: 157 stranica

Doktorski rad br.: _____

O mentoru

Vedran Podobnik rođen je u Zagrebu 1982. godine. Diplomirao je u polju elektrotehnike te doktorirao u polju računarstva na Sveučilištu u Zagrebu Fakultetu elektrotehnike i računarstva (FER), 2006. odnosno 2010. godine. Također je magistrirao u području upravljanja tehnologijom 2013. godine na Sveučilištu u Cambridgeu, Judge Business School (Ujedinjeno Kraljevstvo).

Od 2006. godine radi na Zavodu za telekomunikacije FER-a (od 2020. kao redoviti profesor). Utemeljitelj je i voditelj "Laboratorija za društveno umrežavanje i društveno računarstvo (socialLAB)" te jedan od utemeljitelja "FER-ovog studentskog startup inkubatora SPOCK". Bio je voditelj većeg broja domaćih i međunarodnih znanstvenih projekata te projekata suradnje s gospodarstvom. Trenutno je voditelj radnog paketa u jedinom nacionalnom znanstvenom centru izvrsnosti (ZCI) u području tehničkih znanosti "ZCI za znanost o podatcima i kooperativne sustave" te član Upravljačkog vijeća FER-ovog "Centra za umjetnu inteligenciju". Provodi nastavne i istraživačke aktivnosti u transdisciplinarnim područjima znanosti o mrežama i podacima, društvenog računarstva i upravljanja tehnologijom. Objavio je više od 120 znanstvenih i stručnih radova, uključujući radove u časopisima Information Sciences, Information Technology & People, International Journal of Energy Research i AI Magazine. Od 2018. godine savjetuje globalnu tehnološku kompaniju Hewlett Packard Enterprise (HPE) u području podatkovnih platformi, analitike te umjetne inteligencije. Izabran je u znanstvena zvanja u dva polja tehničkih znanosti – elektrotehnici i računarstvu.

Prof. Podobnik član je stručnih udruga IEEE, ACM, INFORMS, AIS i KES International te društva Cambridge Union Society. Sudjelovao je u programskim i organizacijskim odborima mnogih znanstvenih konferencija i ljetnih škola, te sudjeluje kao recenzent u većem broju inozemnih časopisa. Koordinirao je međunarodni tim koji je dobio priznanje "Success Story" za iznimno uspješno provedeni projekt u programu ERASMUS+ Strateška partnerstva, što je prva takva nagrada u sektoru visokog obrazovanja u Republici Hrvatskoj (2018., dodijelila Europska komisija). Bio je voditelj interdisciplinarnog tima koji je nagrađen najvišom hrvatskom državnom nagradom u području edukacije (2015., dodijelio Hrvatski sabor) te godišnjom nacionalnom nagradom PMI Projekt godine (2016., dodijelila vodeća svjetska profesionalna udruga projektnih menadžera PMI). Kao mladi istraživač primio je godišnju nacionalnu nagradu za znanost u području tehničkih znanosti (2011., dodijelio Hrvatski sabor), kao i srebrnu plaketu "Josip Lončar" za posebno istaknutu doktorsku disertaciju (2010., dodijelio FER).

About the Supervisor

Vedran Podobnik was born in Zagreb in 1982. He received M.Eng. (2006, Electrical Engineering) and Ph.D. (2010, Computer Science) degrees from the University of Zagreb, Faculty of Electrical Engineering and Computing (FER), Zagreb, Croatia, as well as M.Phil. (2013, Technology Policy) degree from the University of Cambridge, Judge Business School, Cambridge, UK.

From 2006, he works at the Department of Telecommunications at FER (from 2020 as the Full Professor). He is the founder and Director of the "Social Networking and Computing Laboratory (socialLAB)" and co-founder of the "FER's student startup incubator SPOCK". He led several national and international scientific and industrial projects. Currently, he is a work package leader in the only national centre of research excellence (CoRE) in the field of technical sciences, the "CoRE for Data Science and Cooperative Systems", and the management board member at FER's "Center for Artificial Intelligence". His teaching and research activities are in transdisciplinary fields of network and data science, social computing, and technology policy. He co-authored over 120 scientific and professional papers, including publications in Information Sciences, Information Technology & People, International Journal of Energy Research and AI Magazine journals. From 2018, he advises the global technology company Hewlett Packard Enterprise (HPE) in the fields of data platforms, data analytics and artificial intelligence. He received scientific titles in two fields of engineering - electrical engineering and computer science.

Prof. Podobnik is a member of IEEE, ACM, INFORMS, AIS and KES International associations, as well as the Cambridge Union Society. He has participated in the program and organizing committees of many scientific conferences and summer schools, and has served as a peer reviewer in various international journals. He coordinated an international team that received the "Success Story Award" for a particularly successful ERASMUS+ Strategic Partnerships project, the first such award in the higher education sector in Croatia (2018, awarded by the European Commission). He was a leader of an interdisciplinary team that was awarded the highest national award for notable achievements in the education activity (2015, awarded by the Croatian Parliament) as well as the annual national PMI Project of the Year Award (2016, awarded by the world's leading project management professionals association PMI). As a junior researcher, he received the Croatian Annual National Award for Science in the field of technical sciences (2011, awarded by the Croatian Parliament), as well as the Silver Medal "Josip Loncar" award for outstanding doctoral dissertation and particularly successful scientific research (2010, awarded by FER).

Ovaj rad je posvećen supruzi Ivani i sinu Franu, te mojoj obitelji! Hvala vam na ljubavi, brizi i podršci!

Sažetak

Doktorski rad bavi se izazovima usmjeravanja flote električnih vozila uzimajući u obzir preference vlasnika, kontekst prostora te karakteristike i položaj električnih punionica i spremišta vozila. Usmjeravanje vozila izazovan je problem u području mobilnosti i transporta te se mora sagledati iz perspektive okolišne održivosti, telekomunikacija, prometnih znanosti i znanosti o podacima. Privlači veliku pozornost državnih agencija, industrije i istraživačke zajednice zbog svoje velike važnosti za svakodnevni život ljudi i održivog razvoja gradova. Višeagentski pristup u rješavanju problema usmjeravanja vozila dobar je način za obuhvaćanje složenih ograničenja i širokog spektra informacija sadržanih unutar profila agenata, pružajući time mogućnost provođenja simulacija višeagentskog sustava za usmjeravanje električnih vozila radi dobivanja najboljeg modela za usmjeravanje flote električnih vozila, bez prethodne implementacije modela u stvarni svijet. Ključna komponenata doktorskoga rada jest izgradnja višeagentskog sustava koji uključuje kontekstno obogaćene podatke za izgradnju predikcijskih modela korištenih unutar algoritama za usmjeravanje flote električnih vozila. Koliko je autoru poznato, ne postoji javno dostupan višeagentski sustav za kontekstno usmjeravanje flote električnih vozila.

U doktorskom radu predstavljen je model višeagentskog sustava za usmjeravanje električnih vozila koji uključuje postupke kontekstnog usmjeravanja flote električnih vozila uzimajući u obzir prostorne i vremenske uvjete kretanja vozila i obavljanja poslova, i s njima povezane funkcionalnosti električnih punionica i spremišta vozila. Postupci kontekstnog usmjeravanja flote električnih vozila uključuju korištenje modela umjetne iskoristivosti za predviđanje mjere iskoristivosti električnih punionica i resursa odredišta na kojima električna vozila obavljaju poslove. Ostvareni model višeagentskog sustava za usmjeravanje električnih vozila korišten je za ostvarivanje platforme za simulaciju transportnog sustava flote električnih vozila koja omogućuje evaluaciju postupaka usmjeravanja pri promjeni kontekstnih uvjeta te usporednu analizu postupaka usmjeravanja u definiranim kontekstnim uvjetima. Višeagentski sustav evaluiran je za grad Split, uzimajući u obzir komunalne električne čistilice te podatke o korištenju gradskog parkinga i električnih punionica. Prikupljeni su podaci o korištenju 60 parkirališta u gradu Splitu s početkom od 2017. godine pa sve do polovice 2021. godine. Podaci o korištenju električnih punionica prikupljeni su za 138 električnih punionica operatora Hrvatski Telekom u Hrvatskoj počevši od 2020. godine pa sve do 2022. godine. U sklopu doktorskog rada postignut je model višeagentskog sustava za kontekstno usmjeravanje flote električnih vozila s ciljem maksimizacije preferenci korisnika koji se može koristiti za poboljšanje održivosti u transportnim sustavima i u korištenju gradskih procesa i resursa.

Ključne riječi: problem usmjeravanja električnih vozila, višeagentski sustav, kontekstualno obogaćeni podaci, znanost o podacima

Extended abstract

Multi-agent system for contex-aware routing of electric vehicle fleet

This dissertation addresses the challenges of electric vehicle fleet routing considering owner preferences, spatial context, and the characteristics and location of electric charging stations and depots. The vehicle routing problem is a challenging problem in the field of mobility and transportation that needs to be considered from the perspectives of environmental sustainability, telecommunications, transportation science, and data science. Due to its great importance to people's daily lives and sustainable urban development, it attracts the attention of government agencies, industry, and society. A multi-agent approach to the vehicle routing problem is a good way to capture the complex constraints and wide range of information contained in agent profiles. This makes it possible to simulate a multi-agent system for routing an electric vehicle fleet to obtain the best model for routing an electric vehicle fleet without first implementing it in the real world. A key component of the dissertation is to build a multi-agent system for context-aware routing of electric vehicle fleets that incorporates context-enriched data to build predictive models that are used in algorithms for routing electric vehicle fleets. To the author's knowledge, there is no publicly available multi-agent system for context-aware routing of electric vehicle fleets.

The thesis presents a model of a multi-agent system for electric vehicle routing that includes procedures for context-aware routing of the electric vehicle fleet, taking into account the spatial and weather conditions under which the vehicle moves, as well as the associated functionalities of charging stations and depots. The procedures for context-aware routing of the electric vehicle fleet include the use of AI utilization models to predict charging station utilization and destination demand for electric vehicle routing. The realized model of the multi-agent system for electric vehicle routing is used for the realization of a platform for transportation system simulations of electric vehicle fleet, which will allow the evaluation of routing procedures under changing context conditions and the comparative analysis of routing procedures under defined context conditions. The multi-agent system is evaluated for the city of Split, taking into account communal electric cleaners and usage data of parking lots and charging stations in the city of

Split. Parking lot usage data is collected for 60 parking lots in the city of Split from early 2017 to mid-2021. Charging station usage data is collected for 138 charging stations in Croatia for the operator Hrvatski Telekom from the beginning of 2020 to 2022. The model of a multi-agent system for context-aware routing of the electric vehicle fleet defined in the dissertation aims to maximize user preferences and improve the sustainability of transport systems and the use of urban processes and resources.

Introduction chapter (1. Uvod) begins work by providing a concise description of the research area and research objectives. This chapter defines the problem in the form of the following research questions:

- •How to define a model of multi-agent system for electric vehicles routing?
- •How to define procedures for electric vehciles routing?
- •How to realize artificial intelligence models required in routing procedures?
- •How to realize a multi-agent platform for simulating the transport system of the electric vehcile fleet?
- •How to define a comparative analysis of routing procedures in a multi-agent platform for simulating the transport system of the electric vehicle fleet?

The first question is related to the definition of the model of multi-agent system for electric vehicles routing. The model of multi-agent system for electric vehicle routing must define the main actors of the electric vehicle routing problem: i) electric vehicle; ii) charging station iii) depot. In the model, the electric vehicle represents a moving entity that is controlled by the entity depot through its work. The entity depot defines the routing procedures for electric vehicles to the charging stations and to the destination. In addition, the electric vehicles need to be charged during the journey, so the corresponding process must also be considered in the definition of the model. The second research question defines the procedures required from the depot to route electric vehicles. The electric vehicle routing problem defines several approaches for defining routing procedures, such as time windows, capacity-based routing, and routing with different charging strategies. In addition, artificial intelligence (AI) models can also be used to improve the routing in case of using time windows. The third research question addresses the problems related to data acquisition required for defining AI models, i.e., data source definition, data understanding, data cleaning, and data preparation for building AI models. In addition, contextual data may also be used, so it is important to define the process of data enrichment with contextual data. The fourth research question defines the challenges in realizing multi-agent platforms, where a suitable runtime and development environment must be considered. There are a variety of multi-agent environments, so it is critical to choose one that meets our requirements for realizing a multi-agent model for electric vehicle route planning. The fifth research question covers the multi-agent system for context-aware routing of electric vehicles by establishing the need for a comparative analysis of routing methods and other multi-agent

models for electric vehicle routing through measurable indicators of success.

Chapter two ("2. Pregled povezanih istraživanja") provides an overview of the state of the art regarding the electric vehicle routing problem, which is the focus of this research. The first part of the chapter provides an overview of selected chapters on the electric vehicle routing problem. The electric vehicle routing problem brings solutions for better electric vehicle routing. In defining solutions for the routing problem, the constraints of electric vehicles must be considered, such as the range of the vehicle and the battery capacity. It is also shown that there are different types of electric vehicles: battery electric vehicles, hybrid electric vehicles, and fuel cell electric vehicles. What they all have in common is the battery, which must be charged at a charging station. However, the difference lies in the architecture and tank-to-wheel efficiency. This study considers battery electric vehicles, which will be referred to only as electric vehicles (EVs) in the rest of the text. In addition to the constraints imposed by the electric vehicle, there are other factors that can determine the solution of the routing problem for electric vehicles, such as time window and capacity. The time window is usually tied to the time interval in which the customer wants to be served, and the capacity defines the specific capacity of the vehicle (battery capacity) or is defined by the size of the electric vehicle fleet. It is also shown that the use of electric vehicles in cities is increasing, especially in the provision of services and transportation of people and goods. Finally, it is shown that the solution to the electric vehicle routing problem can be achieved using a centralized or distributed approach, which has strong similarities to routing approaches in telecommunications science. The distributed approach to electric vehicle routing emphasizes the use of multi-agent based solutions. The second part of the chapter reviews the relevant literature focusing on electric vehicle routing solutions, fleet sizing and definition solutions, context-aware routing, and agent-based routing solutions. It is noted that there is no publicly available multi-agent system for context-aware routing of electric vehicles that defines a model of a multi-agent system, context-aware routing methods, and a multi-agent platform for simulations of transportation systems for electric vehicle fleets. The chapter concludes with a reflection on the given review of related literature and proposes a solution to the discovered shortcomings in electric vehicle routing.

Chapter three ("3. Model višeagentskog sustava za usmjeravanje električnih vozila") defines the model of a multi-agent system for electric vehicle routing. The model of *multi-agent system for electric vehicle routing* consists of three basic agents: i) agent *electric vehicle*; ii) agent *charging station*; iii) agent *depot*. Each agent represented by the multi-agent model is defined using a multi-method approach that uses agent-based modeling and discrete-event modeling. The agent system is defined using static and dynamic variables used in the agents' processes, which are defined for processing discrete events that may occur in the system. The behavior of the agents is modeled with state diagrams provided by the agent-based modeling. The agent electric vehicle is the main agent in the model, which is directed in the system to the charging

stations and to its destinations. The model provides the ability to define a more specific agent for the electric vehicle that takes into account domain usage. This model provides genericity in the application of electric vehicles. This work specifies the agent *comunal cleanner*, which is specifically intended for cleaning urban areas. With the agent *charging station*, the model allows charging the battery of electric vehicles during routing actions created by the agent *depot*, which uses routing algorithms for decision making. In addition, the electric vehicle destinations must also be represented as agents specifically intended to use the model. The agent *parking lot* is defined as the target agent for the agent *communal cleaner*, on which it performs cleaning actions. The model is created using the AnyLogic tool, which offers three types of modeling approaches: agent-based, discrete-event, and system-dynamic.

Chapter four ("4. Algoritmi za usmjeravanje električnih vozila") presents routing algorithms used in multi-agent systems for context-aware routing of electric vehicle fleets. *The algorithms for electric vehicle routing* implemented in the thesis are based on the problem of electric vehicle routing with time window and capacity, where the time window defines the time interval in which the cleaning tasks must be performed, while the capacity defines the number of electric cleaners in the fleet. Electric vehicle routing algorithms are divided by direction: i) to the parking lot; ii) to the charging station; and by type: i) basic algorithm; ii) AI-empowered algorithm. Four algorithms are defined in the paper:

- •Algorithm 1 - Basic algorithm for routing electric cleaners to parking lots;
- •Algorithm 2 - AI-empowered algorithm for routing electric cleaners to parking lots;
- •Algorithm 3 - Basic algorithm for routing electric cleaners to charging station;
- •Algorithm 4 - AI-empowered algorithm for routing electric cleaners to the charging station.

Algorithm 1 and Algorithm 2 define two phases: i) planning phase ii) execution phase, where in the planning phase time windows are defined for the cleaning tasks and in the execution phase the cleaning tasks are executed by the electric cleaners. Algorithm 1 defines all time windows for each cleaning task equally and in the execution phase uses the shortest path principle for assigning the cleaning task to the electric cleaner. Algorithm 2 uses AI utilization models for on-street and off-street parking to define the time windows. The AI utilization models also consider contextual data, using weather forecasts and point-of-interest data as contextual data. The best on-street parking utilization model uses contextually enriched data with point-of-interest context and achieves an R^2 of 92.84% using the CatBoost machine learning method, which is an improvement of 4.68% over the utilization model without contextual data enrichment. The best off-street parking utilization model with CatBoost achieves a R^2 of 97.04% and improves the parking utilization prediction by 1.06% by using contextual point-of-interest from utilization models without contextual data enrichment. It can be concluded that context plays an important role in predicting parking utilization. The data needed to build utilization models were collected

from January 2017 to July 2021 for on-street and off-street parking lots in the city of Split. In the case of routing electric cleaners to the charging station, Algorithm 3 directs electric cleaners to the nearest charging station based on the shortest path principle, and Algorithm 4 uses a charging station utilization model for the routing decision. Based on the charging station utilization model, Algorithm 4 routes electric cleaner to the charging station with the lowest utilization value. Contextual data is also used to create charging station utilization models, and the best charging station utilization model achieves an R^2 result of 91.78% by using CatBoost as a machine learning method and point-of-interest as contextual data. This means that the contextual data has an impact on the usage of charging stations. The data required to build charging station utilization models were collected for 138 charging stations of the operator Hrvatski Telekom in Croatia from December 2019 to January 2022. Contextual data used in all of the defined utilization models is in case of weather forecasts collected from January 2011 to early 2022, and in case of point-of-interest data is collected once from Open Street Map data for Croatia.

Chapter five ("5. Višeagentska platforma za simulaciju transportnog sustava flote električnih vozila") describes the achieved multi-agent platform for the simulation of the electric vehicle fleet transportation system. *Multi-agent platform for simulation of electric vehicle fleet transportation system* is realized using AnyLogic toll, the same tool used for definition of multi-agent system models. The achieved multi-agent platform enables multi-agent system evaluation for electric vehicle routing models using different contextual environments and provides comparative analysis of routing algorithms under defined contextual conditions. Such a platform provides a more financially feasible way to test different multi-agent solutions. In this work, a functional and techno-economic analysis of the implemented multi-agent platform is performed. The functional analysis shows the successful implementation of a multi-agent system for context-aware routing of electric vehicles and the implementation of electric vehicle fleet sizing. The simulation of electric vehicle fleet size determination enables the determination of three types of fleet sizes: i) maximum fleet size; ii) realistic fleet size; iii) optimal fleet size. In the techno-economic analysis, two indicators of success for electric vehicle routing were defined: i) cleaning success; ii) charging success. The cleaning success measure represents the efficiency of the electric cleaners in performing the cleaning tasks and is defined as the number of parking spaces cleaned relative to the total number of parking spaces within a cleaning cycle. The charging success measure represents the efficiency in the use of the charging station by the electric cleaners and is defined as the effective charging rate, which is equal to the amount of energy consumed in kWh divided by the total time spent at the charging station (waiting time and charging time). Simulations on the platform have shown that algorithms empowered with AI models improve cleaning success by 5.6% and charging success by N%.

Chapter six ("6. Zaključak i nastavak istraživačkog rada") concludes the thesis with a discussion of the scientific and economic contribution of the defined multi-agent system for context-

aware routing of electric vehicle fleets. Ideas for future research are also presented. This dissertation has four appendices: (i) the first appendix ("Prikaz podataka iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta") contains a 24-hour display for the utilization of charging stations, on-street parking and off-street parking; (ii) the second appendix ("Prikaz važnosti ulaznih varijabli modela iskoristivosti") shows all the feature imporatnces of all the utilization models performed in the dissertation; iii) the third appendix ("Sistemske specifikacije potrebne za alat AnyLogic") defines the system configurations for the use of AnyLogic; and iv) the fourth appendix ("Specifikacija električne čistilice RASCO LYNX Charge tvrtke RASCO") describes the technical specification of the RASCO LYNX Charge electric cleaner used in the simulations of the electric cleaner fleet routing.

Finally, the expected scientific contribution of this dissertation consists of three parts. The first part is the definition of a model for a multi-agent system for electric vehicle routing, consisting of agents representing moving entities - electric vehicles - and stationary entities - charging stations and depot, including the properties of the entities and their relationships with each other. This model is defined in chapter three of this thesis along with all the mentioned moving and stationary entities, including their properties and relationships with each other. The second part is the definition of a context-aware routing method for the electric vehicle fleet that takes into account the spatial and weather conditions of vehicle movement and performance, as well as the functionalities of the charging stations and the depot. Context-aware routing methods in the form of electric vehicle fleet routing algorithms are defined in chapter four, which defines basic and AI-empowered routing algorithms that consider different contexts within utilization models to produce utilization forecasts that serve as inputs to routing algorithm decision making. The third part of the scientific contribution is the realization of a multi-agent platform for the simulation of the electric vehicle fleet transportation system through the multi-agent system model defined in the first scientific contribution, which enables the evaluation of the routing methods defined in the second scientific contribution under changing context conditions and provides a comparative analysis of the routing methods under defined context conditions. The realized multi-agent platform for the simulation of the electric vehicle fleet transportation system is presented in chapter five along with the functional and techno-economic analysis performed with the realized multi-agent platform.

Keywords: electric vehicle routing problem, multi-agent system, contextually enriched data, data science

Sadržaj

1. Uvod 1

1.1. Definicija problema 2

1.2. Struktura rada 6

2. Pregled povezanih istraživanja 7

2.1. Odabrana poglavlja iz područja problema usmjeravanja električnih vozila . . .7

2.1.1. Električna vozila 8

2.1.2. Problem usmjeravanja električnih vozila 10

2.1.3. Područja primjene problema usmjeravanja električnih vozila 11

2.1.4. Pristup rješavanju problema usmjeravanja električnih vozila 13

2.2. Problem usmjeravanja električnih vozila u literaturi 14

2.2.1. Rješenja problema usmjeravanja električnih vozila 14

2.2.2. Problem usmjeravanja električnih vozila pomoću kontekstnih informacija16

2.2.3. Veličina i sastav flote električnih vozila 17

2.2.4. Višeagentski sustav za usmjeravanje električnih vozila 18

2.3. Osvrt i prijedlog rješenja 20

3. Model višeagentskog sustava za usmjeravanje električnih vozila 22

3.1. Pregled višeagentskog sustava 22

3.2. Pokretni agenti 23

3.2.1. Agent Električno vozilo 24

3.2.2. Agent Električna čistilica 29

3.3. Stacionarni agenti 33

3.3.1. Agent Električna punionica 33

3.3.2. Agent Spremište vozila 37

3.3.3. Agent Parkiralište 42

3.4. Komunikacija između agenata 45

4. Algoritmi za usmjeravanje električnih vozila 47

4.1. Pregled algoritama 48

4.2. Osnovni algoritmi 51
4.2.1. Usmjeravanje prema parkiralištu 51
4.2.2. Usmjeravanje prema električnoj punionici 53
4.3. Algoritmi zasnovani na umjetnoj inteligenciji 54
4.3.1. Usmjeravanje prema parkiralištu 55
4.3.2. Usmjeravanje prema električnoj punionici 58
4.4. Modeli iskoristivosti 59
4.4.1. Metodologija 60
4.4.2. Razumijevanje domene 61
4.4.3. Definiranje analitičkog pristupa 63
4.4.4. Definiranje, prikupljanje i razumijevanje podataka 64
4.4.5. Priprema podataka 72
4.4.6. Stvaranje, procjena i korištenje modela iskoristivosti 81
4.4.7. Rezultati modela iskoristivosti 85

5. Višeagentska platforma za simulaciju transportnog sustava flote električnih vozila 94
5.1. Izvedba platforme za simulaciju 95
5.1.1. Implementacija agenata 96
5.1.2. Implementacija procesa 100
5.1.3. Implementacija prezentacijskog sloja 106
5.1.4. Baza podataka 107
5.1.5. Postavke simulacije 109
5.2. Funkcijska analiza ostvarene platforme 111
5.2.1. Optimizacija veličine flote električnih vozila 111
5.2.2. Simulacija osnovnog usmjeravanja električnih vozila 114
5.2.3. Simulacija kontekstnog usmjeravanja električnih vozila 119
5.3. Tehno-ekonomska analiza ostvarene platforme 121
5.3.1. Povećanje održivosti u gradskim komunalnim procesima 123
5.3.2. Povećanje održivosti u korištenju gradskih električnih punionica 124
5.3.3. Korištenje modela iskoristivosti u aplikaciji Bmove 126
5.4. Odgovori na istraživačka pitanja 128

6. Zaključak i budući rad 129

Prilog 132

Literatura 141

Popis oznaka 153

Životopis 155

Biography 157

Poglavlje 1

Uvod

Izazovi u transportu i mobilnosti dobivaju sve veću pažnju državnih agencija, poslovnih organizacija, same industrije i istraživačke zajednice radi ostvarivanja sustava za planiranje i upravljanje te transportnih sustava koji su resursno učinkovitiji, povezaniji te klimatski i okolišno osviješteniji [1]. Primjena automatizacije i modernih informacijskih i komunikacijskih tehnologija u logistici motivirana je činjenicom da postojeća rješenja u domeni transporta i mobilnosti nisu dugoročno održiva, pri čemu povećanje gradskog stanovništva dovodi do novih problema i izazova u prometu i transportu, a samim time i do poteškoća za održivo upravljanje gradskim procesima i imovinom [2]. U današnje vrijeme, gradsko stanovništvo već se suočava s različitim problemima povezanim s dostupnošću parkinga, električnih punionica, stanjem u prometu i stanjem okoliša. S druge strane grad je u potrazi za rješenjima za bolje upravljanje i planiranje gradskih resursa koji se koriste u gradskim procesima, kao što su čistilice za čišćenje gradskih površina.

Trenutačno 54% svjetskog stanovništva živi u urbanim područjima, pri čemu se očekuje do kraja 2050. godine daljnji porast do 66% [3]. Ovakav će porast prouzročiti daljnje povećanje gradskog prometa što će za posljedicu imati povećanje zagađenja zraka ispušnim plinovima, povećanje vremena potrebnog za traženje slobodnog parkirališnog mjesta i u slučaju korisnika električnih vozila povećanje vremena potrebnog za traženje slobodne punionice [4]. Primjerice, vrijeme potrošeno za traženje slobodnog parkirališnog mjesta vozeći se po gradu, doprinosi više od 40% ukupnom gradskom prometu [5]. Gradovi trebaju prilagoditi svoje procese povećanju gradskog stanovništva održivim planiranjem i upravljanjem uzimajući u obzir dostupne terenske podatke te proširivanje terenskih izvora podatka integracijom tehnologija interneta stvari, poput prizemnih parking-senzora, pametnih parking-rampi, umreženih električnih punionica i umreženih električnih vozila. Gradovi mogu shvatiti ove izazove kao mogućnost za unapređenje održivosti svojih gradskih procesa, pružajući pritom pogodnosti svojim stanovnicima u vidu poboljšanja kvalitete života.

Terenski podaci mogu se prikupiti i analizirati radi dobivanja boljeg uvida u korištenje sa-

mog sustava. Prikupljeni podaci mogu se obogatiti s kontekstnim podacima kao što su vremenska prognoza ili mjesta od značaja, dobivajući time još širi skup podataka. Takav skup kontekstno obogaćenih podataka može dati bolje rezultate prilikom izgradnje prediktivnih modela za usmjeravanje električnih vozila, dobivajući time modele za kontekstno usmjeravanje električnih vozila [6]. Takav se model može upotrijebiti za usmjeravanje flote električnih vozila u javnom prijevozu ili za čišćenje gradskih površina (ulica, parkirališta, trgova, itd.), ostvarujući pritom bolju učinkovitost u upravljanju gradskih resursa. Također se može upotrebljavati i za usmjeravanje pojedinih električnih vozila prema električnoj punionici ili parkiralištu radi što bržeg pronalaska slobodne punionice ili parkirališnog mjesta, ostvarujući pritom manji utrošak energije na traženje te što brži početak punjenja baterije vozila. Za dobivanje što boljeg modela usmjeravanja električnih vozila potrebno je ostvariti višeagentski sustav unutar kojeg se mogu provoditi simulacije modela za kontekstno usmjeravanja električnih vozila nad stvarnim terenskim podacima radi analize performanse modela, optimizacije modela, detekcije izranjajućih svojstava koja trebaju biti uključena u fazi stvaranja modela te optimizacije gradskih resursa za postizanje veće održivosti rješenja za upravljanje i korištenje gradske imovine.

1.1Definicija problema

Gradovi digitalizacijom svojih procesa, pomoću informacijskih i komunikacijskih tehnologija i integracijom različitih uređaja interneta stvari, mogu uspostaviti bolju umreženost svih svojih dijelova [7]. Takvom transformacijom gradovi uspostavljaju vizualno mjerljivo i raspodijeljeno upravljanje gradskim procesima i korištenjem gradske imovine. Izazov zagađenja zraka te povećanja održivosti, gradovi počinju rješavati tako da postojeće flote vozila za obavljanje gradskih radnji čišćenja gradskih površina, odvoza smeća i gradskog javnog prijevoza zamjenjuju s hibridnim i električnim vozilima. Prema izvještaju Europske Unije, emisije CO_2 iz 28 država članica sačinjavaju 22,40% ukupne svjetske emisije CO_2 [8]. Stoga se Europska unija obvezala da će smanjiti emisiju štetnih plinova za barem 60% do 2050. godine tako što će promovirati zamjenu konvencionalnih vozila u urbanim područjima sa nekonvencionalnim vozilima, poput hibridnih i električnih vozila [9].

Hibridna i električna vozila sa sobom donose nove izazove u smjeru osiguravanja dostupnosti novih izvora energije za hibridna i električna vozila te planiranja obavljanja gradskih radnji na što bolji način uzimajući u obzir radne kapacitete koja ta vozila imaju [10]. Na primjer, električna vozila imaju bateriju određenog kapaciteta koja može pružiti određeni broj radnih sati ili doseg vožnje, koji kad se ostvari vozilo, mora obaviti punjenje baterije na električnoj punionici. Punjenje baterije vremenski je zahtjevan proces koji može trajati nekoliko sati te predstavljati izazov prilikom obavljanja gradskih radnji. Primjer može biti čišćenje gradskih površina koje mora odraditi određeni broj električnih čistilica unutar definiranog radnog vremena gradskih

komunalnih radnji. Iz perspektive korisnika električnog vozila, traženje slobodnog parkinga ili električne punionice rezultira nepotrebnim trošenjem baterije te povećava zabrinutost kod korisnika da će se baterija isprazniti prije nego stignu do samog odredišta [11]. Potrebno je, iz gledišta grada koji upotrebljava flote električnih vozila i samog korisnika električnog vozila, pružiti pouzdane informacije na temelju kojih će se moći usmjeriti u prostoru radi maksimizacije njihovih preferenci.

Problem usmjeravanja električnih vozila može se gledati kao varijacija problema usmjeravanja ekološki prihvatljivih vozila gdje se u obzir uzimaju vozila s alternativnim izvorom energije (poput električnih vozila) koja imaju određeni maksimalni doseg i moraju obavljati punjenje prilikom svog rada na posebnim punionicama koje pružaju izvor energije za takva vozila [12]. Kod rješavanja problema usmjeravanja električnih vozila treba uzeti u obzir nekoliko entiteta potrebnih za uspješno usmjeravanje kao što su: električno vozilo i električna punionica. U slučaju flote električnih vozila, potrebno je uzeti u obzir i dodatan entitet, a to je spremište vozila. Gradovi raspolažu flotama vozila, poput primjerice flota električnih čistilica za čišćenje gradskih površina ili flota električnih buseva za gradski prijevoz, pa time kod rješavanja problema usmjeravanja električnih vozila u domeni gradova treba uzeti u obzir sva tri prethodno spomenuta entiteta.

Korištenje rješenja problema usmjeravanja električnih vozila može se ostvariti pomoću višeagentskog sustava za usmjeravanje električnih vozila koji uključuje postupke usmjeravanja i koji se može ostvariti u obliku višeagentske platforme [13]. Višeagentskom platformom mogu se provoditi simulacije različitih modela višeagentskih sustava za usmjeravanje električnih vozila radi dobivanja najboljeg modela koji se može upotrebljavati u gradskim procesima, kao što je čišćenje gradskih parkirališnih površina flotom komunalnih električnih čistilica, ili unutar aplikacija za pametne uređaje za pružanje informacija o dostupnosti električnih punionica i parkirališnih mjesta u gradu. Za postizanje što boljih postupaka usmjeravanja električnih vozila treba uključiti u proces definiranja i kontekstualne podatke, kao što su vremenska prognoza ili mjesta od značaja zajedno s terenskim podacima, poput podataka o korištenju električnih punionica te uličnog i vanuličnog parkirališta [14]. Ovime dobivamo postupke za kontekstno usmjeravanje električnih vozila koji se mogu vrednovati pomoću višeagentskog sustava za usmjeravanje električnih vozila bez prethodne integracije u stvarni svijet. Ovaj rad specifično se bavi usmjeravanjem flote komunalnih električnih čistilica za provođenje čišćenja gradskih parkirališnih površina, koja se u slučaju uličnog parkinga koriste prizemnim senzorima za indikaciju zauzetosti parkirališnog mjesta te vanuličnog parkirališta koja se koriste pametnim rampama kao barijerama za ulazak i izlazak iz parkirališta. Provedeno istraživanje povezanih istraživanja ukazuje na to da trenutačno ne postoji višeagentski sustav za kontekstno usmjeravanje flote električnih vozila koji uključuje modele umjetne inteligencije za kontekstne postupke usmjeravanja flote komunalnih električnih vozila radi optimizacije procesa čišćenja gradskih

parkirališnih prostora.

Glavni izazov u ovome istraživanju jest ostvarivanje višeagentskog sustava za kontekstno usmjeravanje flote električnih vozila sastavljen od modela višeagentskog sustava, postupaka za usmjeravanje vozila i višeagentske platforme kojom je omogućena evaluacija postignutih modela i provođenje usporednih analiza postupaka za usmjeravanje. Za ostvarivanje višeagentskog sustava za kontekstno usmjeravanje flote električnih vozila potrebno je odgovoriti na određena istraživačka pitanja (eng. Research Questions - RQs). Prvo istraživačko pitanje odnosi se na ostvarivanje modela višeagentskog sustava za usmjeravanje električnih vozila:

RQ1: *Kako definirati model višeagentskog sustava za usmjeravanje električnih vozila?*

Za rješavanje problema usmjeravanja električnih vozila potrebno je uzeti u obzir entitete koji sudjeluju prilikom usmjeravanja. Najvažniji je entitet *električno vozilo* koje se usmjerava u prostoru. Električno vozilo svojom namjenom uže se specificira od osnovnog entiteta *električno vozilo* predstavljajući time entitet *namjenska električna vozila*. Primjer namjenskog električnog vozila jest električna čistilica za čišćenje gradskih površina. Električna vozila prilikom usmjeravanja moraju obavljati punjenje baterije na električnim punionicama i zbog toga je potrebno uzeti u obzir entitet *električna punionica*. U slučaju usmjeravanja flote električnih vozila potrebno je definirati entitet *spremište vozila* koji upravlja flotom i koji predstavlja početak i završetak usmjeravanja svakog vozila iz flote. Definirani entiteti predstavljaju osnovni skup entiteta koji se mogu klasificirati kao pokretni i stacionarni entiteti. Pokretne i stacionarne entitete potrebno je ostvariti u modelu višeagentskog sustava za usmjeravanje električnih vozila kao agente sa svojim obilježjima i međusobnim odnosima.

Ostvareni model višeagentskog sustava za usmjeravanje električnih vozila koristi se postupcima usmjeravanja električnih vozila u obliku algoritama te se postavlja sljedeće istraživačko pitanje:

RQ2: *Kako definirati postupke za usmjeravanje električnih vozila?*

Algoritmi za usmjeravanje električnih vozila moraju uzeti u obzir ograničenja električnih vozila, u vidu kapaciteta baterije i dometa, koja definiraju potrebu punjenja električnog vozila na električnim punionicama tijekom usmjeravanja. Upravo zbog toga potrebno je razviti strategije punjenja električnih vozila tijekom usmjeravanja kojima se osigurava uspješnost obavljanja posla vozila. Isto tako potrebno je definirati algoritme za dva smjera usmjeravanja: smjer prema odredištu i smjer prema električnoj punionici. Za postizanje uspješnog usmjeravanja algoritam se mora sastojati od dviju faza: faze planiranja i faze izvršavanja. U fazi planiranja definira se plan usmjeravanja koji se izvršava i optimizira u fazi izvršavanja. Na uspješnost plana us-

mjeravanja mogu utjecati i kontekstni uvjeti u kojima se vozila kreću i obavljaju posao te u kojima se nalaze odredišta i električne punionice. Predviđanjem utjecajnih čimbenika u fazi planiranja, algoritmi mogu ostvariti bolju uspješnost usmjeravanja električnih vozila ostvarujući pritom maksimizaciju korisničkih preferenci. Predviđanje utjecajnih čimbenika može se ostvariti pomoću modela umjetne inteligencije ostvarene nad prikupljenim terenskim i kontekstnim podacima.

Algoritmi se mogu u fazi planiranja koristiti modelima umjetne inteligencije za predviđanje utjecajnih čimbenika na usmjeravanje te se stoga postavlja sljedeće istraživačko pitanje:

RQ3: *Kako ostvariti modele umjetne inteligencije potrebne u radu postupaka usmjeravanja?*

Modeli umjetne inteligencije mogu pružiti vrijedne informacije algoritmima za usmjeravanja električnih vozila u vidu poboljšanja rezultata usmjeravanja. Za stvaranje modela umjetne inteligencije potrebno je definirati cilj predviđanja. Cilj predviđanja modela umjetne inteligencije koji se koriste u algoritmima usmjeravanja jest *mjera iskoristivosti*[15] električnih punionica, uličnih i vanuličnih parkirališta. Mjera iskoristivosti električnih punionica iskazuje udio iskorištenog vremena punjenja na priključcima električne punionice od ukupno dostupnog vremena unutar jednog sata. Mjera iskoristivosti uličnih i vanuličnih parkirališta iskazuje udio iskorištenog parkirališnog vremena koje parkiralište može ponuditi korisnicima unutar jednog sata. Mjerom iskoristivosti ostvaruju se modeli iskoristivosti, za čije je stvaranje potrebno uključiti i kontekstne podatke mjesta od značaja i *vremenske prognoze*, koji su vezani uz električne punionice i parkirališta. Evaluacijom modela iskoristivosti odabiru se najbolji ostvareni modeli iskoristivosti za korištenje u algoritmima usmjeravanja električnih vozila.

Na kraju uz ostvarene sve elemente modela višeagentskog sustava za kontekstno usmjeravanje flote električnih vozila potrebno je realizirati višeagentsku platformu te se postavlja sljedeće istraživačko pitanje:

RQ4: *Kako ostvariti višeagentsku platformu za simulaciju transportnog sustava flote električnih vozila?*

Za ostvarivanje modela višeagentskog sustava potrebno je koristiti se okruženjem za razvoj i pokretanje višeagentske platforme. Postoji širi skup okruženja za razvoj i pokretanje višeagentskih platformi [16], ali ovaj se rad fokusira na upotrebu alata *AnyLogic* koji omogućuje lakše ostvarivanje višeagentskih modela pomoću višemetodnog modeliranja [17]. Implementacijom modela višeagentskog sustava za kontekstno usmjeravanje flote električnih vozila ostvaruje se višeagentska platforma za simulaciju transportnog sustava flote električnih vozila. Višeagentska platforma za simulaciju transportnog sustava flote električnih vozila mora omogućavati vrednovanje definiranih algoritama usmjeravanja uz promjenu kontekstnih uvjeta te usporednu analizu

algoritama usmjeravanja u definiranim kontekstnim uvjetima.

Nakon što je ostvarena višeagentska platforma za definirani model višeagentkog sustava, mogu se izvoditi simulacije zadanih algoritama usmjeravanja flote električnih vozila u definiranim kontekstnim uvjetima. Rezultate algoritama usmjeravanja dobivenih simulacijama potrebno je međusobno usporediti radi odabira najboljeg algoritma te se postavlja sljedeće istraživačko pitanje:

RQ5: *Kako definirati usporednu analizu postupaka usmjeravanja u višeagentskoj platformi za simulaciju transportnog sustava električnih vozila?*

Višeagentska platforma za simulaciju transportnog sustava električnih vozila omogućuje izvođenje simulacija za definirani model višeagentskog sustava za usmjeravanje električnih vozila koji se koristi algoritmima za usmjeravanje električnih vozila unutar postavljenih kontekstnih uvjeta. Provođenjem funkcijskih analiza ostvarene simulacije dokazuje se mogućnost izvođenja definiranih modela višeagentskog sustava, dok se tehno-ekonomskim analizama ostvaruju usporedne analize postupaka usmjeravanja. Rad definira dvije mjere uspješnosti koje su vezane uz studijski slučaj izvođenja simulacija višeagentskog sustava: *uspješnost čišćenja* i *uspješnost punjenja*. Mjera uspješnost čišćenja definira uspješnost flote električne čistilice u procesu čišćenja parkirališnih površina na temelju postupaka usmjeravanja. Mjera uspješnosti punjenja definira uspješnost flote električnih čistilica u korištenju električnih punionica tako da su obavljale punjenje sa što manjim čekanjem na slobodan priključak električne punionice.

1.2Struktura rada

Nakon uvodnog poglavlja 1, koje opisuje motivaciju rada i definira ga pomoću postavljenih istraživačkih pitanja, poglavlje 2 prikazuje pregled povezanih istraživanja u odabranim poglavljima iz područja problema usmjeravanja električnih vozila usko vezana uz problematiku ovog rada te pregledom literature vezanom uz ostvarivanje višeagentskih sustava za kontekstno usmjeravanje flote električnih vozila. Na kraju poglavlja 2 nudi se prijedlog rješenja na identificirane nedostatke uočene pregledom povezanih istraživanja.

Poglavlje 3 opisuje model višeagentskog sustava za usmjeravanje električnih vozila detaljanim opisom modela svih pokretnih i stacionarnih agenata. U poglavlju 4 definirani su algoritmi za usmjeravanje električnih vozila razlikujući osnovne algoritme i algoritme koji koriste modele iskoristivosti, pri čemu je dan detaljan opis algoritama i modela iskoristivosti. Poglavlje 5 opisuje izvedbu ostvarene platforme za simulaciju transportnog sustava flote električnih vozila pomoću funkcijske i tehno-ekonomske analize.

Na kraju poglavlje 6 zaključuje rad i opisuje nastavak istraživačkog rada pomoću poboljšanja ostvarenog višeagentskog sustava za kontekstno usmjeravanje flote električnih vozila.

Poglavlje 2

Pregled povezanih istraživanja

Drugo poglavlje prikazuje pregled istraživanja relevantnih za ovaj rad. U prvom dijelu prikazuje se pregled odabranih područja vezanih uz problem usmjeravanja električnih vozila. Pregled uključuje prikaz tipova električnih vozila koja se mogu koristiti prilikom usmjeravanja, vrste i načini pristupa rješavanju problema usmjeravanja električnih vozila te područja primjene. Nakon toga prikazuje se pregled same literature vezane uz problem usmjeravanja električnih vozila s naglaskom na korištenje kontekstnih informacija u algoritmima za usmjeravanje flote električnih vozila ostvarenih u višeagentskom sustavu, pri čemu je potrebno definirati sastav i veličinu korištene flote.

2.1 Odabrana poglavlja iz područja problema usmjeravanja električnih vozila

Korištenje električnih vozila u obavljanju usluga i transporta dovodi do određenih prednosti [18]. Električna vozila predstavljaju ekološki prihvatljivi način transporta zato što nemaju lokalnih emisija stakleničkih plinova i proizvode minimalnu buku u odnosnu na konvencionalna vozila. Štoviše, korištenjem električnih vozila može se postići i nulta emisija stakleničkih plinova ako se električna energija dobiva pomoću obnovljivih izvora energije [19]. Osim ekološke prihvatljivosti, operativni troškovi i troškovi održavanja električnih vozila niži su u odnosu na konvencionalna vozila [20]. No električna vozila predstavljaju i određene nedostatke kao što su troškovi nabave, koji su veći za električna vozila u odnosu na konvencionalna. Također, ograničeni domet vožnje i dugo vrijeme potrebno za punjenje baterije utječu na operativne odluke. Nedostatak infrastrukture za punjenje električnih vozila smatra se isto tako nedostatkom. Unatoč nedostacima, zbog vrhunske tehnologije, državnih subvencija i propisa za smanjivanje emisija stakleničkih plinova, električna vozila postaju sve konkurentnija konvencionalnim vozilima [21]. Za rješavanje nedostataka vezanih uz utjecaj na operativne odluke korisnika električnih vozila, istraživačka zajednica uključuje električna vozila u istraživanja vezana uz problem

usmjeravanja vozila (eng. *vehicle routing problem (VRP)*) [19]. Uključivanjem električnih vozila u VRP definiran je termin pod nazivom problem usmjeravanja ekološki prihvatljivih vozila (eng. *green vehicle routing problem (G-VRP)*)[22]. Povećanje korištenja električnih vozila dovodi do sve većeg interesa u istraživačkoj zajednici definirajući pritom novi termin pod nazivom problem usmjeravanja električnih vozila (eng. *electric vehicle routing problem (E-VRP)*) [23]. Istraživački radovi vezanu uz E-VRP razmatraju različite smjerove: homogene i heterogene flote električnih i hibridnih vozila, linearne i nelinearne modele punjenja i potrošnje energije te odluke vezane uz lokaciju punionica. Napretkom informacijskih i komunikacijskih tehnologija (eng. *information and communication tehnologies (ICT)*) ostvaruju se inteligentni transportni sustavi (ITS) unutar kojih se mogu primijeniti rješenja E-VRP-a pri čemu ITS omogućuje prikupljanje i obradu podataka u stvarnom vremenu pružajući time potrebne podatke za planiranje usmjeravanja vozila u prostoru [24].

2.1.1Električna vozila

Električna vozila dijele se na potpuno električna vozila (eng. *battery electric vehicles (BEV)*), hibridna električna vozila (eng. *hybrid electric vehciles (HEV)*) i električna vozila s gorivim ćelijama (eng. *fuel cell electric vehicle (FCEV)*) [20]. Opis navedenih vrsta električnih vozila prikazuje se u nastavku.

Potpuno električna vozila

BEV se pokreće pomoću električnog motora pri čemu se koristi samo energijom iz baterije koju se može puniti na električnim punionicama [25]. Prednosti su ovakvih električnih vozila odsutnost ispušnih plinova, visoka učinkovitost od spremnika do kotača (eng. *tank-to-wheel efficiency*) i puno manja buka u odnosu na vozila s unutarnjim izgaranjem. Tehnički nedostaci BEV-a relativno su mali ostvarivi doseg i znatna količina vremena potrebna za punjenje baterije [26]. Motori BEV-ova mogu proizvesti veliki okretni moment pri malim brzinama i puno su učinkovitiji od vozila s unutarnjim izgaranjem. BEV-ovi također ne zahtijevaju velika održavanja jer nemaju previše pokretačkih dijelova koji bi se s vremenom potrošili te ne zahtijevaju zamjenu ulja kao što je to slučaj kod vozila s unutarnjim izgaranjem. Tipični doseg teretnih BEV-ova, kao što je električna čistilica, jest od 100 do 200 kilometara i smanjuje se sa starenjem baterije [27]. Ostali faktori koji utječu na smanjivanje dosega vozila jesu visoke temperature, velike brzine, jaka ubrzanja, prijevoz teškog tereta i brdovit teren [28]. U radu se koriste BEV-ovi kao električna vozila (EV).

Hibridna električna vozila

HEV-ovi se koriste motorom s unutarnjim izgaranjem zajedno s električnim motorom s kojim dolazi baterija za spremanje električne energije. Mogu se klasificirati prema funkciji njihova elektromotora, arhitekturi pogonskog sklopa ili kapacitetu priključivanja na električnu mrežu za punjenje baterije [29]. Električni motori koriste se u mikrohibridnim sustavima za "start/stop" sustave zbog smanjenja potrošnje goriva, no električni motori mogu se koristiti u poluhibridnim i potpunim hibridnim vozilima za pomoć u radu motora s unutarnjim izgaranjem, kao što je na primjer omogućavanje vožnje s isključenim motorom s unutarnjim izgaranjem. Potpuno hibridna vozila mogu se nadalje klasificirati prema arhitekturi pogonskog sklopa [30]. Serijska arhitektura pogonskog sklopa koristi se motorom s unutarnjim izgaranjem za napajanje generatora, a električni motor jedina je pogonska komponenta spojena na pogon vozila. U paralelnoj arhitekturi pogonskog sklopa, motor s unutarnjim izgaranjem i električni motor spojeni su na pogon vozila i omogućuju njihovo istovremeno ili pojedinačno korištenje tijekom vožnje. Serijsko-paralelna arhitektura kombinira prethodne dvije vrste arhitektura, pri čemu se koristi generator kao dodatni elektromotor. Potpuno hibridna vozila koja uključuju i bateriju s mogućnošću punjenja na električnim punionicama definiraju se kao *plug-in* hibridna vozila (eng. *plug-in hybrid electric vehicles (PHEV)*). PHEV-ovi se koriste baterijama koje su veće od standardnih hibridnih vozila, ali su manje od baterija u električnim vozilima te ostvaruju domet od 30 do 60 kilometara [31].

Električna vozila s gorivim ćelijama

FCEV-ovi dobivaju električnu energiju pomoću vodika koji se koristi za pokretanje elektromotora ili za punjenje baterije, pri čemu je nusprodukt voda koja se izbacuje iz sustava [32]. Vodik se nalazi u spremniku vozila u plinovitom ili tekućem obliku te postoji mogućnost dobivanja vodika fizikalnom ili kemijskom adsorpcijom. FCEV-ovi se mogu napuniti s vodikom u vrlo kratkom vremenu i mogu ostvariti domete u iznosu od nekoliko stotina kilometara. Vozila ostvaruju manju buku prilikom rada, ali su manje efikasna od BEV-ova iz perspektive prijenosa energije iz spremnika do pogonskog sklopa [33]. Gorive ćelije imaju efikasnost od 50% u smislu udjela vodika za dobivanje električne energije. Isto tako troškovi održavanja FCEV-ova visoki su jer je trajanje gorive ćelije procijenjeno na maksimalno 10.000 radnih sati. Električna vozila s gorivim ćelijama koriste ultrakondezatore (eng. *ultracapacitor*) kojima se omogućuje spremanje regenerativne energije kočenja i pomaže u radu gorivih ćelija kod visokih opterećenja. Ultrakondenzatori imaju veću snagu od baterija te se razmatra njihovo korištenje zajedno uz baterije u BEV-ovima i HEV-ovima [34].

2.1.2Problem usmjeravanja elektri čnih vozila

Problem usmjeravanja električnih vozila jest proširenje problema usmjeravanja vozila tako da su uključena električna vozila koja moraju tijekom svog rada puniti baterije. Problem usmjeravanja vozila definira nekoliko podvrsta koja uključuju vremenska ograničenja, ograničenje putem kapaciteta, pristup s više spremišta vozila, heterogene ili homogene flote i različite strategije punjenja baterije [35].

Problem usmjeravanja električnih vozila s kapacitetom

Problem usmjeravanja električnih vozila s kapacitetom (eng. *capcitated electric vehicle routing problem (CE-VRP)*) uzima u obzir ograničenje koje je definirano kapacitetom vozila ili kapacitetom flote [36]. Kapacitet vozila može se definirati kao nosivost tereta, veličina teretnog prostora, udaljenost koju može prijeći ili kapacitet baterije, dok se kapacitet flote definira brojem vozila koja su dostupna za izvršavanje usluge na odredištima [37]. E-VRP uključuje proces određivanja ruta za jedno ili više vozila od lokacije skladišta vozila do lokacije odredišta, uključujući i povratak vozila natrag u spremište, pri čemu je za CE-VRP potrebno voditi brigu o kapacitetu vozila ili flote. Odredišta definiraju različite zahtjeve koji za CE-VRP predstavljaju potencijalni problem vezan uz prekoračenje definiranih kapaciteta vozila ili flote. CE-VRP je prema tome težak oblik optimizacije koji može imati različite ciljeve, kao što su minimiziranje ukupnih troškova ili ukupne prijeđene udaljenosti vozila [38]. Dodatno, CE-VRP može definirati dodatna ograničenja, kao što su broj posjeta odredištu prilikom usmjeravanja vozila. Dostupne su i brojne varijacije CE-VRP-a: varijacija s jednim spremištem vozila ili više njih i varijacije s vremenskim ograničenjima u obliku vremenskih okvira.

Problem usmjeravanja električnih vozila s vremenskim okvirom

Problem usmjeravanja električnih vozila s vremenskim okvirom (eng. *electric vehicle routing problem with time window (E-VRPTW)*) uzima u obzir vremenski okvir unutar kojeg zahtjevi odredišta moraju biti izvršeni [39]. Vremenski okvir može biti jednak za svako odredište ili se može razlikovati od odredišta do odredišta. Isto tako vremenski okvir može biti definiran zasebno za svaki novi zahtjev odredišta. Prema tome u odnosu na klasični E-VRP, vremenski okvir definira ograničenje koje mora biti uzeto u obzir prilikom određivanja optimalnih ruta vozila. Potreba punjenja baterije električnih vozila prilikom izvršavanja zahtjeva odredišta predstavlja dodatan izazov prilikom rješavanja E-VRPTW-a jer plan usmjeravanja vozila mora uzeti u obzir i vrijeme potrebno za punjenje unutar definiranog vremenskog okvira odredišta [40]. E-VRPTW može uključivati jedno ili više vozila pri čemu je potrebno uzeti u obzir specifikacije vezane uz bateriju vozila. Također, često se uz vremenski okvir uzima u obzir i kapacitet vozila i time se ostvaruje problem usmjeravanja električnih vozila s kapacitetom i vremenskim

okvirom (eng. *capacitated electric vehicle routing problem with time window (CE-VRPTW)*) [41].

Problem usmjeravanja električnih vozila s različitim strategijama punjenja

Problem usmjeravanja električnih vozila s različitim strategijama punjenja često je istraživani problem koji pritom naglašava važnost rješavanja pristupa izradi planu punjenja električnih vozila prilikom izvršavanja definiranih ruta [42]. Trajanje procesa punjenja električnih vozila može trajati od pola sata pa sve do jednog ili više sati, pri čemu sve ovisi o tipu tehnologije dostupne na električnim punionicama, definirajući pritom sljedeće brzine: spore, do 3 kW (6-8 sati); brze, 7-43 kW (1-2 sata); i ultrabrze, 50-250 kW (5-30 min) [35]. Ovakva ograničenja predstavljaju veliki izazov u planiranju ruta za izvršavanje zahtjeva odredišta, pri čemu mogu biti uključena i dodatna ograničenja, kao što su kapacitet vozila i vremenski okvir za izvršavanje zahtjeva odredišta pri čemu tradicionalni način punjenja električnih vozila više nije održiv. Neke od strategija punjenja baterije električnih vozila jesu: djelomično punjenje [43] i zamjena baterije [44]. Strategija djelomičnog punjenja sastoji se u tome da električno vozilo puni bateriju samo do određene razine koja je dostatna za izvršavanje zahtjeva odredišta, smanjujući time vrijeme punjenja. Strategija zamjene baterija na za to definiranim postajama omogućuje vrlo brzo punjenje pomoću jednostavne zamjene baterije vozila s novom. Ovom strategijom električna vozila vrlo brzo mogu nastaviti s izvršavanjem zahtjeva odredišta.

2.1.3Podru čja primjene problema usmjeravanja električnih vozila

E-VRP koristi se za rješavanje različitih izazova i problema vezanih uz različite sustave i procese iz stvarnog svijeta. Primjenjivost rješenja E-VRP-a široka je, od gradskih procesa i djelatnosti pa sve do industrijskih i privatnih sektora. Područja primjene mogu se definirati unutar tri grupacije vezane uz uslužne djelatnosti, djelatnosti prijevoza robe i ljudi [45].

Uslužne djelatnosti

Primjena E-VRP-a u uslužnim djelatnostima usmjerava električna vozila prema korisnicima usluge koja im se pruža po dolasku električnog vozila na odredište korisnika. Primjeri usluga mogu biti vezani uz gradske komunalne usluge čišćenja gradskih površina ili odvoza otpada te usluge dostave hrane ili paketa [46]. Rješenja E-VRP-a za ovakav tip primjene definira se s vremenskim okvirom (E-VRPTW) unutar kojeg usluga mora biti izvršena i kapacitetom (CE-VRP) koji označava broj vozila namijenjenih za izvršavanje usluge. Primjer ovakve usluge jest čišćenje gradskih površina koju flota električnih čistilica mora izvršiti unutar operativnoga vremena gradske komunalne službe. Rješenja E-VRPTW-a i CE-VRP-a naznačuju nužnost razvoja sustava za potporu u odlučivanju (eng. *Decission support system (DSS)*). Konkretno, u [47] i [48]

predstavljena su rješenja E-VRP-a s DSS-om za poštanske usluge dostave paketa i prikupljanja otpada u gradovima. Oba su rješenja ostvarena pomoću E-VRPTW-a s promjenjivim vremenskim okvirom i primjenom algoritma "problem trgovačkog putnika" (eng. *travelling salesman problem (TSP)*). Ostale uslužne djelatnosti u kojima se može postići primjena E-VRP-a vezana je uz usluge održavanja [49].

Prijevoz robe

Područje primjene vezane uz prijevoz robe u gradskim sredinama predstavlja vrlo zahtjevno okruženje za provođenje usmjeravanja vozila gdje prometne gužve i ostali čimbenici mogu poremetiti definirani plan usmjeravanja vozila [50]. Isto tako, korisnici u gradskim sredinama vrlo često traže uslugu dostave robe isti dan, čime se skraćuje vrijeme sustava potrebno za promjene u planovima usmjeravanja uzimajući pritom trenutačno stanje zahtjeva odredišta i stanje gradskog prometa [46]. Upravo zbog toga agencije za dostavu robe uključuju rješenja za E-VRP u svoje DSS-sustave uključujući pritom podatke o stanju u prometu i modele za predviđanje vremena trajanja izvršavanja pojedinih ruta na temelju povijesnih podataka i podataka u stvarnom vremenu [51]. U tipičnim primjena E-VRP-a za prijevoz robe funkcija cilja vezana je uz minimiziranje ukupnih troškova prijevoza brinući se pritom o korisničkom iskustvu pružanja usluge [52].

Prijevoz ljudi

Područje primjene E-VRP-a za prijevoz ljudi vrlo je sličan VRP-u za "pokupi i dostavi" (eng. *pickup and delivery*) i često je ostvaren modelima *Dial-a-Ride Problem (DARP)*, gdje se veliki naglasak stavlja na ostvarivanje što većeg korisničkog zadovoljstva uslugom [53]. Prijevoz ljudi u gradovima povezan je s prijevozom putnika gradskim električnim autobusima ili električnim taksijima. Električni autobusi predstavljaju velik potencijal za rješavanje problema vezanih uz gradske prometne gužve i emisije štetnih plinova uzrokovanih sve većim rastom osobnih automobila s unutarnjim izgaranjem. Električni autobusi rade učinkovitije i tiše od autobusa s unutarnjim izgaranjem i značajno doprinose smanjenju negativnih utjecaja na okoliš. Međutim, nedostaci električnih autobusa jesu ograničeni domet baterije i visoki troškovi punjenja jer se koriste punionicama koje pružaju vrlo brzo punjenje baterije [54]. Posljedično, ovo postavlja nove izazove za planiranje ruta električnih autobusa radi ostvarivanja plana usmjeravanja, koji uključuje plan punjenja baterije kojim se osigurava ekonomska isplativost. E-VRP s korištenjem različitih strategija punjenja baterije (djelomično na autobusnoj stanici ili punionici) može ostvariti ekonomsku isplativost [55]. E-VRP za električne taksije ima cilj predviđanja zahtjeva odredišta na temelju kojih se izrađuje plan punjenja i korištenje taksija iz skupa dostupnih taksija [56].

2.1.4Pristup rješavanju problema usmjeravanja elektri čnih vozila

Napretkom ICT-a ostvaruju se novi pristupi rješavanja E-VRP-a uključujući pritom današnje sve dinamičnije okruženje unutar kojih se vozila usmjeravaju. Dva osnovna pristupa u rješavanju E-VRP-a jesu centralizirani i raspodijeljeni pristup [57] koji se mogu poistovjetiti s principima rada protokola usmjeravanja u telekomunikacijama [58].

Centralizirani pristup

Centralizirani pristup u telekomunikacijama definira princip rada protokola usmjeravanja tako da centralni čvor definira rute usmjeravanja između dvaju čvorova u mreži na temelju prikupljenih informacija koji su ulaz za algoritam za usmjeravanje [57]. Jednaki se princip primjenjuje i za E-VRP gdje centralni entitet može biti predstavljen spremištem vozila koje izrađuje plan usmjeravanja svih vozila na temelju prikupljenih informacija koji su ulaz u algoritme za usmjeravanje [59]. Prema tome, središnji entitet (eng. *central node (CN)*) definira sustav za donošenje odluka (eng. *decission support system (DSS)*) koji određuje i provodi plan usmjeravanja entiteta u mreži unutar sustava. Razlika u odnosu na protokole usmjeravanja u telekomunikacijama jest u definiciji zahtjeva odredišta koja može biti poznata unaprijed ili može biti poznata tek po dolasku do odredišta. Centralizirani sustav za E-VRP definira deterministički i stohastički pristup rješavanju E-VRP-a [60]. Deterministički pristup definira rješavanje E-VRP-a s unaprijed poznatom količinom zahtjeva odredišta na temelju kojih se radi plan usmjeravanja. Definirani plan usmjeravanja tijekom izvršavanja može se periodički ili kontinuirano dodatno optimizirati. Periodička optimizacija plana usmjeravanja može se izvršavati na točno određenim vremenskim intervalima ili na temelju promjene plana usmjeravanja nastale zbog neuspjelih usmjeravanja vozila (npr. vremenski okvir za odredište nije ispoštovan). Kontinuirana optimizacija provodi optimizaciju prvotnoga plana tako da pohranjuje sva uspješna usmjeravanja vozila i pomoću tih informacija optimizira plan usmjeravanja vozila. Stohastički pristup rješava E-VRP s unaprijed nepoznatim odredišnim zahtjevima, pri čemu oni postaju poznati tek po dolasku vozila na odredište. Primjer takvog sustava jest čišćenje gradskih parkirališnih površina, gdje električna čistilica tek po dolasku na parkiralište može vidjeti koliko je parkirališnih mjesta slobodno za čišćenje. Stohastički pristup riješavanju E-VRP-a definira dvije faze: faza planiranja i faza izvršavanja [60]. Faza planiranja definira plan usmjeravanja na temelju prediktivnih modela koji mogu predvidjeti količinu zahtjeva odredišta za izvršavanje. Faza izvršavanja provodi definirani plan usmjeravanja pri čemu se može omogućiti promjena plana.

Raspodijeljeni pristup

Telekomunikacijski sustavi definiraju i raspodijeljeni pristup u radu protokola za usmjeravanje, pri čemu je svaki čvor u mreži obaviješten o stanju mreže od susjednog čvora [57]. Ovime se

omogućuje brža reakcija na novonastale situacije u mreži koje mogu biti nepovoljne za sva sljedeća usmjeravanja unutar mreže. Veći transportni i logistički sustavi jednako tako zahtijevaju bržu reakciju na neočekivane promjene prilikom izvođenja usluga čime se naglašava potreba uvođenja raspodijeljenog pristupa u E-VRP [61]. Za potrebe E-VRP-a raspodijeljeni pristup može se ostvariti višeagentskim sustavima (eng. *multi-agent systems (MAS)*) koji definiraju autonomne programske agente za određene logističke i transportne entitete (spremište vozila, električno vozilo, narudžbe, odredišta). Agenti omogućuju komunikaciju s drugim agentima radi razmjene informacija i donošenja odluka. Primjer MAS-sustava za VRP prikazan je u radu [61] koji definira dva tipa agenata: *nalog* i *kamion*. Agent *nalog* stvara se po dolasku novog korisničkog zahtjeva za prijevoz robe i predaje se agentu *kamion* na izvršavanje. Rad [62] prikazuje također MAS-primjenu za VRP definirajući pritom agente *pošiljatelj* i *prijevoznik* koji se usmjeravanju na temelju algoritma *pickup-and-delivery*. MAS-sustav korišten je za ostvarivanje plana usmjeravanja koji će postići najmanje troškove i kašnjenja dostave paketa korisnicima. U fokusu provođenja optimizacije pomoću MAS-a bila su izranjajuća ponašanja *eng. emergent behaviors* koja su uzeta u obzir prilikom definiranja sljedećih planova usmjeravanja. U radu [63] prikazan je MAS pomoću kojeg dostavna vozila definirana u obliku agenata međusobno komuniciraju radi obavještavanja o prometnim gužvama u gradu čime se skraćuje vrijeme dostave robe korisnicima.

2.2Problem usmjeravanja elektri čnih vozila u literaturi

Za razumijevanje relevantnosti prikazanog istraživanja u ovome radu, nudi se prikaz literature povezane s glavnim dijelovima ovog rada kao što su: rješavanje E-VRP-a s osnovnim algoritmima i algoritmima koji uključuju kontekstne informacije i ograničenja u obliku vremenskih okvira izvršavanja usluge i kapaciteta vozila; definiranje veličine flote električnih vozila za usmjeravanje; i definiranje modela višeagentskog sustava električnih vozila radi ostvarivanja platforme za simulaciju transportnog sustava flote električnih vozila koja omogućuje provođenje funkcijskih i tehno-ekonomskih analiza.

2.2.1Rješenja problema usmjeravanja elektri čnih vozila

Postoji relativno malo istraživačkih radova veznih uz rješavanje E-VRP-a s vremenskim okvirom (E-VRPTW) i kapacitetom (CE-VRP) koji definiraju ograničenja kod usmjeravanja. Artmeier i sur. (2010) [64] prvi su put formalizirali problem određivanja najkraće rute sa strogim i blagim ograničenjima, pri čemu su korištena električna vozila za usmjeravanje. Definiran je algoritam koji predstavlja proširenje algoritma za određivanje najkraće rute gdje je težinska funkcija definirana količinom potrošene energije za određenu rutu usmjeravanja. Rezultati istraživanja pokazuju da se troškove ubrzavanja i usporavanja vozila na dionicama s različitim brzinama

moraju uzeti u obzir prilikom usmjeravanja vozila. Conrad i Figliozzi (2011.) [65] predstavili su E-VRPTW u kojem je omogućeno punjenje električnih vozila na odredištima korisnika koja vozila posjećuju. Erdoğan i Miller-Hooks (2012) [22] definirali su novu vrstu problema usmjeravanja vozila pod nazivom problem usmjeravanja ekološki prihvatljivih vozila (eng. *green vehicle routing problem (GVRP)*). GVRP uzima u obzir sva vozila s alternativnom vrstom goriva koja imaju ograničeni domet vožnje i za koja je potrebna posebna infrastruktura za punjenje alternativnog goriva. Istraživanje se koristi heurističkom metodom uštede *Clarke and Wright* zajedno s metodom grupiranja za ostvarivanje algoritma usmjeravanja vozila. Prethodno prikazana istraživanja definirala su temelje pristupa u rješavanju E-VRP-a pružajući pritom instance E-VRP-a kao osnovu za usporedbu svih sljedećih algoritama za usmjeravanje električnih vozila u odnosu na ostvarene algoritme.

Nastavak istraživanja E-VRP-a fokusirao se na način provođenja punjenja električnog vozila, uključujući i dalje pritom ograničenja vremenskog okvira i kapaciteta vozila. Razlog je tome mogućnost kršenja vremenskog okvira izvršavanja usluge prema određenom odredištu zbog potrebe punjenja električnog vozila koje ovisno o brzini punjenja može trajati i do nekoliko sati. Scheneider i sur. (2014.) [66] dodaju u E-VRPTW i CE-VRP mogućnost punjenja električnog vozila na bilo kojoj dostupnoj punionici. Za ostvarivanje rješenja korišten je metaheuristički pristup ostvaren algoritmima pretraživanja promjenjivom okolinom (eng. *Variable Neighborhood Search*) i tabu-pretraživanjima (eng. *Tabu Search*). Felipe i sur. (2014.) [67] razmatraju E-VRP sa strategijama djelomičnog punjenja električnog vozila na punionicama. Strategije djelomičnog punjenja razlikovale su se po vremenskom ograničenju za trajanje punjenja. Ostvaren je algoritam usmjeravanja koji uključuje konstruktivne i determinističke algoritme lokalnog pretraživanja koji se koriste unutar ne-determinističkog algoritma "simuliranje kaljenja" (eng. *Simulated Annealing*). Desaulniers i sur. (2014.) [68] razmatraju čak četiri vrste E-VRPTW-a koji se razlikuju po načinu provođenja punjenja električnog vozila na punionici. Prva strategija definira jedno punjenje do maksimalnog kapaciteta baterije po ruti, dok druga strategija određuje mogućnost obavljanja više punjenja do maksimalnog kapaciteta baterije unutar jedne rute. Treća i četvrta strategija jednake su prvoj i drugoj razlikujući se u tome što je dozvoljeno djelomično punjenje baterije umjesto do maksimalnog kapaciteta. Korišten je algoritam *branch-price-and-cut* zajedno s algoritmima za jednosmjerno i dvosmjerno označavanje (eng. *mono directional and bi-directional labeling*) za ostvarivanje najboljeg rješenja. Goeke and Schneider (2015) [69] predlažu E-VRPTW s heterogenom flotom koja se sastoji od električnih i konvencionalnih vozila. Cilj je istraživanja definiranje funkcije potrošnje energije temeljene na brzini vozila, nagibu terena i distribuciji tereta. Rješenje definiranog problema postignuto je korištenjem algoritma pretraživanja promjenjive okoline zajedno s algoritmom lokalnog pretraživanja. Zhenfeng i sur. (2017.) [70] definiraju E-VRPTW za ostvarivanje što većeg dometa vozila tijekom usmjeravanja pri čemu uključuju mogućnost punjenja na nekoliko

električnih punionica. Rješenje E-VRPTW-a u obliku je modela za usmjeravanja električnih vozila koji se koristi genetskim algoritmima za usmjeravanje vozila.

Posljednjih nekoliko godina intenzivirao se broj istraživanja E-VRP-a koji se fokusiraju na potrošnju električne energije vozila tijekom usmjeravanja vozila te potrošnju električne energije definiraju kao važan čimbenik u algoritmima za usmjeravanje. Zhang i sur. (2018.) [71] definiraju CE-VRP koji uzima kapacitet baterije kao kapacitet vozila. Rješenje CE-VRP-a postignuto je u obliku matematičkog modela pomoću kojeg se izračunava potrošnja energije električnog vozila tijekom usmjeravanja. Cilj je postići što manju potrošnju električne energije vozila. Matematički model temelji se na korištenju metaheurističkog mravljeg algoritma (eng. *ant colony*) pomoću kojeg se postiže plan usmjeravanja s najmanjom potrošnjom električne baterije definirane kapacitetom baterije. Pelletier i sur. (2019.) [45] definiraju E-VRP za teretna vozila namijenjena za urbana gradska područja, kao što su električni autobusi i dostavna vozila. Fokusiraju se na potrošnju energije vozila koju definiraju kao važan čimbenik, pri čemu na potrošnju energije utječu razni vanjski nepredvidivi čimbenici poput vremenske prognoze, stanja u prometu, endogenih čimbenika poput ponašanja vozača i drugi parametri potrošnje koje je teže mjeriti. Predlažu radni okvir za izradu optimizacijskog modela koji uključuje nepredvidive utjecajne čimbenike na potrošnju energije za kontekst usmjeravanja električnih teretnih vozila. Cilj je modela postići što manje troškove usmjeravanja pri čemu se jamči uspješno izvršavanje svih ruta dodijeljenih vozilu. Predloženi radni okvir za izradu optimizacijskog modela koristi se za manje flote vozila algoritmima linearnog programiranja, dok za veće flote upotrebljava algoritam pretraživanja veće promjenjive okoline (eng. *large neighbourhood search*). Zhang i sur. (2020.) [72] za E-VRPTW ne uzimaju deterministički način definiranja količine zahtjeva odredišta prilikom izvršavanja usluge na lokaciji odredišta, već ih modeliraju stohastički dodjelom različitih vremena trajanja pružanja usluge na lokaciji odredišta. Optimizacijski model koristi se algoritmom adaptivnog pretraživanja promjenjive veće okoline (eng. *adaptive large neighborhood search*), pri čemu se ostvareni model koristi unutar *fuzzy* simulacije. Basso i sur. (2021.) [73] za rješavanje CE-VRP-a koriste se modelima umjetne inteligencije pomoću kojih rade predviđanje potrošnje energije za određenu rutu usmjeravanja. Algoritam usmjeravanja sastoji se od dviju faza: faze planiranja i faze izvršavanja. Faza planiranja pomoću modela umjetne inteligencije izrađuje optimalni plan usmjeravanja, dok se tijekom faze izvršavanja radi optimizacija plana ovisno o uspješnosti definiranih ruta usmjeravanja.

2.2.2 Problem usmjeravanja električnih vozila pomoću kontekstnih informacija

Kontekstne informacije mogu pomoći kod odlučivanja, planiranja i izvršavanja ruta usmjeravanja električnih vozila u prostoru. Neki od kontekstnih podataka koji se mogu koristiti za rješa-

vanje problema usmjeravanja električnih vozila jesu: stanje u prometu, vremenska prognoza i mjesta od značaja. Kontekstne informacije mogu biti vezane uz vozila koja se usmjeravaju u prostoru ili subjekte koje vozila moraju posjetiti. Rad [74] koristi se kontekstnim informacijama vezanim uz stanje prometa u gradskim sredinama. Stanje prometa definirano je vremenski promjenjivim varijablama koje se upotrebljava u modelu baterije za uočavanje obrazaca punjenja i pražnjenja električnih vozila. Obrasci punjenja i pražnjenja zatim se koriste u algoritmu *hybrid rollout* koji naglasak stavlja na strategiju planiranja usmjeravanja vozila i zatim kreće s fazom izvršavanja (*rollout*). Rad [75] također uzima u obzir stanje gradskih prometnica, ali za usmjeravanje gradskih konvencionalnih buseva. U radu [76] koristi se stanje u prometu za definiranje F-GVRP-a koji služi za određivanje ukupne potrošnje energije tijekom usmjeravanja vozila s varijacijama u brzini vozila uzrokovanih stanjem u prometu.

U radu [77] uz kontekstne informacije stanja u prometu koriste se i informacije vezane uz vremensku prognozu. Autori rada definiraju model pod nazivom *mixed-integer linear program* koji uzima u obzir prikupljene kontekstne informacije na temelju kojih radi dodjelu ruta električnim autobusima za prijevoz ljudi u Kaliforniji. Rad [78] predstavlja još jedan primjer korištenja vremenske prognoze kao izvora kontekstnih informacija za usmjeravanje dronova kod dostave poštanskih paketa [78]. Ostvareni model implementira algoritam za usmjeravanje koji se temelji na korištenju metode lokalnog pretraživanja i dinamičkog programiranja.

Za kontekst mjesta od značaja, koliko je nama poznato, nije uspješno pronađen istraživački rad koji uključuje ovakav kontekst u usmjeravanje električnih vozila. No kontekst mjesta od značaja bilježi veliku primjenu kod istraživanja vezanih uz planiranje i optimizacije infrastrukture električnih punionica [79][80][81][82] te anksioznost dometa (eng. *range anxiety*)[11][83]. Planiranje lokacija smještaja električnih punionica pomoću kontekstnih informacija mjesta od značaja naznačuje da kontekst mjesta od značaja utječe na korištenje samih električnih punionica.

2.2.3Veli čina i sastav flote električnih vozila

E-VRP može uključivati flotu električnih vozila koja se usmjerava u prostoru. Flota električnih vozila definirana je kapacitetom koji označava broj električnih vozila koja mogu sačinjavati homogenu ili heterogenu flotu. Homogena flota električnih vozila sastoji se od vozila istih karakteristika kao što je vrsta električnog vozila ili kapacitet baterije, dok se heterogena flota sastoji od električnih vozila različitih karakteristika. Istraživački radovi vezani uz određivanje veličine flote električnih vozila rijetka su, no postoje određeni pristupi u određivanju veličine flote. Rad [84] nastoji odrediti idealnu flotu električnih vozila za distribuciju tereta iz amsterdamske luke prema korisnicima u centru Amsterdama. Cilj je istraživanja postići optimalnu veličinu flotu električnih vozila za pružanje usluge s minimalnim troškovima. U radu [85] prikazano je korištenje heterogene flote koja se sastoji od električnih vozila i vozila s unutarnjim izgaranjem

korištene za rješavanje VRP-a s principom "pokupi i dostavi" (eng. *pickup and delivery*). Cilj istraživanja jest postizanje minimizacije fiksnih i varijabilnih troškova vezanih uz veličinu flote.

U radu [86] problem određivanja veličine heterogene flote električnih i konvencionalnih vozila prikazan je u obliku natjecanja baziranog na teoriji igara (eng. *game theory*) između regulativne agencije i operatora u dvjema fazama. Regulativna agencija nameće okolišne regulative koje operator flote vozila mora ispuniti, pri čemu definira različite tarife i poreze za poticanje korištenja električnih vozila. Operator flote u ovako definiranom okruženju pokušava postići što bolje pružanje usluge s minimalnim troškovima. Autori istraživanja ostvarili su model ravnoteže za ovakvo natjecanje baziranog na teoriji igara koji ostvaruje veći profit za operatora flote s više električnih vozila pomoću subvencija za električna vozila. Rad [69] istražuje veličinu flote s različitim vozilima koja se primjenjuje za VRP s vremenskim okvirom. Flota se sastoji od električnih i konvencionalnih vozila koja imaju definirane fiksne troškove, operativne troškove, nosivost, utovarni kapacitet, energetski kapacitet i potrošnju energije. Cilj je definirati flotu s vozilima koja će ostvariti minimalne fiksne i operativne troškove. Istraživački problem riješen je pomoću modificirane *Clarke* i *Wright* metode ušteda, pri čemu je ostvarena metoda testirana za svaku od sedam definiranih konfiguracija flota nad 25, 10 i 5 korisnika. Rezultat istraživanja ukazuje na veću konkurentnost električnih vozila kod manjih flota.

Postoje i određena nedavna istraživanja vezana uz određivanje optimalne veličine i sastava flote. Rad [87] iz 2021. godine prikazuje upotrebu heterogene flote vozila sastavljene od električnih i konvencionalnih vozila. Prvi je korak izvršavanje optimizacije ruta za dostavu tereta s funkcijom cilja minimiziranja operativnih troškova. Dobiveni rezultati unose se u ostvareni model zamjene s ciljem pronalaska najboljeg sastava i veličine flote. Rezultati istraživanja pokazali su da korištenje električnih vozila u gradovima može povećati njihovu prisutnost u flotama vozila u odnosu na konvencionalna vozila. Rad [88] naglašava povećanje prisutnosti električnih vozila u heterogenim flotama vozila koja se koriste za usmjeravanje zbog sve strožih propisa vezanih uz emisije štetnih plinova.

2.2.4Višeagentski sustav za usmjeravanje elektri čnih vozila

Višeagentski sustav (eng. *multi-agent system - MAS*) odnosi se na sustav koji se sastoji od više autonomnih agenata koji međusobno komuniciraju i surađuju radi izvršavanja dodijeljenih zadataka [89]. MAS pruža mogućnost ostvarivanja različitih modela sustava i procesa iz stvarnog svijeta omogućujući pritom provođenje i testiranje uporabnih scenarija dajući pritom bolji uvid u dinamiku i odnose implementiranog modela [90]. Osnovna svojstva svakog agenta koja mogu biti prisutna kod definicije agenata jesu: autonomnost, interakcija s okolinom, mogućnost učenja i pokretljivost u prostoru [91]. Za ostvarivanje MAS-a potrebno je koristiti se okruženjem za razvoj i izvršavanje agentskih sustava (eng. *agent execution enviroment (AEE)*) [92]. Primjer AEE-a jest *Java Development Framework (JADE)* koji pruža okruženje za razvoj agentskih sus-

tava kompatibilnih s FIPA-protokolom [93]. *TRlabs Execution Enviroment for Mobile Agents (TEEMA)* predstavlja okruženje za ostvarivanje višeagentske platforme na temelju definiranog višeagentskog modela pružajući različite mogućnosti prilikom određivanja agenata kao što su imenovanja agenata, razmjenu poruka među agentima i pokretljivost agenata u prostoru. *AnyLogic* je alat koji se u zadnje vrijeme sve više koristi kod provođenja istraživanja temeljenih na višeagentskim sustavima pri čemu omogućuje ostvarivanje višeagentske platforme na temelju definiranog modela višeagentskog sustava. Pruža mogućnost ostvarivanja modela višeagentkog sustava pomoću višemetodnog modeliranja koje uključuje modeliranje diskretnih događaja, višeagentsko modeliranje i modeliranje dinamike sustava [94]. Ovaj rad koristi *AnyLogic* kao okruženje za razvoj i ostvarivanje modela višeagentskog sustava za usmjeravanje električnih vozila.

U radu [95] definiran je višeagentski model električnih vozila koji pomoću razvojnog okruženja TEEMA ostvaruje višeagentsku platformu. Definirana višeagentska platforma koristi se za izvođenje simulacija opterećenja električnih vozila na javnu mrežu električne energije zbog povećavanja ili smanjivanja broja izvršenih punjenja na električnim punionicama. Provode se dva tipa scenarija u višeagentskoj platformi. Prvi scenarij provodi kontrolirano korištenje električnih punionica pomoću zakazivanja punjenja električnog vozila u točno određeno vrijeme. Drugi tip simulacije ne kontrolira način korištenja električnih vozila, nego električna vozila obavljaju punjenje nasumično. Model višeagentskog sustava ne uključuje agente električnih vozila i električnih punionica, nego agente koji predstavljaju izvore opterećenja na mrežu električne energije. Svakom agentu *izvor* dodijeljen je skup električnih vozila koja se uzimaju u obzir u definiranom algoritmu za opterećenje. Slična upotreba MAS-a prikazana je u radu [96], gdje se ostvarena višeagentska platforma koristi za provođenje različitih simulacija potražnje električne energije na tržištu. Ostvareni MAS sastoji se od agenata vezanih uz tržište električne energije, pri čemu je uključen i model agenta za električno vozilo. Ostali modeli agenata definirani su za potražnju energije, ponuđača energije i koordinatora za razmjenu energije. Novija istraživanja počinju uključivati upotrebu višeagentskih sustava u rješavanju problema usmjeravanja električnih vozila. Rad [97] prikazuje upotrebu MAS-a za ostvarivanje optimizacije usmjeravanja električnih vozila u lancu opskrbe. Definirani model MAS-a uključuje skup agenata *električno vozilo* i skup agenata *kupac*. Dobiveni model MAS-a koristi se metodom višeagentskog pojačanoga učenja (eng. *multi-agent reinforcement learning (MARL)*) za donošenje odluka o usmjeravanju agenta *električno vozilo* na temelju zahtjeva agenta *kupac* te nije ostvaren u obliku platforme kojom bi se omogućilo provođenje simulacija različitih uporabnih scenarija.

2.3Osvrt i prijedlog rješenja

E-VRP predstavlja proširenje klasičnoga VRP-a s uključivanjem električnih vozila koja se klasificiraju u nekoliko kategorija. Pregled odabranih poglavlja predstavljen u poglavlju 2.1 ukazuje na sve veću primjenu E-VRP-a u sustavima i procesima vezanim uz urbane sredine, posebno za uslužne djelatnosti, prijevoz robe i ljudi. Rješavanju E-VRP-a može se pristupiti na centralizirani način pri čemu se usmjeravanje električnih vozila odvija iz centralne točke, poput spremišta vozila ili centrale, te naznačuje potrebu definiranja faze planiranja i faze izvršavanja usmjeravanja električnih vozila. Raspodijeljeni pristup u rješavanju EVRP-a definira korištenje višeagentskog sustava kojim se postiže bolja reakcija na novonastale neželjene čimbenike tijekom provođenja usmjeravanja vozila (npr. gužve u prometu).

Višeagentski sustav za kontekstno usmjeravanje električnih vozila istražen je u različitim istraživačkim radovima u poglavlju 2.2, na temelju kojih se mogu donijeti zaključci. Pregledom istraživačkih radova vezanih uz definiranje modela višeagentskog sustava za usmjeravanje električnih vozila koji uključuje entitete električnog vozila, električne punionice i spremišta vozila, zaključeno je da postoji mali broj definicija takvih modela koje u većini slučajeva ne uzimaju u obzir sve navedene entitete i usko su specificirani za određenu domenu poslovanja. Prema tome potrebno je definirati generički model višeagentskog sustava za usmjeravanje električnih vozila koji je uz užu specifikaciju električnog vozila primjenjiv na različite domene korištene za usmjeravanje električnih vozila. Usmjeravanje električnih vozila mora se koristiti algoritmima za izradu plana usmjeravanja i algoritmima za izvršavanje usmjeravanja prema definiranom planu. Pregledom istraživanja utvrđen je manji broj onih koja uključuju modele umjetne inteligencije za predviđanje korištenja električnih punionica i potrebe odredišta na temelju povijesnih podataka i kontekstnih podataka, kao što su mjesta od značaja i vremenska prognoza. Štoviše, povezana istraživanja ukazuju na upotrebu konteksta mjesta od značaja radi planiranja i optimizacije infrastrukture električnih punionica, ali ne i za određivanje električne punionice prilikom usmjeravanja električnog vozila prema punionici. Potrebno je definirati modele umjetne inteligencija koji uključuju različite kontekste koji su vezani uz električne punionice i odredišta prema kojima se vozila usmjeravaju za ostvarivanje algoritama za kontekstno usmjeravanja električnih vozila. Isto tako, potrebno je definirati novu mjeru vezanu uz korištenje električnih punionica i resursa na odredištu koja opisuje iskoristivost električnih punionica i resursa na odredištu. Definirana mjera iskoristivosti predmet je predviđanja modela umjetne inteligencije čija se vrijednost može upotrebljavati u algoritmima za usmjeravanje električnih vozila. Pregled povezanih istraživanja ukazuje i na mogućnost upotrebe višeagentskog pristupa za ostvarivanje usmjeravanja električnih vozila radi ostvarivanja platforme za provođenje simulacija kako bi se bolje razumjeli definirani višeagentski modeli. Povezanim istraživanjima utvrđeno je kako ne postoji platforma za evaluaciju modela višeagentskog sustava za usmjeravanje električnih vo-

zila koja bi omogućila provođenje simulacija definiranih modela i odredila usporedne analize postupaka usmjeravanja.

Višeagentski sustav za kontekstno usmjeravanje flote električnih vozila predstavljen u radu pruža rješenja za identificirane probleme tijekom pregleda povezanih istraživanja:

- *model višeagentskog sustava za usmjeravanje električnih vozila* - model višeagentskog sustava za usmjeravanje električnih vozila sastoji se od agenata koji reprezentiraju pokretne entitete – *električna vozila* te stacionarne entitete – *električne punionice* i *spremišta vozila*, njihova obilježja i međusobne odnose;
- *postupci za kontekstno usmjeravanje električnih vozila* - definirani višeagentski sustav za usmjeravanje električnih vozila omogućuje korištenje osnovnih algoritama i algoritama zasnovanim na umjetnoj inteligenciji za usmjeravanje električnih vozila gdje se algoritmi zasnovani na umjetnoj inteligenciji koriste kontekstnim informacijama vremenske prognoze i mjesta od značaja;
- *predviđanje mjere iskoristivosti električnih punionica* - algoritmi zasnovani na umjetnoj inteligenciji koriste se modelima umjetne inteligencije za predviđanje mjere iskoristivosti električnih punionica koja preciznije definira udio iskorištenih resursa električne punionice unutar određenog razdoblja;
- *višeagentska platforma za vrednovanje višeagentskih modela za usmjeravanje flote električnih vozila* - definirani višeagentski sustav za kontekstno usmjeravanje električnih vozila ostvaren je u obliku višeagentske platforme za simulaciju transportnog sustava flote električnih vozila koja omogućuje vrednovanje postupaka usmjeravanja pri promjeni kontekstnih uvjeta;
- *usporedna analiza postupaka usmjeravanja* - Višeagentska platforma za simulaciju transportnog sustava flote električnih vozila omogućuje usporednu analizu osnovnih postupaka usmjeravanja i postupaka usmjeravanja u definiranim kontekstnim uvjetima kroz funkcijsku i tehno-ekonomsku analizu.

Cilj je ovog rada izrada modela višeagentskog sustava za usmjeravanje električnih vozila s postupcima kontekstnog usmjeravanja za ostvarivanje višeagentske platforme za simulaciju transportnog sustava flote električnih vozila kojom je omogućeno vrednovanje postupaka usmjeravanja pri promjeni kontekstnih uvjeta te usporedna analiza postupaka usmjeravanja u definiranim kontekstnim uvjetima. Za ostvarivanje cilja rada prvo se definira model višeagentskog sustava za usmjeravanje električnih vozila koji se sastoji od pokretnih i stacionarnih agenata te određuje njihova obilježja i međusobne odnose (poglavlje 3). Nakon toga definiraju se osnovni i kontekstni postupci usmjeravanja električnih vozila (poglavlje 4). Završno se ostvaruje platforma za simulaciju transportnog sustava flote električnih vozila na temelju modela višeagentkog sustava električnih vozila s osnovnim i kontekstnim postupcima usmjeravanja (poglavlje 5).

Poglavlje 3

Model višeagentskog sustava za usmjeravanje električnih vozila

U ovom poglavlju opisuje se model višeagentskog sustava za usmjeravanje električnih vozila. Model višeagentskog sustava za usmjeravanje električnih vozila ostvaruje se korištenjem višemetodnog modeliranja koje uključuje pristup višeagentskog modeliranja i pristup modeliranja diskretnih događaja. Ovakav pristup modeliranju uzima u obzir svu potrebnu dinamiku, složenost i različitost istraživačkih izazova s ciljem njihova rješavanja. Ostvareni pristup modeliranju prikladan je za proučavanje različitih sustava iz stvarnog svijeta radi provođenja istraživanja koja uključuju empirijsko razumijevanje, normativni dizajn, kvalitativni uvid, kao i optimizaciju pristupa, metoda i procesa [98].

Ostatak poglavlja ima sljedeću strukturu: odjeljk 3.1 predstavlja model *višeagentskog sustava za usmjeravanje električnih vozila* (VAS-UEV) koji se sastoji od pokretnih i stacionarnih agenata. Pokretni agenti mogu se kretati u prostoru a cilj im je izvršavanje zadataka i radnji, dok su stacionarni agenti definirani svojom statičkom geolokacijom u prostoru gdje pružaju usluge za koje su namijenjeni. U odjeljku 3.2 opisani su svi pokretni agenti, pri čemu model VAS-UEV upotrebljava samo jedan tip pokretnog agenta, a to je električno vozilo. Odjeljak 3.3 donosi opis svih stacionarnih agenata koje model VAS-UEV upotrebljava, a to su električna punionica, spremište vozila i parkiralište.

3.1Pregled višeagentskog sustava

Slika 3.1 prikazuje model višeagentskog sustava za usmjeravanje električnih vozila (VAS-UEV), kao sljedeći skup agenata:

$$VAS = \begin{cases} A_p : \{FLOTA\} \\ A_s : \{SV, EP, P\} \end{cases} \tag{3.1}$$

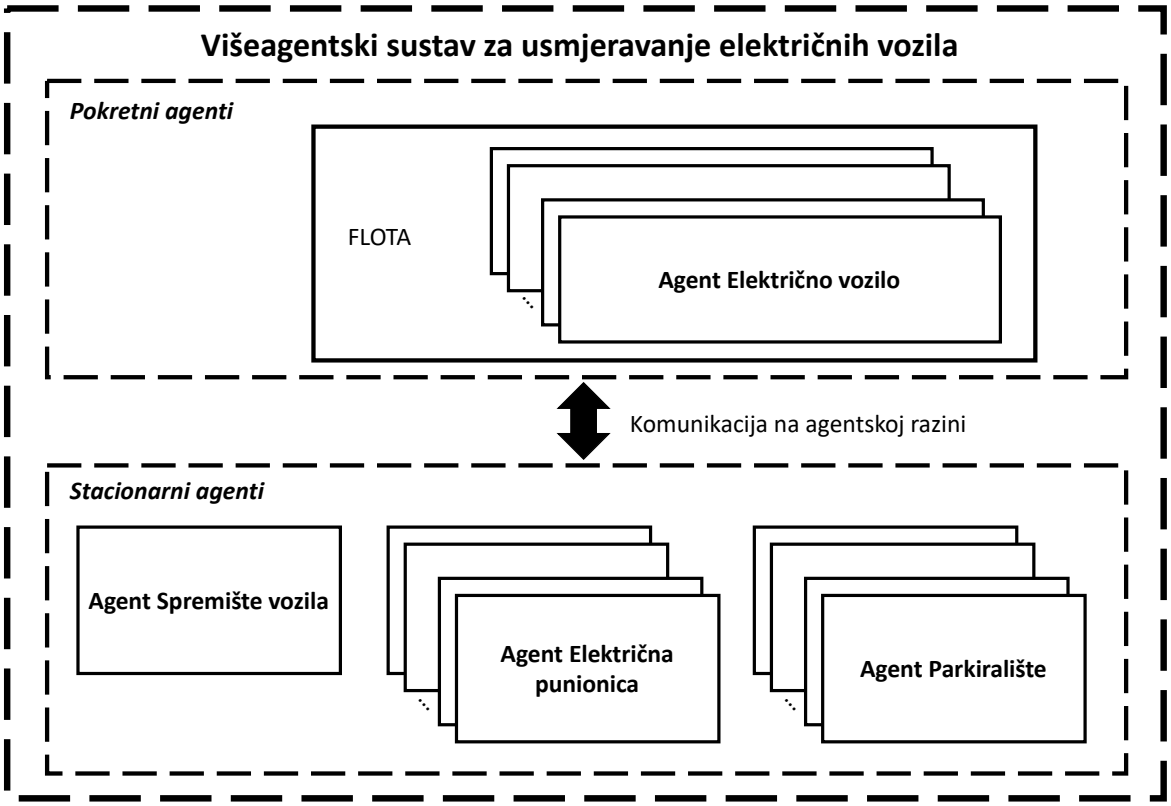

Slika 3.1: Model višeagentskog sustava za usmjeravanje električnih vozila (VAS-UEV)

gdje A_p predstavlja skup pokretnih agenata u modelu VAS-UEV, a A_s predstavlja skup stacionarnih agenata u modelu VAS-UEV. Skup pokretnih agenata A_p sastoji se od flote vozila $FLOTA$ koja predstavlja homogeni skup agenata *Električnog vozila (EV)*, dok skup stacionarnih agenata A_s se sastoji od agenata *Električne punionice (EP)*, *Spremišta vozila (SV)* i *Parkirališta (P)*. Model VAS-UEV ostvaren je pomoću alata AnyLogic* koji može izraditi višeagentski sustav koristeći se višeagentskim modeliranjem i modeliranjem zasnovanim na diskretnim događajima.

3.2Pokretni agenti

Model VAS-UEV sadrži skupinu pokretnih agenata A_p koji se usmjeravaju u prostoru prema definiranoj geolokaciji na karti kako bi obavili određeni zadatak. Pokretni agenti A_p u modelu VAS-UEV definiraju se na sljedeći način:

$$A_p = \{EV^{(1)}, EV^{(2)}, ..., EV^{(i)}\} \tag{3.2}$$

*AnyLogic - alat za višemetodno modeliranje višeagentskih sustava: https://www.anylogic.com/use-of-simulation/multimethod-modeling/

gdje *i* predstavlja broj agenata *Električnog vozila* (EV) iz flote $FLOTA$. Flota vozila mora sadržavati najmanje jedno električno vozilo, dok maksimalni broj vozila može biti proizvoljan, a na taj je način određen i broj agenata EV. Sva vozila unutar flote jednakih su karakteristika i svojstava te time čine homogeni skup vozila koja se upotrebljavaju za usmjeravanje u višeagentskom sustavu. Za potrebe modela VAS-UEV upotrebljava se električna čistilica koja čisti gradske parkirališne prostor te predstavlja specifikaciju EV-agenta.

3.2.1Agent Elektri čno vozilo

Agent Električno vozilo (EV) predstavlja apstrakciju električnog vozila definirajući pritom osnovni okvir koji proširenjem omogućuje usko specificiranje samog električnog vozila. Slika 3.2 prikazuje model agenta EV koji se definira na sljedeći način:

$$EV = \{SV, DV, S_B, S_{EV}\} \tag{3.3}$$

gdje SV predstavlja statičke varijable koje predstavljaju predefinirane vrijednosti specifične za samo električno vozilo, dok DV predstavlja dinamičke varijable koje nakon početne inicijalizacije mijenjaju svoju vrijednost tijekom rada električnog vozila. Agent EV definiran je i skupom stanja u kojima se agent može nalaziti, pa tako S_{EV} predstavlja skup stanja koja su povezana s upotrebom električnog vozila, dok je S_B skup stanja povezan uz upotrebu baterije električnog vozila.

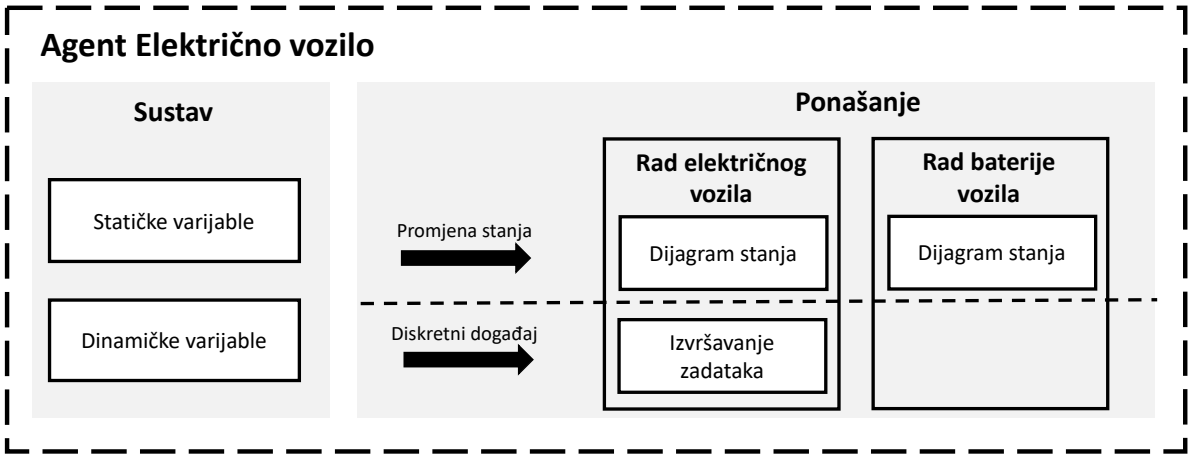

Slika 3.2: Model agenta Električno vozilo

Statičke varijable

Statičke varijable (SV) agenta *Električno vozilo* (EV) definiraju se na sljedeći način:

$$SV^{\{EV\}} = \{id, PM_{EV}, Wh_{BEV}, C_{BEV}, D_{EV}\} \tag{3.4}$$

gdje varijabla *id* predstavlja jedinstveni identifikator vozila unutar flote i on je u većini slučajeva u stvarnom svijetu jednak broju šasije vozila. Svako električno vozilo posjeduje motor koji ima definiranu jačinu iskazanu u kilovatima (kW) te je ta vrijednost opisana statičkom varijablom PM_{EV}. Električno vozilo mora imati bateriju koja je izvor energije za pokretanje motora električnog vozila te ima zadani kapacitet koji je iskazan statičkom varijablom C_{BEV}, dok varijabla D_{EV} definira udaljenost koju vozilo može postići s punom baterijom. Statička varijabla Wh_{BEV} određuje broj operativnih sati koje električno vozilo može pružiti tijekom rada bez potrebe za punjenjem.

Dinamičke varijable

Dinamičke varijable (DV) agenta *Električno vozilo* (EV) definiraju se na sljedeći način:

$$DV^{\{EV\}} = \{R_{BEV}, Z_{EV}, P_{EV}\} \tag{3.5}$$

gdje R_{BEV} predstavlja trenutačnu razinu električne energije u bateriji iskazanu u postocima. Svaki agent EV obavlja određeni zadatak koji mu je dodijeljen. Varijabla Z_{EV} predstavlja trenutačno dodijeljeni zadatak koje vozilo izvršava te po završetku dodijeljenog zadatka agent EV traži sljedeći zadatak koji će se postaviti u varijablu Z_{EV} i s kojim se kreće u izvršavanje. Prilikom rada električnog vozila, baterija električnog vozila prazni se te kad se postigne određena razina baterije iskazane varijablom R_{BEV}, agent EV zahtijeva od agenta *Spremište vozila* dodjelu električne punionice. Dodijeljena električna punionica postavlja se u varijablu P_{EV} te se agent EV na temelju spomenute varijable usmjerava prema električnoj punionici gdje će obaviti punjenje baterije.

Model rada baterije

Ponašanje agenta EV sastoji se od modela *rada baterije* (RB) i modela *rada električnog vozila* (REV). Model RB prikazan na slici 3.3 sastoji se od dvaju dijagrama stanja koji definiraju upotrebu baterije električnog vozila. Dijagram stanja *battery_statechart* na slici 3.3 predstavlja rad same baterije električnog vozila te određuje skup stanja Q_B, dok dijagram stanja *battery_consumption_statechart* na slici 3.3 predstavlja način pražnjenja baterije i definira skup stanja Q_PB. Prema tome, skup stanja modela RB definira skup stanja S_B agenta EV i definira se

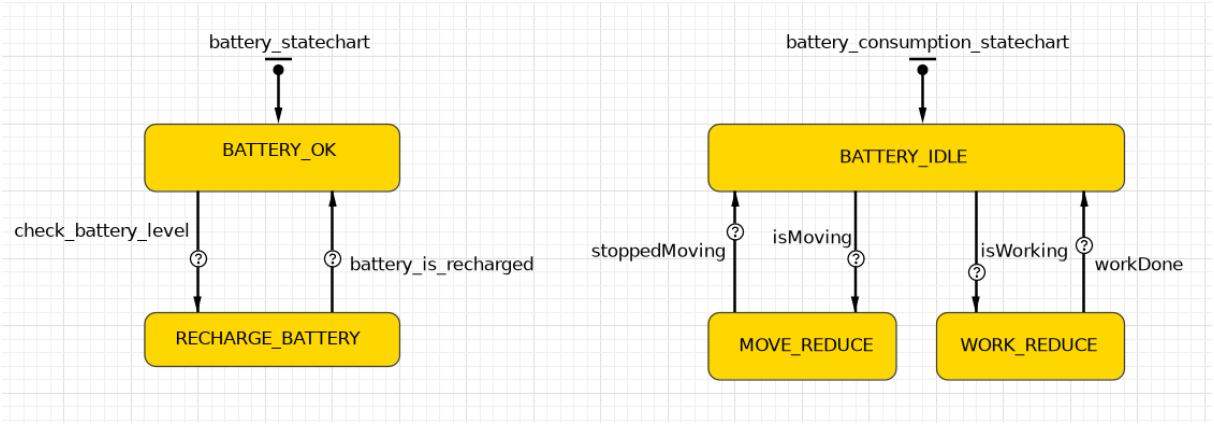

Slika 3.3: Model rada baterije

na sljedeći način:

$$S_B^{\{EV\}} = \{Q_B, Q_{PB}\} \tag{3.6}$$

Skup stanja Q_B vezan je uz rad baterije i definira se na sljedeći način:

$$Q_B^{\{EV\}} = \{BATTERY_OK, RECHARGE_BATTERY\} \tag{3.7}$$

gdje stanje $BATTERY_OK$ označava da je razina električne energije u bateriji zadovoljavajuća, dok stanje $RECHARGE_BATTERY$ ukazuje da je razina električne energije u bateriji pala ispod određene definirane minimalne razine te označava električnom vozilu da je potrebno punjenje na električnoj punionici. Skup stanja Q_{PB} vezan uz način potrošnje baterije električnog vozila sastoji se od dijela koji definira pražnjenje uzrokovano kretanjem vozila i dijela koji definira pražnjenje uzrokovano radom vozila nad zadanim zadatkom, a definira se na sljedeći način:

$$Q_{PB}^{\{EV\}} = \{BATTERY_IDLE, MOVE_REDUCE, WORK_REDUCE\} \tag{3.8}$$

gdje stanje $BATTERY_IDLE$ označava da električno vozilo miruje i da se ne ostvaruje nikakvo pražnjenje baterije, dok stanje $MOVE_REDUCE$ implementira funkciju pražnjenja baterije uzrokovano kretanjem električnog vozila, a stanje $WORK_REDUCE$ implementira funkciju pražnjenja baterije na temelju rada koje električno vozilo obavlja.

Model rada električnog vozila

Model *rada električnog vozila* (REV) prikazan na slici 3.4 modelira ponašanje električnog vozila pomoću dijagrama stanja *electric_vehcile_statechart* koji definira skup stanja S_{EV} agenta EV. Skup stanja modela REV definiran je na sljedeći način:

$$S_{EV}^{\{EV\}} = \{Q_{EVZ}, Q_{EVP}\} \tag{3.9}$$

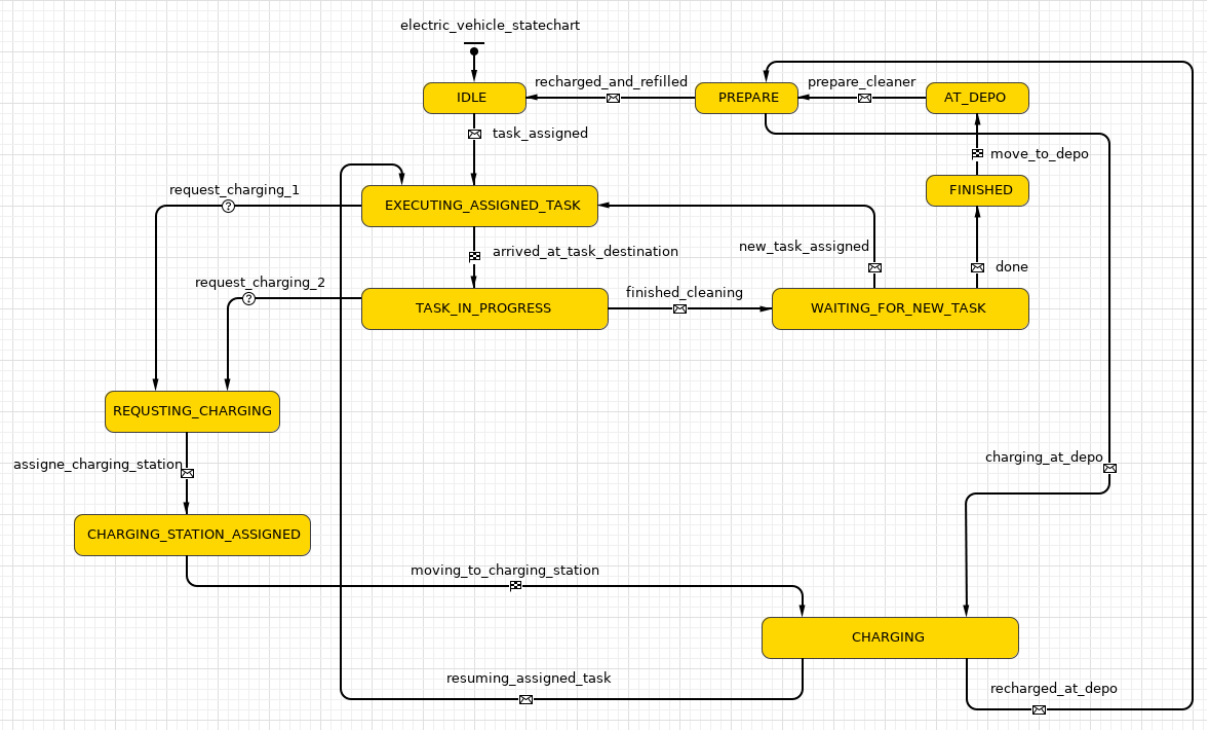

Slika 3.4: Model rada električnog vozila

gdje je skup stanja Q_{EVZ} povezan uz obavljanje dodijeljenog zadatka, dok je Q_{EVP} skup stanja povezan uz radnje punjenja baterije električnog vozila na električnoj punionici. Skup stanja Q_{EVZ} sastoji se od sedam stanja definiranih na sljedeći način:

$$Q_{EVZ}^{\{EV\}} = \{Q_{EVZ}^{(0)}, Q_{EVZ}^{(1)}, Q_{EVZ}^{(2)}, Q_{EVZ}^{(3)}, Q_{EVZ}^{(4)}, Q_{EVZ}^{(5)}, Q_{EVZ}^{(6)}\} \tag{3.10}$$

gdje je opis navedenih stanja prikazan u tablici 3.1. Skup stanja Q_P sastoji se od triju stanja definiranih na sljedeći način:

$$Q_{EVP}^{\{EV\}} = \{Q_{EVP}^{(0)}, Q_{EVP}^{(1)}, Q_{EVP}^{(2)}\} \tag{3.11}$$

čiji je opis prikazan tablicom 3.1. Ovime se definira model agenta EV koji predstavlja apstrakciju električnog vozila. Proširenjem modela agenta EV dodavanjem novih statičkih ili dinamičkih varijabli, ili dodavanjem novih obrazaca ponašanja čime se povećava skup stanja samog EV-agenta, može se ostvariti agent za usko specijalizirano električno vozilo s posebnom namjenom kao što je gradska električna čistilica za čišćenje gradskih površina ili gradski električni autobus za prijevoz putnika.

Agent EV tijekom svog rada mora imati sposobnost obrade diskretnih događaja povezanih s dodjelom zadataka agenta *Spremište vozila* (SV). Pomoću modeliranja diskretnih događaja definira se proces izvršavanja zadataka agenta EV prikazanog na slici 3.5. Zadatak definira agent SV koji u određenom trenutku dodijeli zadatak električnom vozilu tako da ga pošalje

agentu EV. Opis komunikacije između agenta EV i agenta SV prikazuje se u poglavlju 3.4. U trenutku zaprimanja zadatka od agenta SV, pokreće se proces izvršavanja zadataka agenta

Tablica 3.1: Opis stanja modela rada električnog vozila

Stanje	Naziv stanja	Opis stanja
$Q_{EVZ}^{(0)}$	IDLE	Početno stanje agenta EV, kad je vozilo u stanju mirovanja i spremno za izvršavanje zadataka.
$Q_{EVZ}^{(1)}$	EXECUTING_ASSIGNED_TASK	Agentu EV dodijeljen je zadatak koji mora izvršiti te se usmjerava prema geolokaciji zadanog zadatka.
$Q_{EVZ}^{(2)}$	TASK_IN_PROCESSING	Dolaskom na odredište dodijeljenog zadatka, agent EV kreće s odrađivanjem zadatka.
$Q_{EVZ}^{(3)}$	WAITING_FOR_NEW_TASK	Završetkom dodijeljenog zadatka, agent EV u stanju je mirovanja i čeka dodjelu novog zadatka.
$Q_{EVZ}^{(4)}$	FINISHED	Agent EV završio je sa svim zadacima te se usmjerava prema geolokaciji spremišta vozila.
$Q_{EVZ}^{(5)}$	AT_DEPO	Agent EV nalazi se na geolokaciji spremišta vozila i čeka na proces pripreme i održavanja za sljedeći ciklus izvršavanja zadataka.
$Q_{EVZ}^{(6)}$	PREPARE	Agent EV obavlja u spremištu vozila pripremu i održavanje za sljedeći ciklus obavljanja zadataka. Završetkom agent EV označava da je spreman za izvršavanje novih zadataka i prelazi u početno stanje.
$Q_{EVP}^{(0)}$	REQUESTING_CHARGING	Agent EV zahtijeva od spremišta vozila da mu se dodijeli električna punionica za punjenje baterije.
$Q_{EVP}^{(1)}$	CHARGING_STATION_ASSIGNED	Spremište vozila dodjeljuje agentu EV električnu punionicu prema kojoj se agent EV usmjerava
$Q_{EVP}^{(2)}$	CHARGING	Dolaskom na dodijeljenu električnu punionicu, EV-agent započinje proces punjenja baterije te se nalazi u ovome stanju sve do završetka samog procesa punjenja baterije.

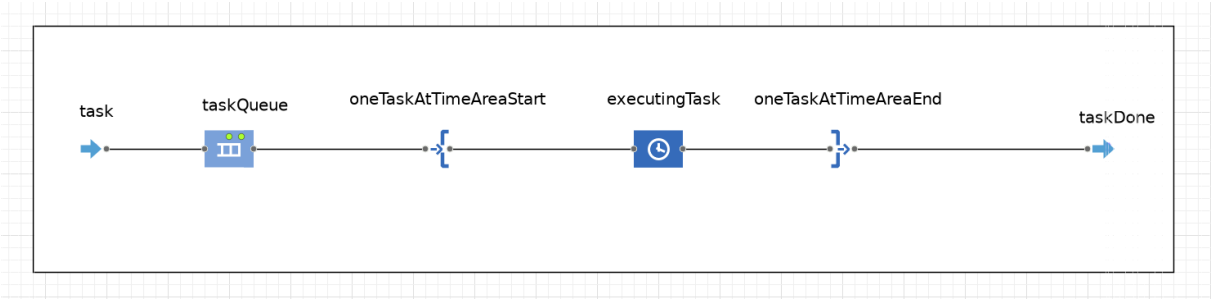

Slika 3.5: Proces izvršavanja zadataka električnog vozila

EV koji zaprima nove zadatke pomoću komponente *task*. Proces svaki zaprimljeni zadatak stavlja u red čekanja *taskQueue* za izvršavanje. Električno vozilo istovremeno može izvršavati samo jedan zadatak, što je u procesu definirano komponentama *oneTaskAtTimeAreaStart* i *oneTaskAtTimeAreaEnd* koje definiraju blok za izvršavanje zadataka s kapacitetom jedan. Unutar bloka za izvršavanje nalazi se element *executingTask* koji implementira na funkciju izvršavanja zadatka. Po završetku izvršavanja zadatka, proces prosljeđuje izvršeni zadatak u element *taskDone* koji obavještava agenta SV da je EV-agent uspješno izvršio dodijeljeni zadatak.

3.2.2Agent Elektri čna čistilica

Agent Električna čistilica (EC) jest proširenje ili uža specifikacija prethodno opisanog agenta *Električno vozilo* (EV) koji predstavlja osnovni okvir električnog vozila. Slika 3.6 prikazuje model agenta EC-a definiranog na sljedeći način:

$$EC = \{SV, DV, S_{SV}, S_{EC}\} \cup EV \tag{3.12}$$

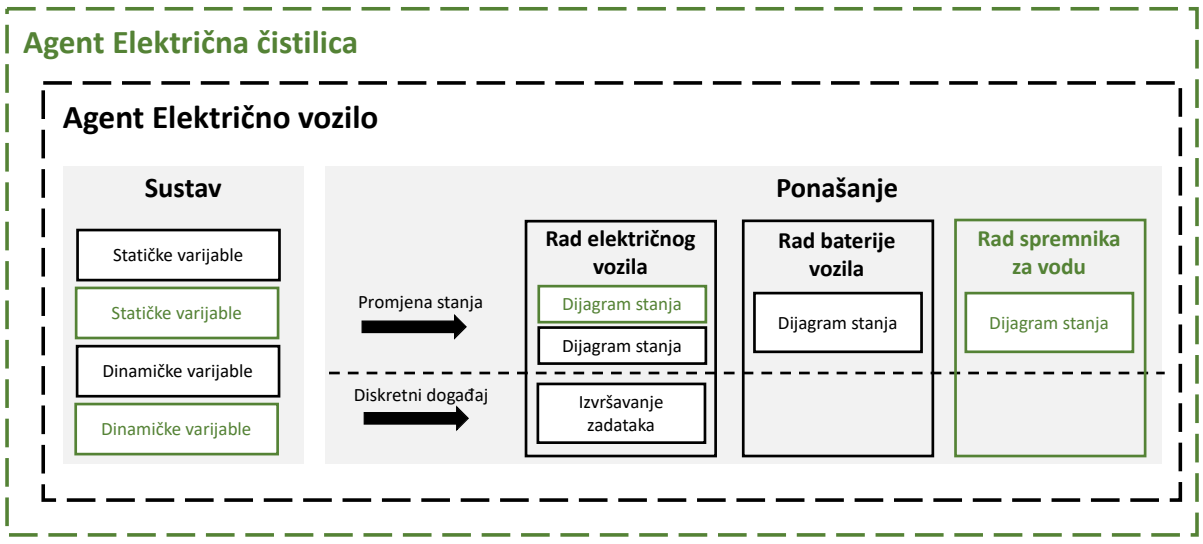

Slika 3.6: Model agenta Električna čistilica

gdje *SV* označava proširenje statičkih varijabli agenta EV te *DV* proširenje dinamičkih varijabli u svrhu ostvarivanja agenta EC. Model agenta EC definira se i proširenjem stanja u kojima agent može biti, pa tako uz stanja koja definira agent EV-a dodaje dodatna stanja S_{EC} specifična za rad i uporabu električne čistilice. Dodatno, električna čistilica koristi se spremnikom vode čije se ponašanje definira modelom rada vodenog spremnika te definira dodatan skup stanja S_{SV} agenta EC. Električna čistilica korištena u radu usko se specificira za obavljanje čišćenja gradskih parkirališnih površina.

Statičke varijable

Statičke varijable (SV) agenta EC jesu proširenje statičkih varijabli agenta EV te su definirane na sljedeći način:

$$SV^{\{EC\}} = \{PV_{EC}, PCU_{EC}, CV_{EC}\} \cup SV^{\{EV\}} \tag{3.13}$$

gdje varijabla PV_{EC} označava jačinu motora ventilatora, a varijabla PCU_{EC} označava jačinu motora četke i usisivača električne čistilice, a obje su varijable iskazane u kilovatima (kW). Električna čistilica za potrebe čišćenja koristi se spremnikom za vodu koji ima određeni kapacitet definiran varijablom CV_{EC}.

Dinamičke varijable

Dinamičke varijable (DV) agenta EC jesu proširenje dinamičkih varijabli agenta EV te su definirane na sljedeći način:

$$DV^{\{EC\}} = \{R_v, I_p\} \cup DV^{\{EV\}} \tag{3.14}$$

gdje varijabla R_v označava trenutačnu razinu spremnika za vodu iskazanu u postocima te se upotrebljava u modelu ponašanja vodenog spremnika. Model ponašanja vodenog spremnika postavlja varijablu I_p i označava agentu EC da je potrebna nadopuna spremnika za vodu te da se agent EC mora usmjeriti prema spremištu vozila gdje može obaviti nadopunu vodom. Model ponašanja vodenog spremnika postavlja varijablu I_p u trenutku kad varijabla R_v bude jednaka nuli. U tom trenutku električna čistilica ne može više obavljati zadaću čišćenja i mora obaviti nadopunu vodenog spremnika.

Model rada spremnika za vodu

Agent EC za potrebe čišćenja gradskih parkirališnih površina koristi se spremnikom za vodu čiji rad se definira modelom *rada spremnika za vodu* (RSV). RSV-model prikazuje se na slici 3.7 te se sastoji od dvaju dijagrama stanja koji definiraju skup stanja S_{SV} agenta EC. Dijagram stanja *water_tank_statechart* opisuje rad spremnika za vodu i definira skup stanja Q_{SV}, dok dijagram stanja *water_tank_consumption_statechart* opisuje način potrošnje vode iz spremnika za vodu

te definira skup stanja Q_{PSV}. Prema tome skup stanja S_{SV} modela RSV definira se na sljedeći način:

$$S_{SV}^{\{EC\}} = \{Q_{SV}, Q_{PSV}\} \tag{3.15}$$

Skup stanja vodenog spremnika Q_{SV} definira se sa sljedećim stanjima:

$$Q_{SV}^{\{EC\}} = \{WATER_TANK_OK, REFILL_TANK\} \tag{3.16}$$

gdje stanje $WATER_TANK_OK$ označava da u spremniku za vodu ima dovoljno vode potrebne za čišćenje gradskih parkirališnih površina, pri čemu u trenutku pada razine spremnika za vodu na nulu prelazi se u stanje $REFILL_TANK$. Stanje $REFILL_TANK$ označava agentu EC da mora zaustaviti rad na trenutačno dodijeljenom zadatku i da se mora uputiti prema spremištu vozila za obavljanje nadopune spremnika za vodu. Spremnik za vodu u stanju je $REFILL_TANK$ tako dugo dok se spremnik ne napuni do kraja, pri čemu prelazi iz trenutačnog stanja u početno stanje $WATER_TANK_OK$ označavajući agentu EC da može nastaviti s radom na dodijeljenom zadatku.

Skup stanja Q_{PSV} definira se sa sljedećim stanjima:

$$Q_{PSV}^{\{EC\}} = \{WATER_TANK_IDLE, REDUCE_WATER_LEVEL\} \tag{3.17}$$

gdje stanje $WATER_TANK_IDLE$ označava da se agent EC ne koristi spremnikom za vodu te da se razina vode u spremniku ne mijenja. Radom agenta EC na dodijeljenom zadatku koji se koristi vodom iz spremnika za vodu, prelazi se u stanje $REDUCE_WATER_LEVEL$ koje implementira funkciju potrošnje vode iz spremnika za vodu. Prestankom rada agenta EC na dodijeljenom zadatku prelazi se natrag u stanje $WATER_TANK_IDLE$.

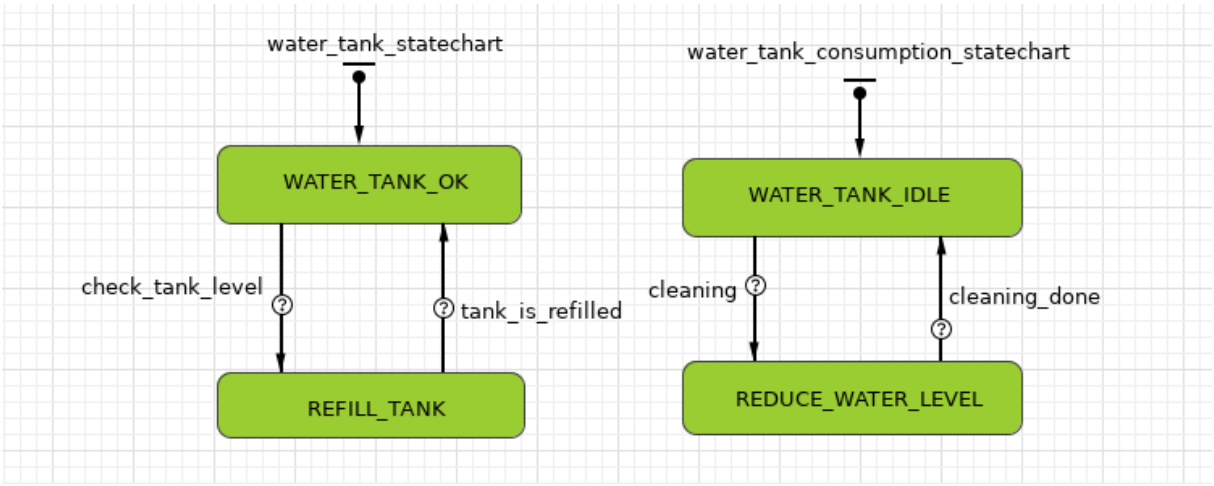

Slika 3.7: Model rada spremnika za vodu

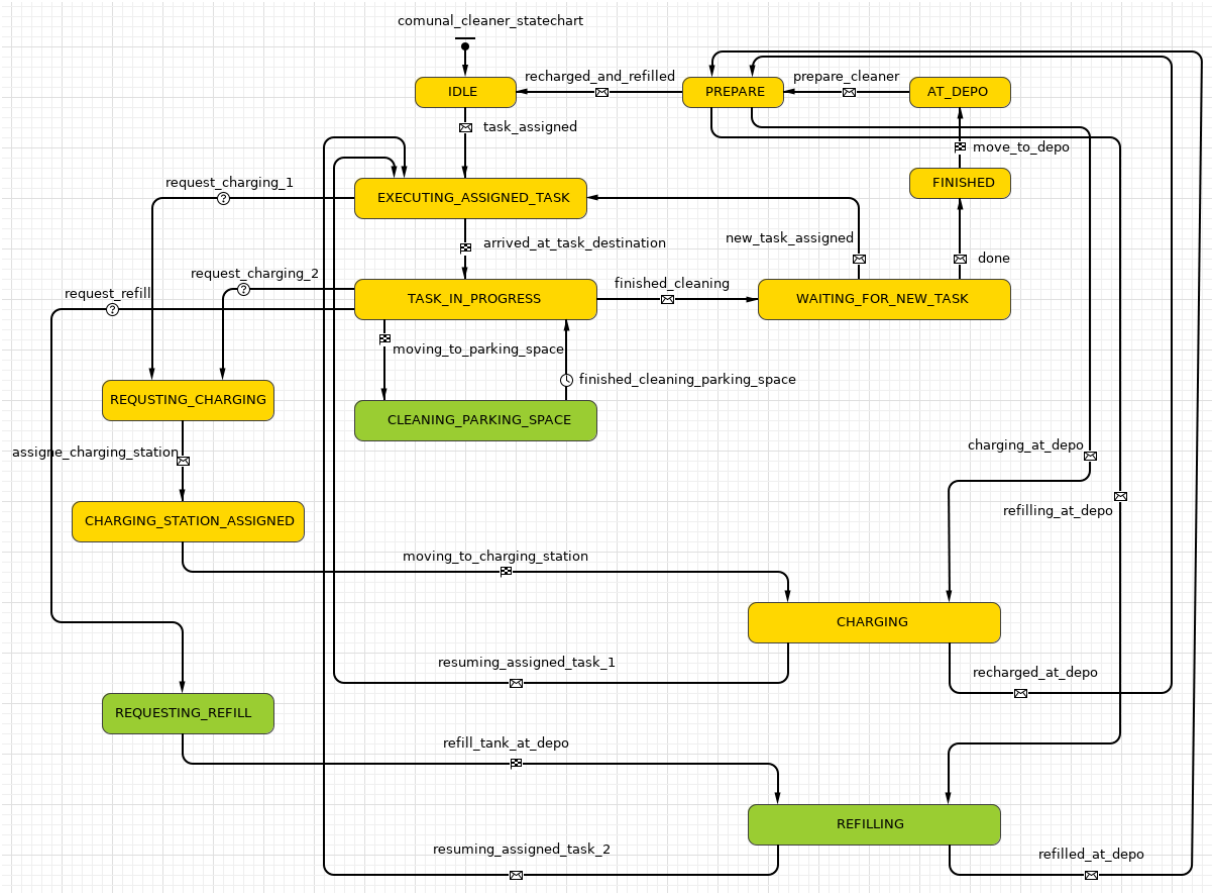

Slika 3.8: Model rada električne čistilice

Model rada električne čistilice

Model *rada električne čistilice* (REC) prikazuje se na slici 3.8 i definira ponašanje električne čistilice kao proširenje modela rada električnog vozila kroz dijagram stanja *communal cleanner statechart*, pri čemu su proširenja povezana za agent EC-a prikazana zelenom bojom na slici 3.8. Dijagram stanja *communal_cleanner_statechart* definira skup stanja S_{EC} agenta EC koji predstavlja proširenje skupa stanja S_{EV} agenta EV definiranog u poglavlju 3.2.1. Skup stanja S_{EC} definira se na sljedeći način:

$$S_{EC}^{\{EC\}} = \{Q_{ECZ}^{(0)}, Q_{ECP}^{(0)}, Q_{ECP}^{(1)}\} \cup S_{EV}^{\{EV\}} \tag{3.18}$$

pri čemu se skup stanja Q_{ECZ} odnosi na dodatna stanja potrebna električnoj čistilici prilikom izvršavanja zadataka povezanih uz čišćenje gradskih parkirališnih površina, dok se skup stanja Q_{ECP} odnosi na proces punjenja vodenog spremnika električne čistilice. Tablica 3.2 opisuje navedena dodatna stanja povezana uz rad električne čistilice, dok su stanja vezana uz rad električnog vozila S_{EV} opisana u tablici 3.1.

Tablica 3.2: Opis stanja modela rada električne čistilice

Stanje	Naziv stanja	Opis stanja
$Q_{ECZ}^{(0)}$	CLEANING_PARKING_SPACE	Stanje specifično za rad električne čistilice koje implementira funkciju čišćenja parkirališnog mjesta električnom čistilicom. Po završetku čišćenja agent EC prelazi u stanje $Q_{EVZ}^{(2)}$.
$Q_{ECP}^{(0)}$	REQUESTING_REFILL	Električna čistilica potrošila je svu vodu iz vodenog spremnika i usmjerava se prema spremištu vozila zbog punjenja vodenog spremnika.
$Q_{ECP}^{(1)}$	REFILLING	Električna čistilica dolaskom u spremište vozila započinje punjenje vodenog spremnika i po završetku nastavlja s obavljanjem dodijeljenog zadatka te agent EC prelazi u stanje $Q_{EVZ}^{(1)}$.

3.3Stacionarni agenti

Model VAS-UEV sadrži skupinu stacionarnih agenata A_s koji se nalaze na definiranoj geolokaciji i ne usmjeravaju se u prostoru te pružaju usluge drugim agentima. Stacionarni agenti A_s u modelu VAS-UEV definiraju se na sljedeći način:

$$A_s = \{SV, EP^{(1)}, ..., EP^{(i)}, P^{(1)}, ..., P^{(j)}\} \tag{3.19}$$

gdje *i* predstavlja broj agenata *Električna punionica* (*EP*), *j* predstavlja broj agenata *Parkiralište* (*P*), a *SV* označava agenta *Spremište vozila*. Model VAS-UEV uzima u obzir samo jedno spremište vozila. Broj agenata za električne punionice i parkirališta u modelu VAS-UEV definira se proizvoljno te se može definirati najmanje jedan agent EP ili agent P, dok maksimalni broj agenata ostaje proizvoljan. Stacionarni agent P uvodi se zbog uže specifikacije agenata EV, a to je agent EC opisan u poglavlju 3.2.2, koji je specijaliziran za čišćenje gradskih parkirališnih površina.

3.3.1Agent Elektri čna punionica

Model agenta *Električna punionica* (EP) prikazuje se na slici 3.9. Agent EP definira se skupom statičkih varijabli koje se ne mijenjaju tijekom rada agenta. Definirani model agenta EP ne uključuje nikakve dinamičke varijable. Ponašanje agenta EP definira se modelom rada električne punionice i modelom rada priključka (eng. *electric vehicle supply equipment (EVSE)*).

Električna punionica može imati jedan ili više jednakih ili različitih priključaka za punjenje električnih vozila, pri čemu se priključci razlikuju po tipu (AC ili DC), brzini punjenja (brzo ili sporo) i standardu (definira tip utičnice). Model agenta EP definira se na sljedeći način:

$$EP = \{SV, S_{EP}, S_{EVSE}\} \tag{3.20}$$

gdje SV predstavlja skup statičkih varijabli za električnu punionicu koje se ne mijenjaju tijekom vremena. Stanja električne punionice opisana su skupom stanja S_{EP} koji se odnose na rad električne punionice te skupom stanja S_{EVSE} koja se odnose na rad priključaka električne punionice.

Statičke varijable

Statičke varijable SV agenta EP definirane su na sljedeći način:

$$SV^{\{EP\}} = \{id, ime, lat, lng, lista_{EVSE}\} \tag{3.21}$$

gdje *id* predstavlja jedinstveni identifikator električne punionice, *ime* predstavlja ime same električne punionice, dok je varijablama *lat* i *lng* definirana geolokacija električne punionice na karti. Varijabla *lat* predstavlja geografsku širinu, dok *lng* predstavlja geografsku dužinu. Priključci koji su dostupni kod električne punionice definirani su u listi $lista_{EVSE}$. U modelu agenta EP svaki priključak $EVSE$ definira se s dodatnim varijablama na sljedeći način:

$$EVSE^{\{EP\}} = \{id, S_{EVSE}, F_{EVSE}, TP_{EVSE}\} \tag{3.22}$$

gdje *id* predstavlja jedinstveni identifikator priključka, dok ostale varijable opisuju svojstva samog priključka. Varijablom S_{EVSE} definira se standard koji priključak upotrebljava i može

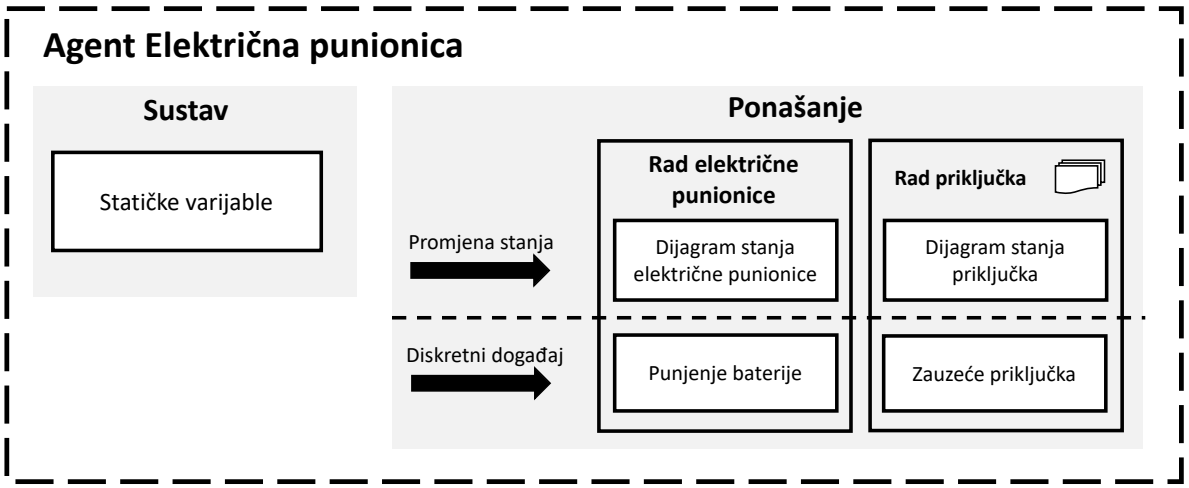

Slika 3.9: Model agenta Električna punionica

biti jedan od: *IEC 62196 T2*, *CHADEMO*, *IEC 62196 T2 COMBO*, *DOMESTIC G*. Format priključka može biti utičnica ili kabel te se definira varijablom F_{EVSE}. Tip snage priključka, a samim time i brzina punjenja, definira se varijablom TP_{EVSE}, definirajući pri tome jednu od sljedećih vrijednosti: *AC 1 PHASE* (sporo punjenje), *AC 3 PHASE* (brzo punjenje), *DC* (vrlo brzo punjenje).

Model rada priključka

Model *rada priključka* (RP) prikazuje se na slici 3.10. Model RP definira se dijagramom stanja *evse_statechart* koji definira skup stanja S_{EVSE} EP-agenta. Skup stanja S_{EVSE} definira se na sljedeći način:

$$S_{EVSE}^{\{EVSE^{\{EP\}}\}} = \{AVAILABLE, OCCUPIED, IN_USE\} \tag{3.23}$$

Stanje *AVAILABLE* označava da je priključak električne punionice dostupan za korištenje električnom vozilu. Kad se električno vozilo uključi na priključak, pri čemu još ne započne punjenje, priključak prelazi u stanje *OCCUPIED*. U trenutku kad započne punjenje električnog vozila, priključak prelazi u stanje *IN_USE*. Po završetku punjenja električnog vozila, priključak ponovno postaje dostupan i prelazi u stanje *AVAILABLE*.

Model RP uključuje proces *zauzeća priključka* (ZP) električne punionice prikazanog na slici 3.11 kojim se definira dostupnost pojedinog priključka. Dolazak zahtjeva za punjenje definira diskretan događaj koji pokreće ZP-proces koji na ulaznu komponentu *chargingEvent* prihvaća zahtjev za punjenje na određenom priključku. Nakon toga zahtjev za punjenje prosljeđuje se

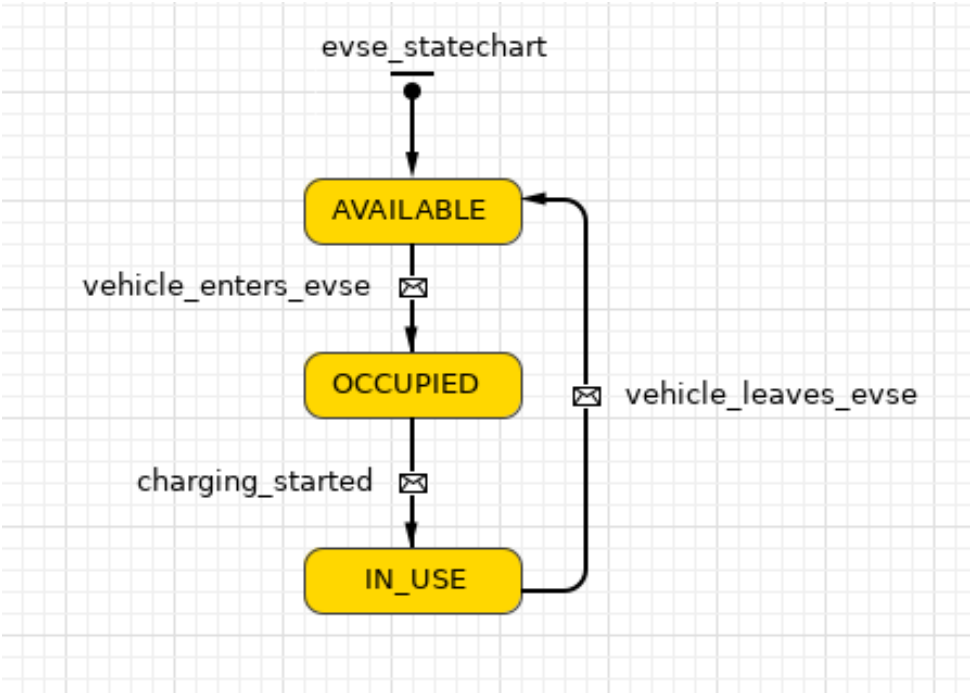

Slika 3.10: Model rada priključka

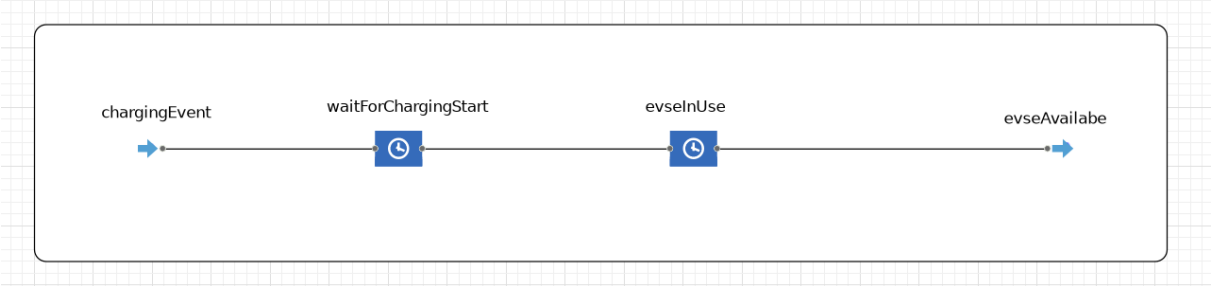

Slika 3.11: Model procesa zauzeća priključka električne punionice

u blok *waitEorChargingStart* koji implementira funkciju za početak upotrebe priključka. Po početku punjenja na priključku, zahtjev za punjenje prosljeđuje se u blok *evseInUse* koji implementira funkciju upotrebe priključka. Završetkom punjenja baterije električnog vozila na priključku, prosljeđuje se zahtjev za punjenje prema izlazu procesa ZP na *evseAvailable*, kojim se označava da je priključak na električnoj punionici ponovno dostupan.

Model rada električne punionice

Model *rada električne punionice* (REP) prikazuje se na slici 3.12 i definira ponašanje električne punionice pomoću dijagrama stanja *evse_statechart*. Dijagram stanja *evse_statechart* definira skup stanja S_{EP} agenta EP na sljedeći način:

$$S_{EP}^{\{EP\}} = \{OPERATIONAL, MAINTENANCE\} \tag{3.24}$$

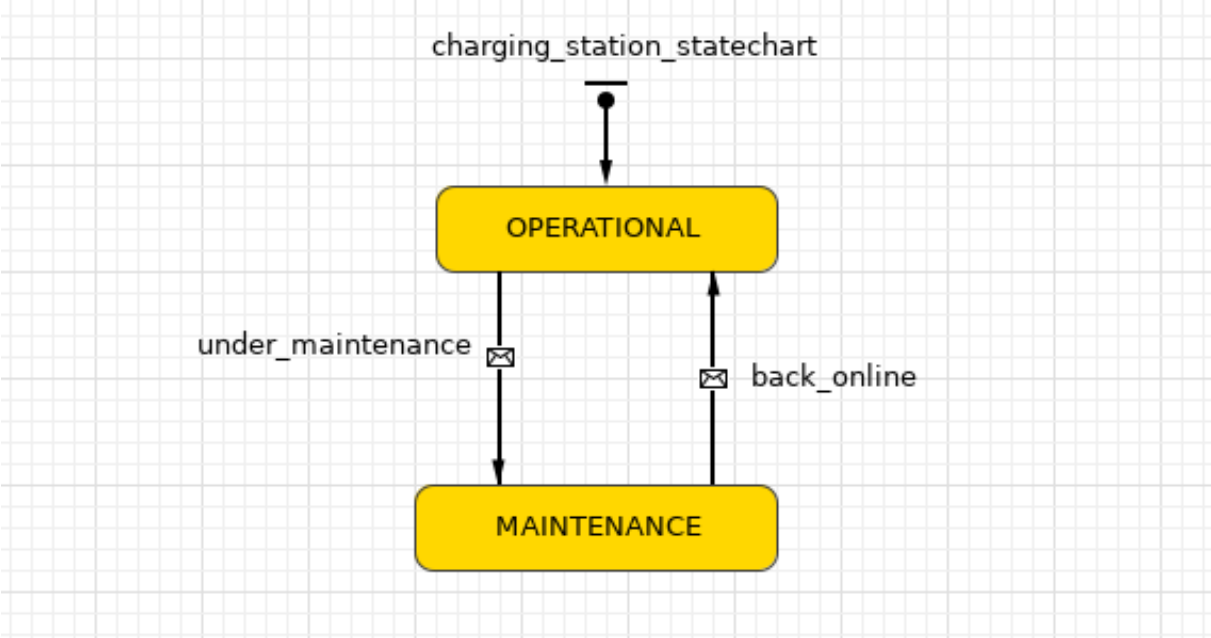

Slika 3.12: Model rada električne punionice

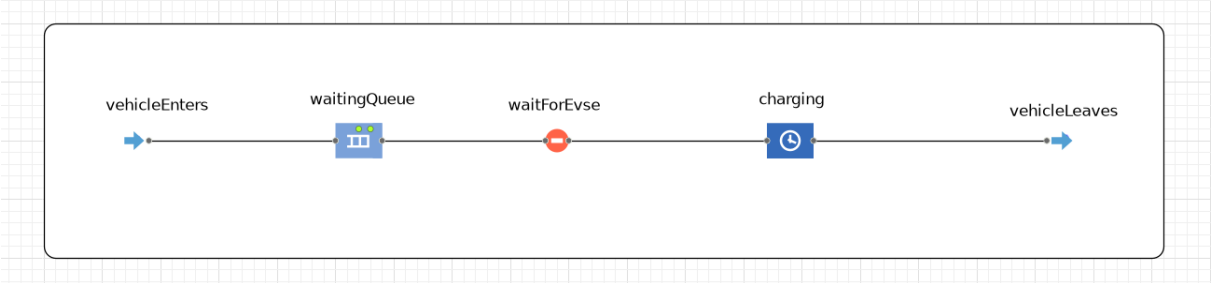

Slika 3.13: Model procesa punjenja baterije električnog vozila

pri čemu stanje *OPERATIONAL* označava da je električna punionica operativna i dostupna električnim vozilima za uporabu, dok stanje *MAINTENANCE* označava da je električna punionica trenutačno u stanju održavanja i da je nedostupna za pružanje usluge punjenja baterije električnih vozila.

Model REP uključuje proces *punjenja baterija* (PB) za električnu čistilicu definiranu u poglavlju 3.2.2. Dolazak električne čistilice na električnu punionicu definira diskretan događaj koji pokreće proces PB-a čiji se model prikazuje na slici 3.13. Proces PB-a definira komponentu *vehicleEnters* putem kojeg prima agenta EC te ga prosljeđuje u red čekanja *waitingQueue* u kojem agent EC čeka na prvi slobodan priključak na električnoj punionici. Blok *waitForEvse* unutar procesa PB-a definira funkciju koja određuje je li priključak pogodan za električnu čistilicu slobodan. Ako postoji takav, priključak proces PB-a prosljeđuje agenta EC iz reda čekanja u blok *charging* koji implementira funkciju punjenja baterije električne čistilice. Po završetku punjenja baterije električne čistilice, proces PB-a prosljeđuje agenta EC prema izlazu procesa *vehicleLeaves* kojim se označava završetak procesa PB-a.

3.3.2Agent Spremište vozila

Model agenta *Spremište vozila* (SV) prikazuje se na slici 3.14. Agent SV definira se skupom statičkih i dinamičkih varijabli koje se upotrebljavaju tijekom rada agenta. Ponašanje agenta SV definira se modelom rada spremišta vozila koji se sastoji od dijagrama stanja za obradu promjene stanja i dvaju procesa za obradu diskretnih događaja: *proces obrade zadataka* i *proces upravljanja flotom*. Oba procesa u svojem radu u nekom trenutku usmjeravaju električno vozilo u prostoru, pri čemu se za usmjeravanje električnih vozila koriste algoritmi za usmjeravanje električnih vozila. Spremište vozila predstavlja središnji dio sustava koji upravlja flotom električnih vozila, radi planiranje obavljanja zadataka, dodjeljuje zadatke vozilima iz flote, usmjerava električna vozila iz flote prema parkiralištima s namjerom što boljeg obavljanja zadatka i prema električnim punionicama s ciljem što bržeg punjenja baterije električnom energijom. Model agenta SV definira se na sljedeći način:

$$SV = \{SVar, DV, S_{SV}\} \tag{3.25}$$

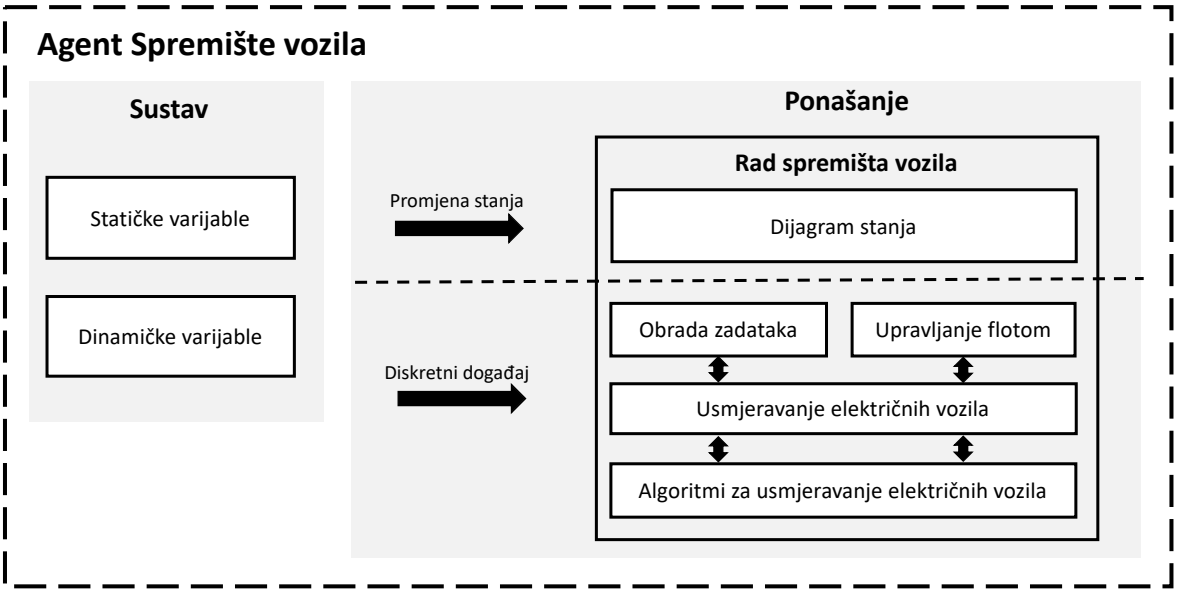

Slika 3.14: Model agenta Spremište vozila

gdje *SVar* predstavlja skup statičkih varijabli, *DV* predstavlja skup dinamičkih varijabli, a S_{SV} definira skup stanja u kojima se može naći SV-agent tijekom svog rada.

Statičke varijable

Statičke varijable *SVar* definiraju osnovne informacije o spremištu vozila i geolokaciju spremišta vozila na karti. Agent SV definira se sa sljedećim statičkim varijablama:

$$SVar^{\{SV\}} = \{ime, flota, lat, lng\} \tag{3.26}$$

gdje *name* predstavlja ime spremišta, *lat* i *lng* definiraju geolokaciju spremišta vozila na karti te predstavljaju geografsku širinu i dužinu, a $flota$ predstavlja flotu električnih vozila kojima spremište vozila raspolaže. Spremište vozila koristi se flotom električnih vozila u obavljanju zadataka, pri čemu ih usmjerava u prostoru s ciljem što boljeg obavljanja zadatka.

Dinamičke varijable

Dinamičke varijable (DV) agenta SV povezane su s stvaranjem i obavljanjem zadataka električnih vozila. Agent SV definira samo jednu dinamičku varijablu *zadaci* koja predstavlja skup stvorenih zadataka za električna vozila koji se moraju obaviti u zadanom vremenskom okviru. Spremište vozila putem varijable *zadaci* ima uvid koliko je zadataka odrađeno te koliko ih se mora još odraditi. Prema tome, dinamičke varijable za agent SV definirane su na sljedeći način:

$$DV^{\{SV\}} = \{zadaci\} \tag{3.27}$$

Varijabla *zadaci* koristi se u procesima temeljenim na diskretnim događajima unutar modela rada spremišta vozila te se ponovno postavlja svaki put kad spremište vozila planira novi set zadataka za električna vozila.

Model rada spremišta vozila

Model *rada spremišta vozila* (RSV) prikazuje se na slici 3.15. Model RSV definira se dijagramom stanja $depo_statechart$ koji definira skup stanja S_{SV} agenta SV. Skup stanja S_{SV} agenta SV definira se na sljedeći način:

$$S_{SV}^{\{SV\}} = \{IDLE, SCHEDULING, SCHEDULING_DONE, \\ PROCESSING, PROCESSING_DONE\} \tag{3.28}$$

gdje stanje *IDLE* označava početno stanje dijagrama stanja agenta SV. Agent SV odrađuje stvaranje zadataka za električna vozila prema definiranom planu izvođenja zadataka (npr. periodičko stvaranje zadataka svaki dan u 6 sati ujutro). U trenutku kad je definirano da agent SV krene stvarati zadatke, prelazi u stanje *SCHEDULING* koje implementira funkciju stvaranja zadataka za električna vozila. Nakon što agent SV stvara sve potrebne zadatke za flotu električnih vozila, prelazi u stanje *SCHEDULING_DONE* te čeka na početak izvršavanja zadataka. Kad

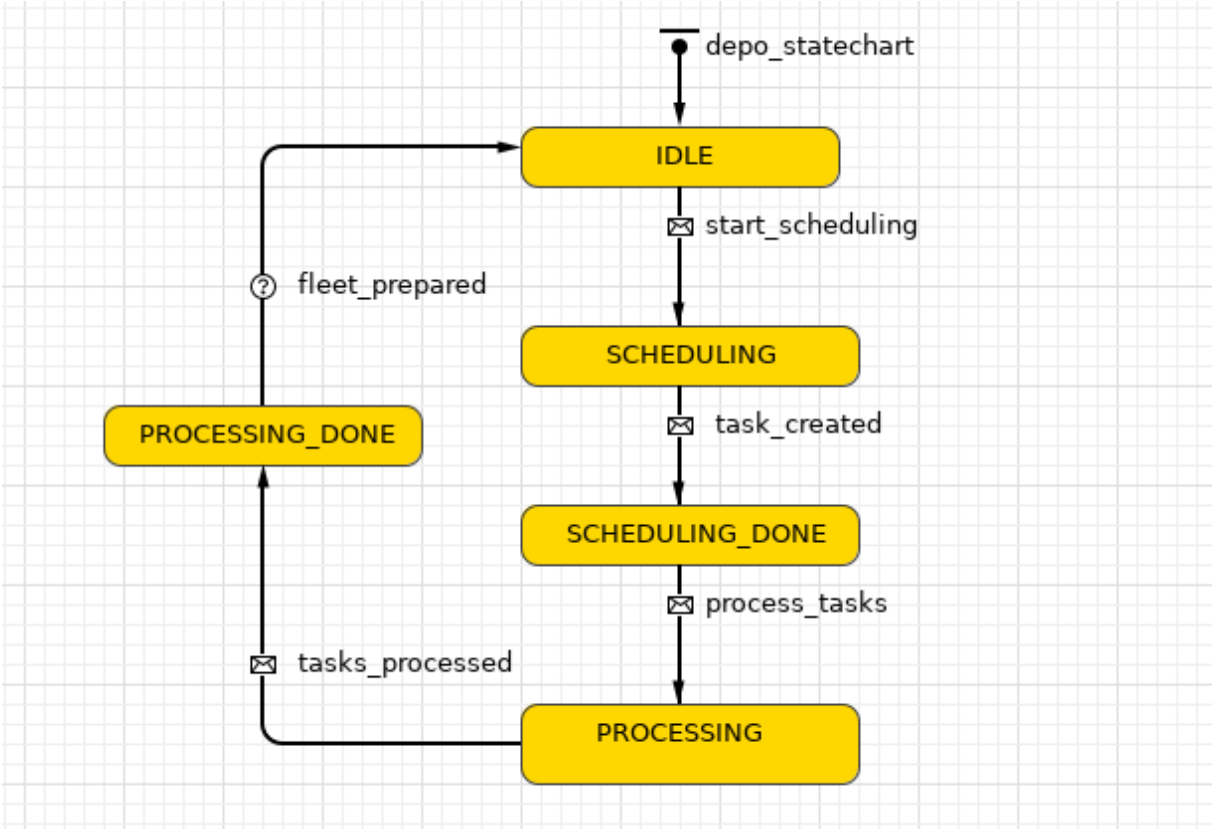

Slika 3.15: Model rada spremišta vozila

flota električnih vozila krene s izvršavanjem zadataka, agent SV prelazi u stanje *PROCESSING* u kojem ostaje tako dugo dok svi stvoreni zadaci iz dinamičke varijable *zadaci* nisu izvršeni. Po završetku izvršavanja svih zadataka, agent SV prelazi u stanje *PROCESSING_DONE* i čeka da svako električno vozilo dođe do spremišta vozila te da odradi pripreme kako bi bilo spremno za novi ciklus izvršavanja zadataka. U trenutku kad su sva vozila u floti pripremljena za novi ciklus izvršavanja zadataka, agent SV prelazi natrag u stanje *IDLE* i čeka na definirano vrijeme za stvaranje novih zadataka.

Model RSV agenta SV-a uključuje dva procesa koja obrađuju zaprimljene diskretne događaje: proces za *izvršavanje zadataka* i proces za *upravljanje flotom*. Model procesa za *izvršavanje zadataka* (IZ) prikazuje se na slici 3.16. Model procesa IZ sastoji se od dvaju dijelova, pri čemu je svaki dio vezan uz određeni diskretan događaj. Prvi diskretan događaj definira agent SV u trenutku stvaranja zadataka za flotu električnih vozila. Svaki novi stvoreni zadatak zaprima se na ulazu prvog dijela procesa IZ *newTask* te se prosljeđuje prema bloku *waitForScheduledTime* koji ima implementiranu funkciju čekanja na vrijeme predviđeno za izvršavanje zadatka. Kad se ostvari vrijeme predviđeno za izvršavanje zadatka, zadatak se prosljeđuje u blok *waitForAssigningToVehicle* koji implementira funkciju čekanja na dodjelu električnog vozila iz flote. Nakon što se dodijeli električno vozilo zadatku, zadatak se šalje prema izlazu prvog dijela procesa IZ *dispatchTask* čime se zadatak prosljeđuje električnom vozilu koji je definiran agentom EV.

Drugi dio procesa IZ definiran je za obradu diskretnog događaja vezanog uz završetak obrade zadatka. Trenutak kad električno vozilo završi s izvršavanjem zadatka, agent EV šalje izvršeni zadatak agentu SV koji pokreće drugi dio procesa IZ na način da prosljeđuje izvršeni zadatak na ulaz drugog dijela procesa IZ *finishedTask*. Izvršeni zadatak prosljeđuje se u blok *releaseVehicleFromTask* koji oslobađa električno vozilo od zadatka i time električno vozilo postaje dostupno za sljedeće zadatke. Po završetku oslobađanja električnog vozila s izvršenog zadatka, zadatak se prosljeđuje prema bloku *waitTillAllTaskFinish* koji implementira funkciju

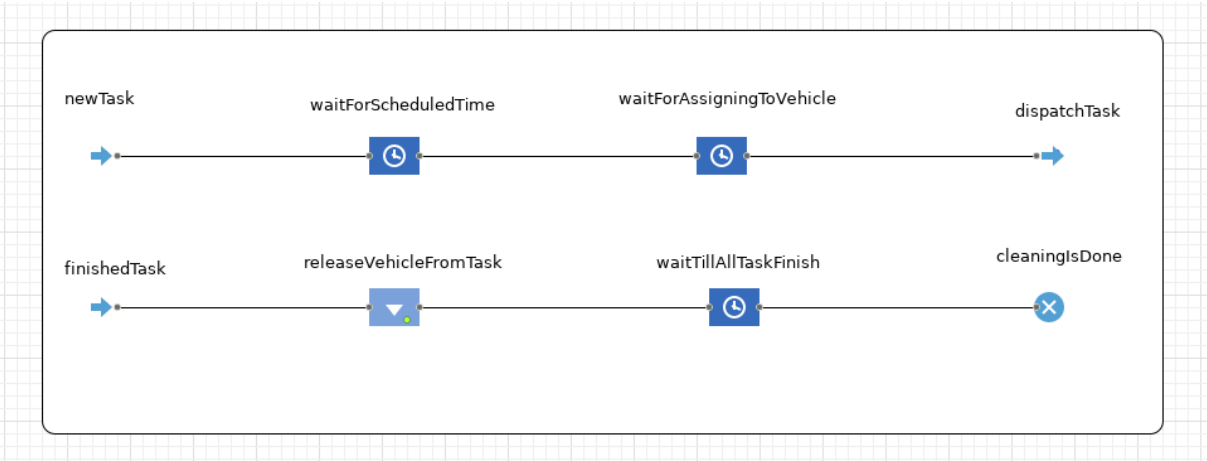

Slika 3.16: Model procesa izvršavanja zadataka

čekanja na završetak izvršavanja svih zadataka koje je agent SV stvorio. U trenutku kad su svi zadaci izvršeni, zadaci se prosljeđuju prema izlazu drugog dijela procesa IZ *cleaningDone* i pri tome agent SV prelazi u stanje *PROCESSING_DONE* te miče sve stvorene zadatke iz liste *zadaci*.

Model RSV agenta SV implementira proces za upravljanje flotom (UF) električnih vozila prikazanog na slici 3.17. Sastoji se od dvaju dijelova za upravljanje električnim vozilima iz flote koji su povezani uz dva diskretna događaja. Prvi diskretan događaj definira agent SV unutar bloka *releaseVehicleFromTask* procesa IZ gdje se električno vozilo oslobađa od dodijeljenog zadatka. Slobodno električno vozilo prosljeđuje se na ulaz prvog dijela procesa UF *availableVehicle* koji prosljeđuje vozilo u sljedeći blok *waitForTask* gdje vozilo čeka na zadatak. Nakon što proces IZ u svom prvom dijelu objavi da neki zadatak mora ići na izvršavanje, sva slobodna vozila koja se nalaze u bloku *waitForTask* prosljeđuju se prema redu čekanja *availableVehicleQueue*. Proces UF uzima jedno po jedno vozilo iz reda čekanja te prosljeđuje u blok *hasTasksForAssigning*, gdje se ispituje postoje li zadaci koji se trebaju izvršiti. Ako postoje, vozilo se prosljeđuje u sljedeći blok *assigneTaskToVehicle* gdje se dodjeljuje zadatak vozilu te se potom prosljeđuje prema izlazu procesa UF *vehicleSeized*. Nakon toga vozilo kreće s izvršavanjem dodijeljenog zadatka. Ako ne postoje zadaci za izvršavanje, tada se vozilo prosljeđuje u blok *shouldReturnToDepo* gdje se ispituje treba li se vozilo vratiti u spremište vozila. Proces UF, u slučaju da treba vratiti vozilo u spremište, prosljeđuje vozilo u blok *returnVehicleToDepo* gdje agent SV obavještava agenta EV da se vrati u spremište. Nakon toga proces UF završava s prosljeđivanjem vozila na izlaz *vehicleFinished*. U slučaju da proces UF zaključi da ipak ne treba vratiti vozilo u spremište, tada se vozilo prosljeđuje na izlaz procesa UF *returnToQueue* čime se vozilo ponovno vraća na ulaz procesa UF.

Drugi diskretan događaj koji je povezan s procesom UF jest trenutak kad električno vozilo stigne u spremište vozila jer je izvršilo sve dodijeljene zadatke ili u slučaju električne čistilice

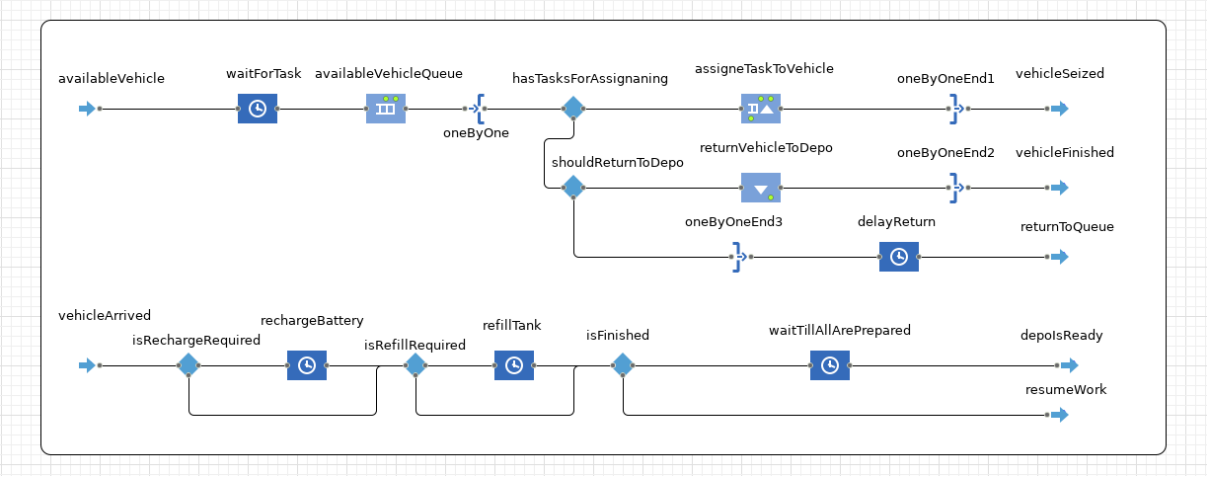

Slika 3.17: Model procesa upravljanja flotom

kada je potrebna nadopuna spremnika za vodu. Po dolasku električnog vozila u spremište pokreće se drugi dio procesa UF tako da se vozilo zaprima na ulazu procesa UF *vehicleArrived*. Spremište vozila nudi mogućnost nadopune baterije, ali samo u slučaju kad je vozilo izvršilo sve zadatke i potrebno ga je pripremiti za sljedeći ciklus izvršavanja zadataka. Stoga se u bloku *isRechargeRequired* provjerava je li vozilo izvršilo sve zadatke te ako jest, prosljeđuje se prema bloku *rechargeBattery* gdje je implementirana funkcija punjenja baterije električnog vozila. Nakon toga vozilo se prosljeđuje u blok *isRefillRequired* gdje se provjerava treba li vozilo nadopunu spremnika za vodu. Ukoliko je potrebno, utoliko se vozilo prosljeđuje u blok *refillTank* gdje je implementirana funkcija za nadopunu spremnika za vodu. Proces UF na kraju u bloku *isFinished* provjerava mora li električno vozilo izvršiti još neke zadatke te ako treba, prosljeđuje se prema izlazu *resumeWork* čime se signalizira agentu EV da nastavi s izvršavanjem dodijeljenog zadatka. U slučaju da je električno vozilo izvršilo sve zadatke, prosljeđuje se u blok *waitTillAllArePrepared* u kojem vozilo čeka da sva vozila iz flote budu pripremljena za sljedeći ciklus izvršavanja zadataka. U trenutku kad sva električna vozila definirana u listi *flota* budu pripremljena, prosljeđuju se na izlaz procesa UF *depoIsReady* čime agent SV prelazi iz stanja *PROCESSING_DONE* u stanje *IDLE* te se završava ciklus izvršavanja zadataka.

3.3.3Agent Parkiralište

Model agenta *Parkiralište* prikazuje se na slici 3.18. Agent *Parkiralište* uveden je u model VAS-UEV kao primjer uže specifikacije upotrebe modela koji je potreban za rad agenta *Električna čistilica* zaduženog za čišćenje gradskih parkirališnih prostora. Model VAS-UEV može se proširiti i na druge načine kojima se ostvaruje usmjeravanje drugačijih tipova električnih vozila, pa se tako za izvršavanje zadataka električnih autobuseva mogu uvesti modeli agenata *autobusna stanica* koji će se upotrebljavati za u procesu izvršavanja zadataka. Za potrebe agenata *električna čistilica* uvedeni su agenti *Parkiralište* koji se upotrebljavaju za ispunjavanje zadatka

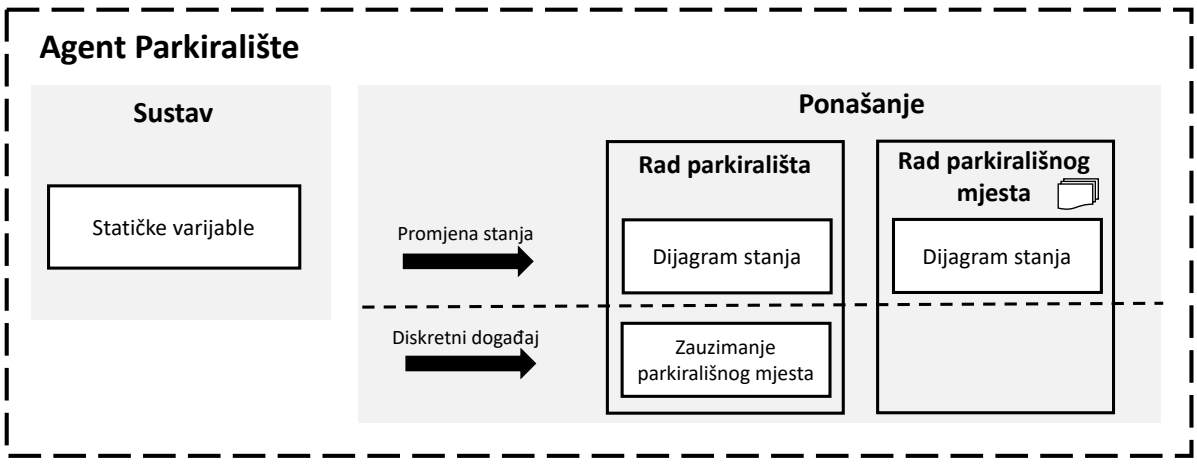

Slika 3.18: Model agenta Parkiralište

čišćenja gradskih parkirališnih površina. Agent *Parkiralište* (P) definira se skupom statičkih varijabli koje se ne mijenjaju tijekom rada agenta. Definirani model agenta P ne uključuje nikakve dinamičke varijable. Ponašanje agenta P definirano je radom parkirališta i radom parkirališnog mjesta, pri čemu se parkiralište sastoji od jednog ili više parkirališnih mjesta. Model agenta P prema tome definira se na sljedeći način:

$$P = \{SV, S_P, S_{PM}\} \tag{3.29}$$

Statičke varijable

Skup *statičkih varijabli* (SV) agenta P definira se na sljedeći način:

$$SV^{\{P\}} = \{id, ime, tip, lat, lng, C_P, lista_{PM}\} \tag{3.30}$$

gdje varijabla *id* predstavlja jedinstveni identifikator parkirališta, *ime* definira ime parkirališta, a C_P označava kapacitet parkirališta koji je jednak broju parkirališnih mjesta koja se nalaze na parkiralištu. Varijabla tip označava tip parkirališta, pri tome definirajući parkiralište kao *uličnо parkiralište* koje se nalazi duž ulice ili kao *vanulično parkiralište* koje se nalazi unutar barijere u obliku rampe. Geolokacija parkirališta određena je varijablama *lat* i *lng*, gdje *lat* označava geografsku širinu, a *lng* predstavlja geografsku dužinu. Varijabla $lista_{PM}$ definira listu parkirališnih mjesta koja se nalaze na tom parkiralištu te su određena modelom rada parkirališnog mjesta.

Model rada parkirališnog mjesta

Agent P sastoji se od parkirališnih mjesta definiranih u statičkoj varijabli $lista_{PM}$ čiji je broj definiran varijablom C_P. Svako parkirališno mjesto definira se modelom *rada parkirališnog mjesta* (RPM) prikazanog na slici 3.19. Model RPM definira se dijagramom stanja *parking_space_statechart* koji definira skup stanja S_{PM} agenta P. Skup stanja S_{PM} definira se na sljedeći način:

$$S_{PM}^{\{P\}} = \{FREE, PARKING_EVENT, OCCUPIED, UNDER_CLEANING\} \tag{3.31}$$

gdje stanje $FREE$ označava da je parkirališno mjesto slobodno, dok stanje $PARKING_EVENT$ najavljuje da postoji vozilo koje je u fazi parkiranja te stanje $OCCUPIED$ označava početak zauzeća parkirališnog mjesta. Po odlasku vozila s parkirališnog mjesta, mjesto se ponovno oslobađa i postaje dostupno te se radi promjena stanja u stanje $FREE$. Dolaskom električne čistilice na parkirališno mjesto s ciljem njegovog čišćenja, radi se promjena stanja u stanje $UNDER_CLEANING$ označavajući parkirališno mjesto nedostupnim za korištenje. Završetkom čišćenja radi se prijelaz stanja u stanje $FREE$ kojim mjesto ponovno postaje dostupno za upotrebu.

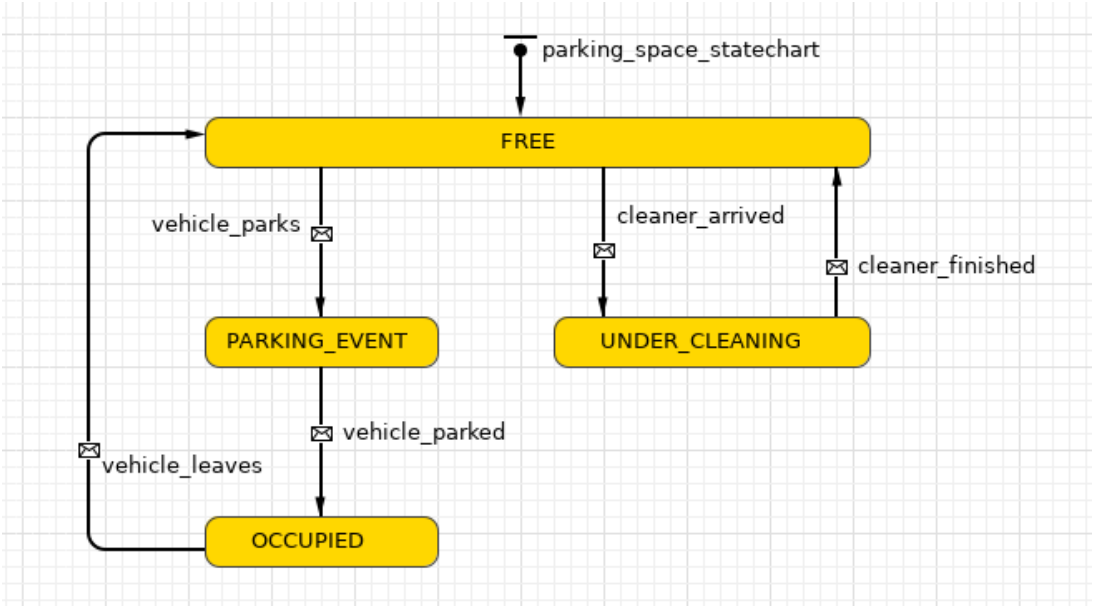

Slika 3.19: Model rada parkirališnog mjesta

Parkirališno mjesto definira dodatan skup statičkih varijabli modela RPM. Skup statičkih varijabli parkirališnog mjesta definira se na sljedeći način:

$$SV^{\{PM^{\{P\}}\}} = \{id, lat, lng\} \tag{3.32}$$

gdje *id* predstavlja jedinstveni identifikator parkirališnog mjesta, dok je geolokacija parkirališnog mjesta definirana varijablama *lat* i *lng*, koje predstavljaju geografsku širinu i dužinu.

Model rada parkirališta

Model *rada parkirališta* (RP) agenta P prikazuje se na slici 3.20. Model RP definira se dijagramom stanja *parking_lot_statechart* koji određuje skup stanja S_P agenta P. Skup stanja S_P

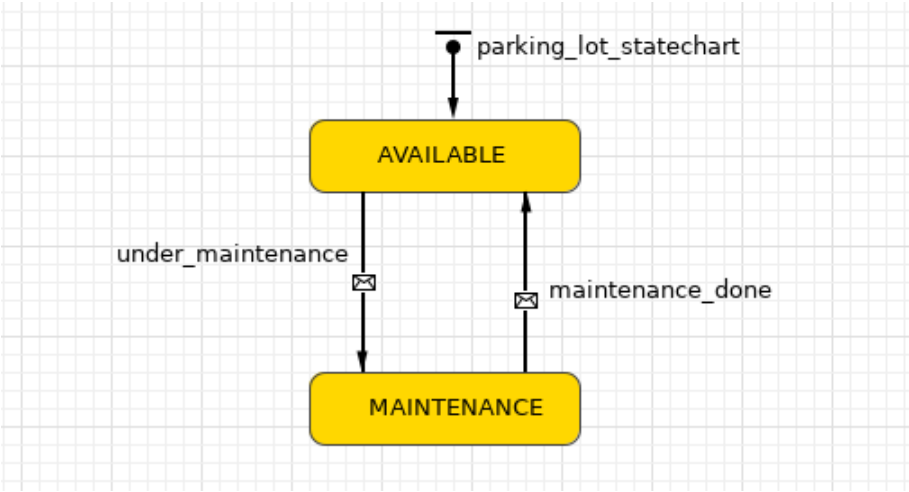

Slika 3.20: Model rada parkirališta

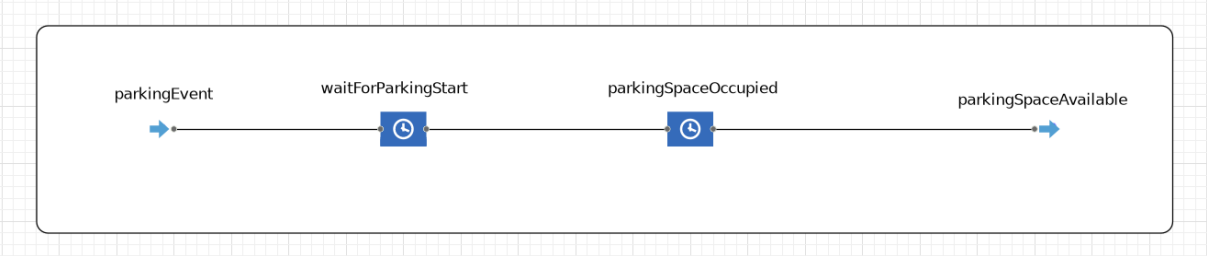

Slika 3.21: Model procesa zauzeća parkirališnih mjesta

definira se na sljedeći način:

$$S_P = \{AVAILABLE, MAINTENANCE\} \tag{3.33}$$

gdje se stanjem *AVAILABLE* označava da je parkiralište operativno i dostupno za pružanje usluge parkiranja, dok stanje *MAINTENANCE* označava da je parkiralište u stanju održavanja i da trenutačno nije dostupno za vozila.

Model RP uključuje proces *zauzeća parkirališnih mjesta* (ZPM) prikazanog na slici 3.21. Proces ZPM obrađuje diskretne događaje povezane s parkiranjem vozila na parkiralištu. Izvor diskretnih događaja zauzeća parkirališnih mjesta mogu biti povijesni zapisi iz stvarnog svijeta ili mogu biti simulirani određenim modelom zauzeća parkirališta. Diskretni događaj zauzeća parkirališnog mjesta sadrži informaciju o identifikatoru mjesta na kojem se vozilo parkiralo, koliko dugo se vozilo zadržalo na mjestu te vrijeme početka i završetka parkiranja. Takav događaj zaprima se na ulazu u proces ZPM *parkingEvent* čime započinje proces zauzeća određenog parkirališnog mjesta. Proces ZPM prosljeđuje diskretni događaj zauzeća parkirališnog mjesta prema bloku *waitForParkingStart* gdje se čeka na početak parkiranja te postavlja parkirališno mjesto u stanje *PARKING_EVENT*. Nakon što se ostvari vrijeme početka parkiranja, diskretni događaj zauzeća parkirališnog mjesta prosljeđuje se u blok *parkingSpaceOccupied* koji označava da je parkirališno mjesto zauzeto i postavlja ga u stanje *OCCUPIED*. Po završetku vremena parkiranja, diskretni događaj prosljeđuje se prema izlazu procesa ZPM *parkingSpaceAvailable* čime se označava da je parkirališno mjesto ponovno slobodno i postavlja se u stanje *FREE*.

3.4Komunikacija izme đu agenata

U modelu *višeagentskog sustava za usmjeravanje električnih vozila* (VAS-UEV) agenti međusobno komuniciraju na temelju jasno definiranih poruka. Komunikacija u modelu VAS-UEV odvija se između pokretnih i stacionarnih agenata kao što je prikazano na slici 3.22.

Prvi dio komunikacije odvija se za provođenje zadataka koje stvara agent *Spremište vozila*, a izvršavaju ih agenti *Električno vozilo*. Svaki zadatak definira se s informacijama o električnom vozilu kojem je dodijeljen te o predmetu zadatka za koji je namijenjen. U slučaju električne

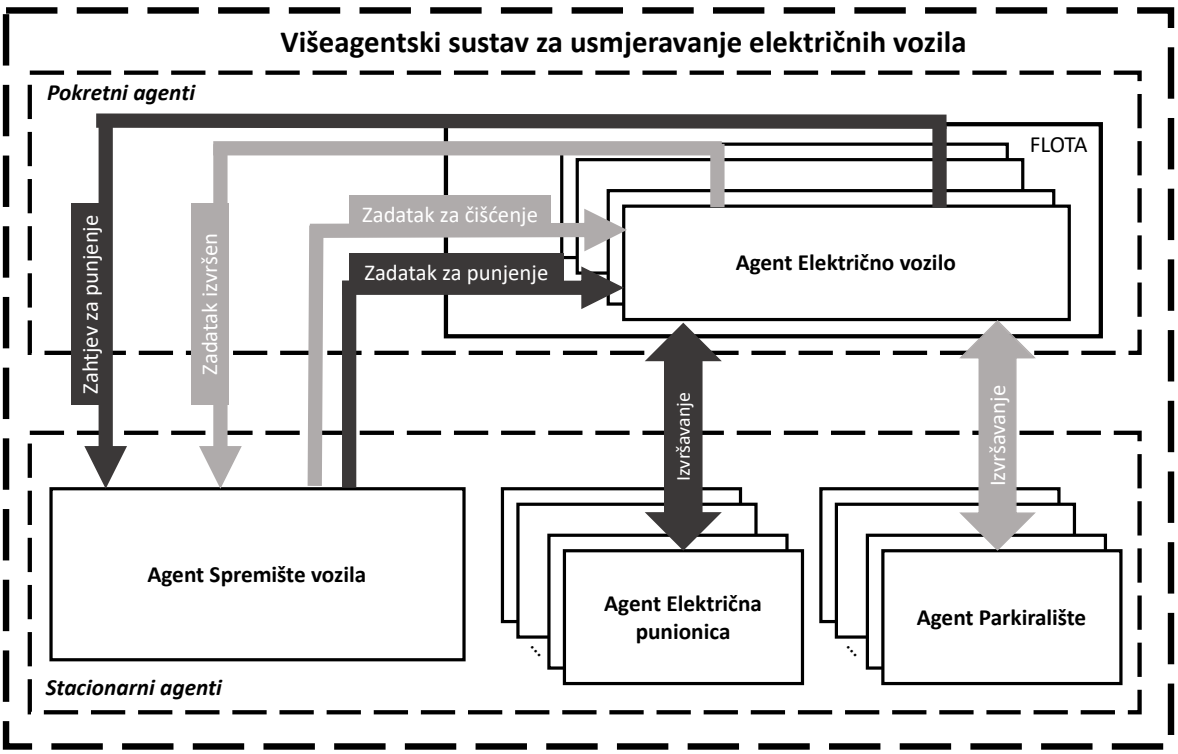

Slika 3.22: Prikaz komunikacije među agentima

čistilice, predmet zadatka jest čišćenje gradskih parkirališnih površina koja su zastupljena u modelu VAS-UEV putem agenata *Parkiralište*. Dodjelom zadatka agentu *Električna čistilica*, agent se usmjerava prema parkiralištu definiranom u zadatku. Po dolasku na lokaciju parkirališta, agent *Električna čistilica* kreće u izvršavanje dodijeljenog zadatka tako da se kreće od parkirališnog mjesta do parkirališnog mjesta i čisti ona koja nisu u tom trenutku zauzeta. Po završetku izvršavanja zadatka, agent *Električna čistilica* obavještava agenta *Spremište vozila* da je zadatak obavljen i da očekuje sljedeći zadatak. Ovakva komunikacija odvija se sve dok agent *Spremište vozila* ne obavijesti porukom agenta *Električna čistilica* da su svi zadaci izvršeni.

Drugi dio komunikacije odvija se radi ostvarivanja punjenja baterije električnog vozila na električnim punionicama. Agent *Električno vozilo* u trenutku kad stanje baterije zahtijeva punjenje, šalje zahtjev agentu *Spremište vozila* za dodjelu električne punionice na kojoj će agent *Električno vozilo* obaviti punjenje baterije. Agent *Spremište vozila* odgovara sa zadatkom za punjenje agentu *Električno vozilo* koje on mora izvršiti. Zadatak za punjenje u sebi sadrži informacije o električnoj punionici na kojoj agent *Električno vozilo* mora obaviti punjenje i informaciju o električnom vozilu. Agent *Električno vozilo* se usmjerava prema električnoj punionici određenoj u zadatku za punjenje te po dolasku do lokacije električne punionice započinje komunikaciju s agentom *Električna punionica* radi izvršavanja zadatka za punjenje. Po završetku punjenja baterije električnog vozila, završava komunikacija između agenta *Električno vozilo* i agenta *Električna punionica* te ujedno završava izvršavanje zadatka za punjenje.

Poglavlje 4

Algoritmi za usmjeravanje električnih vozila

U ovom poglavlju opisani su algoritmi za usmjeravanje električnih vozila koji se upotrebljavaju u modelu višeagentskog sustava za usmjeravanje električnih vozila definiranog u poglavlju 3. Algoritmi za usmjeravanje električnih vozila temelje se na problemu usmjeravanja električnih vozila (eng. *Electric Vechicle Routing Problem - EVRP*) koji definira optimalni skup ruta za električna vozila s ciljem maksimizacije funkcije cilja. Funkcija cilja u većini se slučajeva definira prema korisničkim preferencama, ali standardno se definira kao funkcija smanjivanja troškova usmjeravanja vozila [99]. Standardni skup ograničenja koja definiraju problem usmjeravanja električnih vozila i koja se moraju uzeti u obzir kod definicije algoritama za usmjeravanje električnih vozila jesu: *spremište vozila* koje označava početno i završno odredište svakog vozila, *skup vozila* koji se usmjeravaju u prostoru prema definiranom *skupu odredišta* s ciljem maksimizacije *funkcije cilja* [100]. Problem usmjeravanja električnih vozila je kompleksan i zahtjevan problem za rješavanje, čija se kompleksnost povećava s brojem korisnika.

Uža specifikacija električnog vozila u modelu *višeagentskog sustava za usmjeravanje električnih vozila* (VAS-UEV) jest električna čistilica koja čisti gradske parkirališne površine. U poglavlju 4.1 dan je pregled potrebnih algoritama za ostvarivanje usmjeravanja električne čistilice u modelu VAS-UEV. Model VAS-UEV definira dva algoritma za usmjeravanje električne čistilice. Prvi algoritam usmjerava električnu čistilicu prema parkiralištu kako bi obavio usluge čišćenja, a drugi algoritam usmjerava električnu čistilicu prema električnoj punionici kako bi obavio usluge punjenja baterije. Poglavlje 4.2 daje pregled definiranih osnovnih algoritama za usmjeravanje električne čistilice prema parkiralištu i električnoj punionici, koji će služiti kao mjerilo uspješnosti u odnosu na algoritme definirane u poglavlju 4.3. Poglavlje 4.3 definira algoritme za usmjeravanje električne čistilice prema parkiralištu i električnoj punionici koji su zasnovani na modelima ML-a uzimajući u obzir iskoristivost parkirališta i električne punionice te kontekst u kojima se nalaze.

4.1Pregled algoritama

Algoritmi temeljeni na problemu usmjeravanja električnih vozila moraju uzeti u obzir određena ograničenja. Problem usmjeravanja električnih vozila definira sljedeći skup ograničenja:

- **spremište vozila** - početna i završna točka usmjeravanja električnog vozila;
- **flota vozila** - homogena ili heterogena skupina električnih vozila korištena za usmjeravanje u prostoru;
- **funkcija cilja** - jedna ili više definiranih funkcija cilja za optimizaciju korisničkih preferenci.
- **odredišta** - skup mjesta prema kojima algoritmi usmjeravaju električna vozila radi pružanja usluge.

Problem usmjeravanja električnih vozila definira dvije faze: *faza planiranja* i *faza izvršavanja* [101]. Faza planiranja prva je faza koja se izvršava za planiranje ruta po kojima će se vozila iz flote usmjeravati i vrijeme početka usmjeravanja. Nakon faze planiranja, kreće se u fazu izvršavanja u kojoj se izvršavaju planovi ruta iz faze planiranja u definirano vrijeme te se dodatno rješava one zahtjeve za usmjeravanje koje su poslala vozila. Primjere definiranja i primjene algoritama koji se temelje na problemu usmjeravanja električnih vozila mogu se pronaći u rješenjima za flotu električnih autobusa, flotu električnih taksija i flotu električnih vozila za *car-sharing*.

Algoritmi za sustave gradskih prijevoza usmjeravaju flotu električnih autobusa radi što boljeg izvođenja ruta definiranih za svaki autobus, pri čemu se funkcija cilja može definirati kao smanjivanje troškova odrađivanja rute [102]. Troškovi rute povezani su s brojem punjenja električnog autobusa na električnim punionicama koje se nalaze na ruti ili van nje [103]. Algoritam za usmjeravanje električnih autobusa mora prvo definirati fazu planiranja u kojoj planira kako će flota električnih autobusa izvesti rutu obilaska autobusnih stanica, uključujući i plan punjenja autobusa prilikom izvršavanja rute [73]. Svaka ruta ima definirano vrijeme početka i završetka izvršavanja, što predstavlja vremenski okvir unutar kojeg se ruta izvršava, a njega mora definirati algoritam za usmjeravanje u fazi planiranja. Nakon faze planiranja, algoritam definira fazu izvršavanja u kojoj odrađuje definirane rute obilaska autobusnih stanica iz faze planiranja. Sustav gradskog prijevoza definira spremište vozila s kojeg svaki od električnih autobusa kreće u odrađivanje rute i u koje se vraća nakon što je odradio zadanu rutu [45]. Slična analogija može se primijeniti i za flotu električnih čistilica koja izvršava dodijeljene zadatke čišćenja parkirališnih prostora unutar vremenskog okvira koji predstavlja radno vrijeme električne čistilice. Zadaci za čišćenje mogu se stvarati u fazi planiranja algoritma za usmjeravanje električnih čistilica te ih izvršavati u fazi izvršavanja algoritma. Jednako kao i kod električnih autobusa, za sustav električnih čistilica potrebno je definirati spremište vozila iz kojeg svaka čistilica započinje i završava svoj rad.

Algoritmi za sustave usmjeravanja električnih taksija definicijom su slični algoritmima za usmjeravanje električnih autobusa, jer rješavaju sličan problem, a to je višestruko punjenje baterije električnom energijom prilikom pružanja usluge prijevoza ljudi [104]. Sustav električnih taksija sastoji se od spremišta vozila koje služi kao centrala koja usmjerava električne taksije prema korisnicima i prema električnim punionicama kad je to potrebno [105]. Algoritmi za usmjeravanje nemaju fazu planiranja koja bi izradila skup ruta po kojima bi se taksi kretao, već se zahtjevi za usmjeravanje obrađuju u stvarnom vremenu. Funkcija cilja za usmjeravanje električnih taksija može se definirati kao funkcija smanjivanja troškova koji su vezani uz broj punjenja na električnim punionicama te povećanje ukupnog prihoda koji je vezan uz vrijeme kad je vozilo bilo operativno [56]. Operativno vrijeme vozila može se smanjiti u slučaju da vozilo čeka na red za punjenje na električnoj punionici, pa će se samim time smanjiti i ukupan prihod. Algoritam za usmjeravanje mora uzeti u obzir vrijeme kad se očekuje punjenje vozila i stanje električnih punionica u tom trenutku da bi ostvario što bolju funkciju cilja [106]. Jednaki princip može se primijeniti i na sustav za električne čistilice gdje je potrebno postići što duže operativno vrijeme čistilice. Električne čistilice jednako kao i električni taksiji tijekom svog rada moraju odrađivati višestruko punjenje baterije električnom energijom te se mora postići što manje vrijeme punjenja na električnim punionicama. Analogija spremišta vozila kao centrale koja usmjerava električna vozila u prostoru na zahtjev vozila također se može primijeniti za sustav usmjeravanja električnih čistilica.

Algoritmi za usmjeravanje električnih vozila za *car-sharing* razlikuju se od prethodnih primjera po tome što mogu sadržavati više od jednog spremišta vozila. U osnovi *car-sharing* sustav sastoji se od flote električnih vozila za pružanje usluge korisnicima, jednog ili više spremišta vozila te jedne ili više funkcija cilja [107]. Spremište vozila za *car-sharing* definira se kao mjesto na kojem se može preuzeti vozilo ili ga se ostavlja nakon korištenja usluge. Odluka na kojem se spremištu vozila ostavlja vozilo igra značajnu ulogu u ostvarivanju što boljeg rezultata funkcije cilja te se odluka o tome gdje će vozilo biti ostavljeno prepušta algoritmima za usmjeravanje vozila. *Car-sharing* usluga definira dva načina vraćanja vozila: jednosmjerno i dvosmjerno [108]. Jednosmjerno vraćanje vozila omogućava korisniku da ostavlja vozilo na nekom drugom spremištu vozila različitom od onog s kojeg je preuzeo vozilo. U dvosmjernom načinu, korisnik mora vratiti vozilo u ono spremište vozila s kojeg ga je preuzeo. Način vraćanja vozila potrebno je uključiti u algoritme za usmjeravanje kako bi se postigli što bolji rezultati funkcije cilja. Funkcija cilja za *car-sharing* uslugu može se primjerice definirati kao funkcija smanjivanja operativnih troškova usluge ili kao funkcija povećanja ukupnog profita [109]. Principi *car-sharinga* kao oblika upotrebe višestrukih spremišta vozila i funkcija cilja mogu se primijeniti i na sustav za električna vozila ako sustav predviđa upotrebu više od jednog spremišta vozila.

Model *višeagentskog sustava za usmjeravanje električnih vozila* (VAS-UEV) opisan u po-

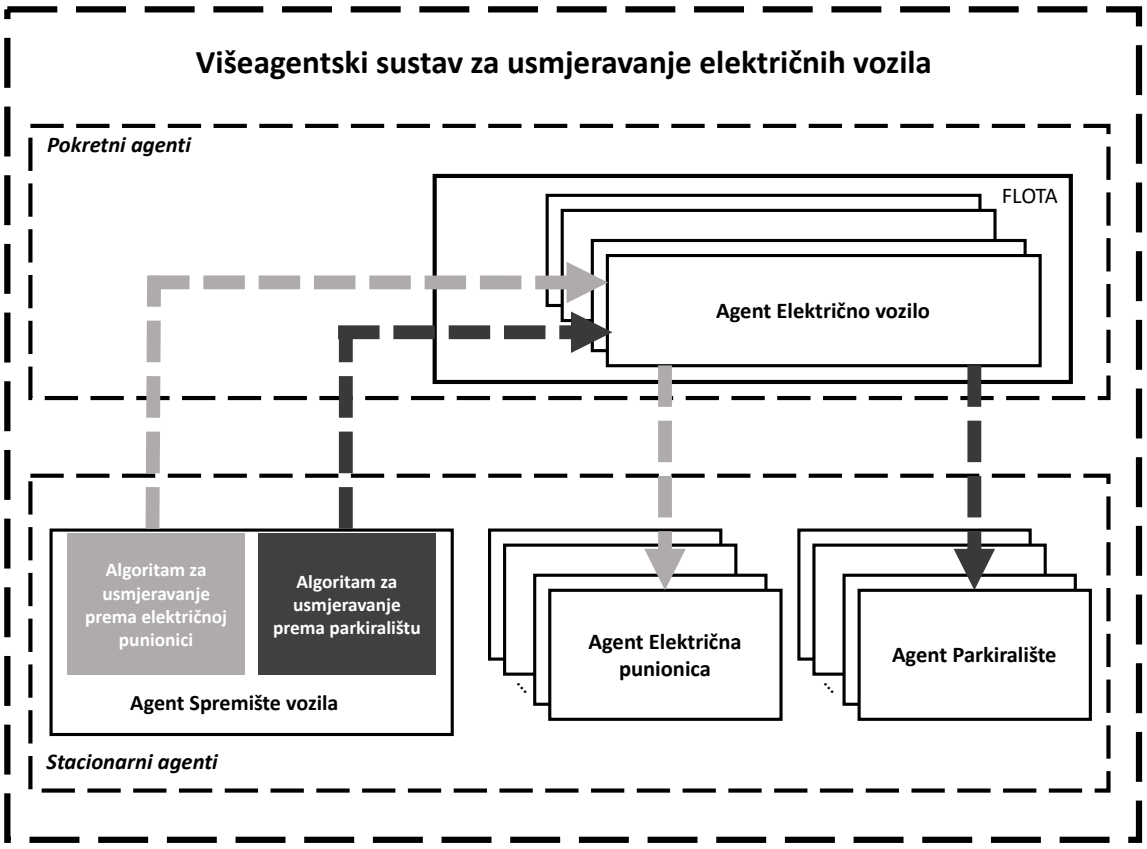

Slika 4.1: Prikaz korištenja algoritama u modelu višeagentskog sustava za usmjeravanje električnih vozila

glavlju 3, gdje se kao električno vozilo upotrebljava električna čistilica, čiji model je opisan u poglavlju 3.2.2, implementira algoritme za usmjeravanje električnih vozila. Implementacija algoritama za usmjeravanje električnih vozila u modelu VAS-UEV prikazana je na slici 4.1. Model VAS-UEV implementira dva algoritma za usmjeravanje:

- •Algoritam za usmjeravanje prema elektri čnoj punionici;
- •Algoritam za usmjeravanje prema parkiralištu.

Algoritmi za usmjeravanje električnih čistilica implementiraju se u agentu *Spremište vozila* koji služi kao centrala za električne čistilice. Model VAS-UEV definira samo jedno spremište vozila koje obrađuje sve zahtjeve flote električnih čistilica. Algoritam za usmjeravanje prema parkiralištu definira fazu planiranja i fazu izvršavanja. U fazi planiranja algoritam stvara zadatke za čišćenje parkirališnih prostora, definirajući pritom vrijeme kad će zadatak biti izvršen, dok u fazi izvršavanja rješava zadatke flote električnih čistilica. Algoritam za usmjeravanje prema električnim punionicama ima samo fazu izvršavanja u kojoj na temelju zahtjeva električnih čistilica usmjerava čistilicu prema električnoj punionici. Model VAS-UEV definira višestruke funkcije cilja opisanih u poglavlju 5 koje definiraju uspješnost ostvarenih algoritama za usmjeravanje električnih čistilica.

4.2Osnovni algoritmi

Osnovni algoritmi za model *višeagentskog sustava za usmjeravanje električnih vozila* (VAS-UEV) temelje se na problemu usmjeravanja električnih vozila s kapacitetom i vremenskim okvirom. Problem usmjeravanja električnih vozila s kapacitetom uzima flotu jednakih električnih vozila koja se usmjeravaju u prostoru radi pružanja usluge kao kapacitet [110]. Model VAS-UEV definira flotu istovrsnih električnih čistilica koje treba usmjeriti u prostoru radi čišćenja gradskih parkirališnih površina ili punjenja baterije električnom energijom na električnim punionicama. Problem usmjeravanja električnih vozila s vremenskim okvirom određuje vremenski interval unutar kojeg će električno vozilo posjetiti odredišta [111]. Vremenski okvir u modelu VAS-UEV opisuje se kao vrijeme unutar kojeg flote električnih čistilica moraju očistiti gradske parkirališne površine, a povezan je s radnim vremenom gradskih komunalnih službi. Opisani se osnovni algoritmi upotrebljavaju kao temeljni algoritmi za omogućivanje usporedbe drugih algoritama i njihove uspješnosti. Model VAS-UEV određuje dvije vrste usmjeravanja kojima se električne čistilice koriste: usmjeravanje prema parkiralištu i usmjeravanje prema električnoj punionici. Definicija algoritama za navedene vrste usmjeravanja definirani su u nastavku.

4.2.1Usmjeravanje prema parkiralištu

Osnovni algoritam za *usmjeravanje prema parkiralištima* (UP) odvija se u dvjema fazama: faza planiranja i faza izvršavanja. Faza planiranja algoritma UP prikazana je algoritmom 1. Ulaz za algoritam UP lista je gradskih parkirališta *PS* koja moraju biti očišćena i unaprijed definirano vrijeme početka čišćenja t_P. Algoritam UP opisuje izlaz kao skup zadataka za čišćenje *ZCS* koji se moraju izvršiti u fazi izvršavanja. Algoritam UP u fazi planiranja za svako parkiralište *P* iz skupa *PS* provjerava stanje samog parkirališta, koje ako nije u stanju *OPERATIONAL*, izuzima se iz ciklusa čišćenja. Za svako operativno parkiralište algoritam UP definira zadatak za čišćenje *ZC* tako da odredi parkiralište *P* kojem je dodijeljen i vrijeme početka čišćenja t_P koje je fiksno i jednako za sva parkirališta u osnovnom algoritmu UP. Početak čišćenja može se vezati uz početak radnog vremena komunalnih gradskih službi. Stvoreni skup zadataka za čišćenje *ZCS* koji se dobiva na izlaz algoritma UP prosljeđuje se procesu za obradu zadataka opisanog u modelu VAS-UEV unutar agenta *Spremište vozila*. Predajom svakog zadatka *ZC* u proces za obradu zadataka za čišćenje modela VAS-UEV, pokreće se faza izvršavanja algoritma UP.

Faza izvršavanja algoritma UP opisana je algoritmom 2. Algoritam UP u fazi izvršavanja dodjeljuje zadatke za čišćenje dostupnim električnim čistilicama iz flote, pri čemu ih time usmjerava u prostoru prema gradskim parkiralištima. U trenutku kad proces za izvršavanje zadataka modela VAS-UEV zatraži čistilicu za zadatak koji se mora početi izvršavati, pokreće se algoritam UP. Algoritam UP na ulaz prima skup zadataka za čišćenje *ZCS* kojima se moraju

Algoritam 1: Usmjeravanje prema parkiralištu - faza planiranja

Ulaz: $PS[P]$, t_p
Izlaz: $ZCS[ZC^{\{P\}}]$

```
1  početak
2      ZCS[ZC^{P}] ← ∅
3      za svaki P ∈ PS čini
4          Q^{P} ← P_Q
5          ako Q^{P} = MAINTENANCE onda
               //Parkiralište se trenutno održava i ne treba ga čistiti
6              Idi na sljedeći P
7          kraj
8          ZC^{P} ← stvori ZC^{P} za P i postavi vrijeme početka t_p
9          dodaj ZC^{P} u ZCS[ZC^{P}]
10     kraj
11     vrati ZCS[ZC^{P}]
12 kraj
```

dodijeliti električne čistilice iz skupa dostupnih električnih čistilica ECS_D. Izlaz algoritma UP definiran je s skupom zadataka za čišćenje ZCS_A koji imaju dodijeljene električne čistilice i agenti *Spremište vozila* mogu ih poslati prema agentima *Električna čistilica*. Algoritam UP na početku provjerava postoji li dostupna električna čistilica u skupu ECS_D te u slučaju da je skup ECS_D prazan, algoritam UP vraća prazan skup ZCS_A i time signalizira procesu za izvršavanje zadataka da nema dostupnih električnih čistilica u floti. Proces za izvršavanje zadataka stavlja se u čekanje i čeka da proces za upravljanje flotom definiran u modelu VAS-UEV zaprimi električnu čistilicu koja je slobodna i spremna za dodjelu sljedećeg zadatka. Po primitku slobodne električne čistilice algoritam UP pokreće dodjelu zadatka za čišćenje *ZC* tako da gleda koji je zadatak za čišćenje parkirališta *ZC* iz skupa zadataka *ZCS* geolokacijski najbliži geolokaciji električne čistilice. Udaljenost između električne čistilice i parkirališta definiranog u zadatku *ZC* definira se po principu najkraće rute (eng. *Shortest Path*)[112][113]. Najbliža električna čistilica *EC* iz skupa ECS_D dodjeljuje se zadatku *ZC* i izuzima se iz skupa ECS_D. Ako algoritam UP nema više dostupnih električnih čistilica za dodjelu, on tada prekida svoje izvršavanje te agent *Spremište vozila* signalizira procesu za izvršavanje zadataka da čeka slobodnu električnu čistilicu iz flote. Algoritam UP po dodjeli električne čistilice zadnjem zadatku za čišćenje iz skupa *ZCS* završava fazu izvršavanja i time završava ciklus čišćenja gradskih parkirališnih površina.

Algoritam 2: Usmjeravanje prema parkiralištu - faza izvršavanja

Ulaz: $ZCS[ZC^{\{P\}}], ECS_D[EC]$
Izlaz: $ZCS_A[ZC^{\{(P,EC)\}}]$

Funkcija `optimalnoVozilo(`$ZC^{\{P\}}$, ECS`):`
  $EC^{(j)} \leftarrow EC \in ECS$ s najkraćom geolokacijskom rutom za $P^{(i)} \in ZC^{\{P^{(i)}\}}$
  vrati $EC^{(j)}$
početak
  $ZCS_A[ZC^{\{(P,EC)\}}] \leftarrow \emptyset$
  ako $ECS_D \in \emptyset$ **onda**
    vrati $ZCS_A[ZC^{\{(P,EC)\}}]$
  kraj
  za svaki $ZC^{\{P\}} \in ZCS$ **čini**
    ako $ECS_D \in \emptyset$ **onda**
      Prekid izvršavanja petlje
    kraj
    $EC = optimalnoVozilo(ZC^{\{P\}}, ECS)$
    makni EC iz ECS_D
    postavi EC za $ZC^{\{P\}}$ u $ZC^{\{(P,EC)\}}$
    dodaj $ZC^{\{(P,EC)\}}$ u $ZCS_A[ZC^{\{(P,EC)\}}]$
  kraj
  vrati $ZCS_A[ZC^{\{(P,EC)\}}]$
kraj

4.2.2Usmjeravanje prema elektri čnoj punionici

Osnovni algoritam 3 za *usmjeravanje prema električnim punionicama* (UEP) sastoji se samo od faze izvršavanja u kojoj električnoj čistilici EC iz skupa električnih čistilica ECS_D dodjeljuje električnu punionicu EP iz skupa električnih punionica EPS. Algoritam UEP na ulaz prima skup električnih punionica EPS i električnu čistilicu EC kojoj treba dodijeliti električnu punionicu. Za svaku električnu punionicu EP provjerava se je li u stanju *OPERATIONAL*, što označava da je električna punionica funkcionalna. Za svaku dostupnu električnu punionicu EP iz skupa EPS izračunava se duljina l rute između geolokacije električne punionice i električne čistilice EC. Električne punionice odabiru se po principu najkraće rute (eng. shortest path), gdje se električna punionica s najmanjom udaljenošću l do električne čistilice EC dodjeljuje električnoj čistilici za punjenje baterije električnom energijom. Agent *Spremište vozila* koristi se algoritmom UEP koji pokreće dodjelu električne punionice nakon zaprimljenog zahtjeva za punjenje baterija električnih čistilica. Po odabiru električne punionice, agent *Spremište vozila* šalje informaciju o električnoj punionici agentu *Električna čistilica* koji se usmjerava prema dodijeljenoj električnoj punionici.

Algoritam 3: Usmjeravanje prema električnoj punionici

Ulaz: $EPS[EP], EC$
Izlaz: $EP_{\{EC\}}$

```
1  početak
2      LS[EP_l^{EC}] ← ∅
3      za svaki EP ∈ EPS čini
4          Q^{EP} ← EP_Q
5          ako Q^{EP} = OPERATIONAL onda
6              [EP_l^{EC} ← l geolokacijske rute EC za EP
7              dodaj [EP_l^{EC} u LS[EP_l^{EC}]
8          kraj
9      kraj
10     EP_l^{EC} ← odredi najmanju duljinu l rute iz LS[EP_l^{EC}]
11     uzmi EP iz EP_l^{EC} i stavi u EP^{EC}
12     vrati EP^{EC}
13 kraj
```

4.3Algoritmi zasnovani na umjetnoj inteligenciji

Algoritmi zasnovani na umjetnoj inteligenciji (eng. *artificial inteligence (AI)*) proširenje su prethodno definiranih osnovnih algoritama temeljenih na problemu usmjeravanja vozila s kapacitetom i vremenskim okvirom. Definicija kapaciteta ostaje jednaka kao i kod osnovnih algoritama te je jednaka broju električnih čistilica za čišćenje gradskih parkirališnih površina. Razlika između osnovnih algoritama i algoritama zasnovanih na AI-u jest kod definiranja vremenskog okvira unutar kojeg električne čistilice moraju očistiti određeno parkiralište. Model VAS-UEV definira vremenski okvir za osnovne algoritme jednako za sva parkirališta te je vrijeme početka i završetka vezano uz radno vrijeme gradskih komunalnih službi. Algoritam zasnovan na AI-u na temelju informacija koje pruža model AI-a određuje početak vremenskog okvira zasebno za svako parkiralište. Kod usmjeravanja prema električnim čistilicama, model AI-a pruža informacije o električnim punionicama na temelju kojih se može odrediti električna punionica za ostvarivanje što bržeg punjenja električne čistilice, dok se kod osnovnih algoritama uvijek traži najbliža električna punionica električnoj čistilici. Model VAS-UEV pomoću modela AI-a izgrađenih metodama strojnog učenja (eng. *machine learning (ML)*) pruža potrebne informacije algoritmima za usmjeravanje električnih čistilica kako bi se optimizirali rezultati funkcije cilja.

4.3.1Usmjeravanje prema parkiralištu

Algoritam zasnovan *na AI-u za usmjeravanje prema parkiralištu* (AI-UP) prikazan algoritmom 4 proširenje je osnovnog algoritma za *usmjeravanje prema parkiralištu* (UP) opisan algoritmom 1. Algoritam AI-UP definiran je jednako kao i algoritam UP s dvjema fazama: fazom planiranja i fazom izvršavanja. Proširenje algoritma AI-UP u fazi planiranja određeno je integracijom modela AI-a za predviđanje iskoristivosti parkirališta kojim se predviđa popunjenost parkirališta za traženo vrijeme. Model *iskoristivosti parkirališta* (IP) predviđa iskoristivost parkirališta za traženo vrijeme na temelju kojih algoritam AI-UP definira početak vremenskog okvira unutar kojeg će parkiralište biti očišćeno električnom čistilicom. Razlikujemo dva modela IP koja ovise o tipu parkirališta za koje se upotrebljava. Za ulična parkirališta definiran je model *iskoristivosti uličnog parkirališta* (IUP), a za vanulična parkirališta definiran je model *iskoristivosti vanuličnog parkirališta* (IVP). Modeli IUP i IVP opisani su u poglavlju 4.4. Faza izvršavanja algoritma AI-UP također predstavlja proširenje faze izvršavanja algoritma UP tako da su pružene dodatne provjere koje su rezultat različitih vremenskih okvira za svako parkiralište.

Faza planiranja algoritma AI-UP prikazana je algoritmom 4 koji na ulaz prima skup parkirališta *PS* koje treba očistiti, modele IUP i IVP i vremenski okvir određen s vremenom početka t_p i vremenom završetka t_k. Vremenski okvir upotrebljava se kao interval unutar kojeg se traži vrijeme za početak čišćenja t_{pc} određenog parkirališta koristeći pritom dobivene informacije modela IUP ili IVP. Za svako parkiralište P iz skupa PS, algoritam AI-UP prvo provjerava stanje parkirališta P koje ako nije operativno i dostupno za parkiranje vozila, bit će izuzeto iz ciklusa čišćenja. Za svako operativno parkiralište P predviđa se iskoristivost pomoću modela IUP za ulično parkiralište P ili modela IVP za vanulično parkiralište P. Predviđanje iskoristivosti odvija se za svakih sat vremena unutar zadanog vremenskog okvira s ulaza algoritma AI-UP. Vremenski okvir predstavlja ograničenje koje određuje gradska komunalna služba, pri čemu vrijeme t_p predstavlja minimalno vrijeme početka izvršavanja zadataka, dok vrijeme t_k predstavlja maksimalno vrijeme početka izvršavanja zadataka čišćenja. Ukoliko gradska komunalna služba zahtijeva da se parkirališta čiste svaki dan unutar radnog vremena, utoliko se s ovakvim zadanim vremenskim okvirom to osigurava. Na temelju dobivene liste iskoristivosti parkirališta modela IP za svaki sat unutar zadanog vremenskog okvira, algoritam AI-UP uzima vrijeme iz liste za koje je dobivena najmanja iskoristivost parkirališta i označava ga kao vrijeme početka čišćenja t_{pc}. Algoritam AI-UP stvara zadatak za čišćenje ZC za parkiralište P s početkom t_{cp} i dodaje ga u skup zadataka za čišćenje ZCS. Skup zadataka za čišćenje ZCS algoritam predaje na izlaz i time završava faza planiranja.

Faza izvršavanja algoritma AI-UP prikazana je algoritmom 5 i predstavlja proširenje osnovnog algoritma definiranog algoritmom 2. Ulaz algoritma AI-UP skup je trenutno dostupnih zadataka za čišćenje ZCS_D i skup dostupnih električnih čistilica ECS_D za koje se dodjeljuju zadaci za čišćenje ZC iz skupa ZCS_D. Ulaz kod osnovnog algoritma bio je skup svih zadataka za

Algoritam 4: Usmjeravanje prema parkiralištu zasnovano na modelu umjetne inteligencije - faza planiranja

Ulaz: $PS[P]$, IUP_{model}, IVP_{model}, t_p, t_k
Izlaz: $ZCS[ZC^{\{P\}}]$

Funkcija `predikcijaIskoristivosti`(P, t_p, t_k, IP_{model})**:**
  $IPS[IP_t^{\{P\}}] \leftarrow \emptyset$
  $t \leftarrow t_p$
  dok $t \leq t_k$ **čini**
    $IP_t^{\{P\}} = IP_{model}(P,t)$
    dodaj $IP_t^{\{P\}}$ u $IPS[IP_t^{\{P\}}]$
    dodaj 1 sat u t
  kraj
  vrati $IPS[IP_t^{\{P\}}]$
Funkcija `odrediVrijemePocetka`($IPS[IP_t^{\{P\}}]$)**:**
  $IPmin_t^{\{P\}} \leftarrow$ uzmi najmanju vrijednost $IP_t^{\{P\}} \in IPS[IP_t^{\{P\}}]$
  $t_{pc} \leftarrow$ uzmi t iz $IPmin_t^{\{P\}}$;
  vrati t_{pc}
početak
  $ZCS[ZC^{\{P\}}] \leftarrow \emptyset$
  za svaki $P \in PS$ **čini**
    $Q^{\{P\}} \leftarrow P_Q$
    ako $Q^{\{P\}} = OPERATIONAL$ **onda**
      $T^{\{P\}} \leftarrow P_{tip}$
      ako $T^{\{P\}} = ONSTREET$ **onda**
        $IPS[IP_t^{\{P\}}] =$ **predikcijaIskoristivosti**(P,t_p,t_k,IUP_{model})
      inače
        $IPS[IP_t^{\{P\}}] =$ **predikcijaIskoristivosti**(P,t_p,t_k,IVP_{model})
      kraj
      $t_{pc} =$ **odrediVrijemePocetka**$(IPS[IP_t^{\{P\}}])$
      $ZC^{\{P\}} \leftarrow$ stvori $ZC^{\{P\}}$ za P i postavi vrijeme početka t_{pc}
      dodaj $ZC^{\{P\}}$ u $ZCS[ZC^{\{P\}}]$
    kraj
  kraj
  vrati $ZCS[ZC^{\{P\}}]$
kraj

Algoritam 5: Usmjeravanje prema parkiralištu zasnovano na modelu umjetne inteligencije - Faza izvršavanja

Ulaz: $ZCS_D[ZC^{\{P\}}], ECS_D[EC]$
Izlaz: $ZCS_A[ZC^{\{(P,EC)\}}]$

Funkcija `uzmiVozilo(`$ZC^{\{P\}}$, ECS`)`**:**
    $EC \leftarrow$ pronađi $EC \in ECS$ s najkraćom geolokacijskom rutom za P iz $ZC^{\{P\}}$
    vrati EC
početak
    $ZCS_A[ZC^{\{(P,EC)\}}] \leftarrow \emptyset$
    ako $ECS_D \in \emptyset$ **onda**
        vrati $ZCS_A[ZC^{\{(P,EC)\}}]$
    kraj
    ako $ZCS_D \in \emptyset$ **onda**
        vrati $ZCS_A[ZC^{\{(P,EC)\}}]$
    kraj
    za svaki $ZC^{\{P\}} \in ZCS_D$ **čini**
        ako $ECS_D \in \emptyset$ **onda**
            Prekid izvršavanja petlje
        kraj
        $EC = uzmiVozilo(ZC^{\{P\}}, ECS)$
        makni EC iz ECS_D
        postavi EC za $ZC^{\{P\}}$ u $ZC^{\{(P,EC)\}}$
        dodaj $ZC^{\{(P,EC)\}}$ u $ZCS_A[ZC^{\{(P,EC)\}}]$
    kraj
    vrati $ZCS_A[ZC^{\{(P,EC)\}}]$
kraj

čišćenje ZCS iz faze planiranja jer su sva parkirališta imala postavljen jednaki vremenski okvir, što rezultira time da zadaci za čišćenje imaju jednako vrijeme početka čišćenja parkirališta. U algoritmu AI-UP svako parkiralište P iz skupa PS ima potencijalno različiti vremenski okvir određujući pritom za svaki zadatak za čišćenje ZC različito vrijeme početka čišćenja parkirališta. Time se postiže da skup ZCS_D može biti prazan na ulazu u algoritam AI-UP. Iz tog razloga algoritam AI-UP pruža dodatnu provjeru za skup ZCS_D tako da ako nema zadataka za čišćenje ZC koji se mogu dodijeliti trenutačno dostupnim električnim čistilicama ECS_D, on zaustavlja svoj rad i signalizira procesu za izvršavanje zadataka da električne čistilice moraju pričekati sljedeći dostupan zadatak. Pojavom dostupnih zadataka za čišćenje, proces za izvršavanje zadataka pokreće algoritam AI-UP radi dodjele zadataka dostupnim električnim čistilicama iz skupa ECS_D po principu najkraće rute do parkirališta P iz zadatka za čišćenje ZC. Za svaki zadatak ZC kojem je dodijeljena električna čistilica EC stavlja se u skup zadataka za izvršavanje ZCS_D koji definiraju izlaz algoritma AI-UP u fazi izvršavanja.

4.3.2Usmjeravanje prema elektri čnoj punionici

Algoritam zasnovan *na AI-u za usmjeravanje prema električnim punionicama* (AI-UEP) prikazan algoritmom 6 predstavlja proširenje osnovnog algoritma za usmjeravanje prema električnim punionicama (UEP) prikazan algoritmom 3 s modelom AI-a za predviđanje iskoristivosti električne punionice. Model *iskoristivosti električne punionice* (IEP) korišten u algoritmu AI-UEP opisan je u poglavlju 4.4. Ulaz u algoritam AI-UEP jest skup električnih punionica EPS, električna čistilica EC kojoj treba dodijeliti električnu punionicu i model iskoristivosti električne

Algoritam 6: Usmjeravanje prema električnoj punionici zasnovano na modelu umjetne inteligencije

Ulaz: $EPS[EP], EC, IEP_{model}$
Izlaz: $EP_{\{EC\}}$

početak
  $LS[EP_l^{\{EC\}}] \leftarrow \emptyset$
  $IEPS[IEP_t^{\{EP\}}] \leftarrow \emptyset$
  za svaki $EP \in EPS$ **čini**
    $Q^{\{EP\}} \leftarrow EP_Q$
    ako $Q^{\{EP\}} = OPERATIONAL$ **onda**
      $[EP_l^{\{EC\}} \leftarrow l$ geolokacijske rute EC za EP
      dodaj $[EP_l^{\{EC\}}$ u $LS[EP_l^{\{EC\}}]$
      $IEP_t^{\{EP\}} \leftarrow \mathbf{IEP_{model}}(\mathbf{t}, \mathbf{EP})$
      dodaj $IEP_t^{\{EP\}}$ u $IEPS[IEP_t^{\{EP\}}]$
    kraj
  kraj
  $EP^{\{EC\}} \leftarrow$ dodijeli EP iz $EP_l^{\{EC\}} \in LS[EP_l^{\{EC\}}]$ koji ima najmanju vrijednost l
  $LIEPS[LIEP_t^{EP}] = LS_l^{EC} * IEP_t^{EC}$
  $LIEPmin_t^{\{EP\}} \leftarrow$ uzmi prvi $LIEP_t^{\{EP\}}$ iz $LIEPS[LIEP_t^{\{EP\}}]$
  za svaki $LIEP_t^{\{EP\}} \in LIEPS[LIEP_t^{\{EP\}}]$ **čini**
    ako $LIEP_t^{\{EP\}} < LIEPmin_t^{\{EP\}}$ **onda**
      $EP \leftarrow$ dodijeli EP iz $IEP_t^{\{EP\}}$
      $LIEPmin_t^{\{EP\}} = LIEP_t^{\{EP\}}$
      $EP^{\{EC\}} = EP$
    kraj
  kraj
  vrati $EP^{\{EC\}}$
kraj

punionice IEP_{model}. Za svaku električnu punionicu EP iz EPS algoritam AI-UEP provjerava stanje električne punionice koja ako nije operativna, izuzima se iz skupa električnih punionica za dodjelu električnoj čistilici EC. Algoritam AI-UEP za svaku operativnu električnu punionicu izračunava udaljenost l od električne čistilice EC do električne punionice EP te rezultat dodaje u skup LS. Zatim algoritam pomoću modela IEP predviđa iskoristivosti IEP svake operativne električne punionice za sljedećih sat vremena, jer električna čistilica mora obaviti punjenje unutar sljedećih sat vremena od trenutka traženja dodjele električne punionice te rezultat stavlja u skup $IEPS$. Algoritam AI-UEP odabire električnu punionicu EP iz skupova LS i $IEPS$ tako da uzima električnu punionicu koja je što bliže električnoj čistilici sa što manjom vrijednošću iskoristivosti električne punionice. Odabrana električna punionica EP šalje se na izlaz algoritma AI-UEP te agent *Spremište vozila* obavještava agenta *Električna čistilica* o izabranoj električnoj punionici prema kojoj se kreće usmjeravati.

4.4Modeli iskoristivosti

Algoritmi zasnovani na AI-u proširenje su prethodno definiranih studijskih algoritama s modelima AI-a ostvarenim metodama ML-a. Za potrebe usmjeravanja električnih čistilica prema parkiralištima potrebno je ostvariti dva modela AI-a: model iskoristivosti uličnog parkirališta i model iskoristivosti vanuličnog parkirališta. Model iskoristivosti uličnog parkirališta namijenjen je za potrebe usmjeravanja prema parkiralištu uličnog tipa čija su mjesta pokrivena s prizemnim senzorima za indikaciju prisutnosti vozila. Model iskoristivosti vanuličnog parkirališta namijenjen je za potrebe usmjeravanja prema parkiralištima vanuličnog tipa koji posjeduju ulaznu barijeru u obliku rampe. Za potrebe usmjeravanja električne čistilice prema električnoj punionici potrebno je ostvariti model iskoristivosti električne punionice.

Modeli iskoristivosti uličnog i vanuličnog parkirališta predviđaju iskoristivost parkirališta za određeni trenutak. Iskoristivost parkirališta definira se kao iskorišteno vrijeme parkiranja od ukupnog vremena parkiranja koje parkiralište može ponuditi unutar sat vremena. Ukupno vrijeme parkinga u satima jednako je broju parkirališnih mjesta koje parkiralište može ponuditi te ujedno definiraju kapacitet parkirališta.

Model iskoristivosti električne punionice predviđa iskoristivost električne punionice. Iskoristivost električne punionice definira se kao iskorišteno vrijeme punjenja od ukupnog vremena punjenja koje električna punionica može ponuditi unutar sat vremena. Ukupno vrijeme punjenja u satima jednako je broju priključaka električne punionice koje može ponuditi te ujedno definiraju kapacitet električne punionice.

4.4.1Metodologija

Za ostvarivanje modela iskoristivosti korištenih u algoritmima zasnovanim na AI-u potrebno je definirati metodologiju koja će biti korištena za ostvarivanje analize podataka. Metodologija za ostvarivanje modela iskoristivosti prikazana je na slici 4.2 i temelji se na *Cross-industry Standard Process for Data Mining CRISP-DM*[114]. CRISP-DM je često korištena metodologija u obradi podataka i upravo zbog toga odabrana je kao referentna metodologija za ostvarivanje modela iskoristivosti. Upotrebom metodologije CRISP-DM u obradi i procesiranju podataka mogu se spoznati zanimljivi obrasci ponašanja i izranjajuća ponašanja koja se kasnije mogu primijeniti za daljnje analize podataka. Procesiranje podataka za ostvarivanje modela iskoristivosti metodologijom prikazanom na slici 4.2 prolazi kroz 9 faza: *razumijevanje domene, definiranje analitičkog pristupa, definiranje potrebnih podataka, prikupljanje podataka, razumijevanje podataka, obrada podataka, priprema podataka, stvaranje modela iskoristivosti, evaluacija modela iskoristivosti i primjena modela iskoristivosti*. Svih devet faza metodologije bit će opisano u nastavku za slučaj grada Splita.

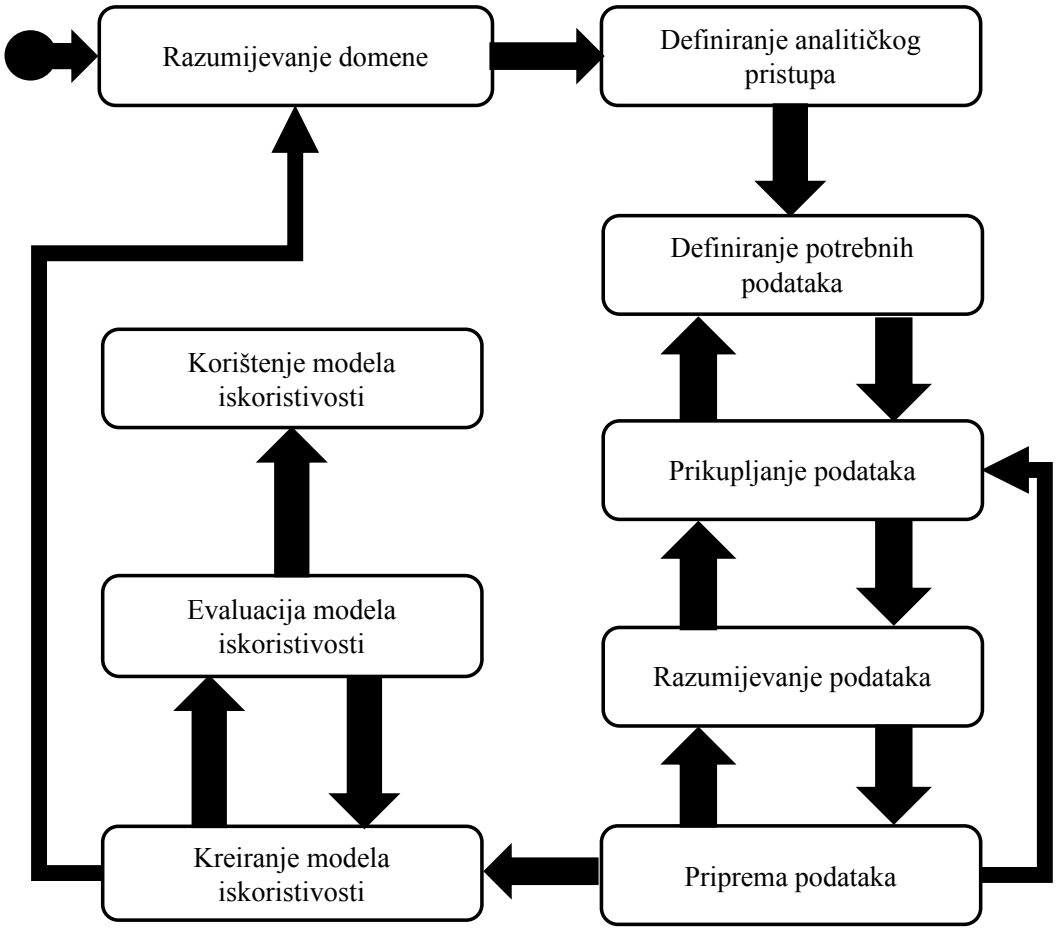

Slika 4.2: Metodologija za stvaranje modela iskoristivosti

4.4.2Razumijevanje domene

Razumijevanje rada gradskog parkinga i električnih punionica vrlo je važno za definiranje izazova i zahtjeva koje treba adresirati s modelima iskoristivosti. Grad Split transformirao je gradska ulična parkirališta tako da je svako parkirališno mjesto pokriveno s prizemnim senzorom koji ukazuje je li parkirališno mjesto zauzeto ili slobodno. Prizemnim senzorima pokriveno je 1.516 parkirališnih mjesta koja se nalaze na 50 uličnih parkirališta. Svako parkirališno mjesto generira senzorske podatke koji se pokazuju u aplikaciji *Split Parking*[*] za pametne pokretne uređaje. Aplikacija *Split Parking* službena je aplikacija grada Splita te uz aplikaciju *Bmove*[†] tvrtke *Paydo Services* omogućuje kupnju parkirališnih karata. Grad Split transformirao je vanulična parkirališta tako da je uveo barijere u obliku rampe koja je povezana s internetom i koja šalje podatke o upotrebi parkirališta. Podaci rampe definiraju zapise o ulascima i izlascima vozila s parkirališta putem kojih se definira trenutačna popunjenost parkirališta. Grad Split sadrži 10 vanuličnih parkirališta koja pružaju 1.445 parkirališnih mjesta. Aplikacija *Split Parking* pruža informacije o trenutačnoj popunjenosti vanuličnih parkirališta svojim korisnicima te zajedno uz aplikaciju *Bmove* omogućuje plaćanje parkirališne karte.

Korisnici aplikacije *Split Parking* mogu vidjeti dostupna parkirališna mjesta i popunjenost vanuličnih parkirališta u gradu i mogu odabrati mogućnost navigiranja do samog parkirališta. Jednom kad korisnik parkira vozilo na željeno parkirališno mjesto, onda u slučaju uličnog parkirališta prizemni će senzor ukazivati da je mjesto zauzeto, dok će kod vanuličnog parkirališta rampa ukazivati na povećanje zauzetosti, a takve će promjene stanja ostali korisnici vidjeti u aplikaciji. Ono što nedostaje u aplikaciji jesu podaci o trendovima upotrebe gradskih parkirališta i mogućnost predviđanja iskoristivosti parkirališta. Predviđanjem iskoristivosti parkirališta, korisnici mogu brže pronaći željeno parkirališno mjesto bez gubljenja vremena na traženje kružeći po gradu. Iskoristivost parkirališta može se modelirati modelima iskoristivosti uličnog i vanuličnog parkirališta pomoću kojih korisnici mogu dobiti predviđanje dostupnosti uličnih i vanuličnih parkirališnih mjesta. Gradske službe pomoću modela mogu postići održivo i učinkovito korištenje gradskim resursima, kao na primjer učinkovitiju upotrebu električnih čistilica za čišćenje gradskih uličnih i vanuličnih parkirališnih površina.

U Hrvatskoj postoji 138 električnih punionica kojima upravlja operator Hrvatski Telekom (HT). U gradu Splitu instalirano je 7 električnih punionica. Na električnim punionicama mogu se puniti sva električna vozila koja su proizvedena u skladu sa standardom IEC-61851. To uključuje gotovo sva serijski proizvedena vozila PHEV (eng. *plug-in hybrid electric vehicle*) i potpuno električna vozila (eng. *full electric vehicle*), kao i ona prerađena električna vozila za koja je ishođena odgovarajuća homologacija. Električne punionice prije korištenja zahtijevaju prijavu i identifikaciju. Za njihovo korištenje mora se prethodno sklopiti ugovor s pružateljem

[*]Aplikacija "Split Parking" - https://play.google.com/store/apps/details?id=profico.splitparking
[†]Aplikacija "Bmove" - https://play.google.com/store/apps/details?id=hr.infoart.epk

usluga punjenja koji nudi svoje usluge na tim punionicama. Pružatelj usluga po sklapanju ugovora izdat će pametnu identifikacijsku karticu. Identifikacija se, osim putem identifikacijskih kartica, može vršiti i pomoću aplikacije Hrvatskog Telekoma espoTs[‡].

Razlikujemo dvije vrste električnih punionica operatora Hrvatkog Telekoma: električne punionice bez identifikacije korisnika i električne punionice s identifikacijom korisnika. Električne punionice bez identifikacije korisnika jednostavne su za korištenje, jer korisnik za početak punjenja mora uključiti samo svoj kabel u punionicu i vozilo te punjenje baterije električnog vozila započinje automatski. Takve električne punionice nazivaju se *priključi i puni* (eng. *Plug&Charge*). Električne punionice s identifikacijom korisnika zahtijevaju prije početka punjenja identifikaciju korisnika putem beskontakne identifikacijske kartice ili putem aplikacije espoTs. Ovime se sprječava neovlašteni pristup punionicama te omogućuje jednostavniju naplatu usluge punjenja. Operator Hrvatski Telekom razlikuje brze i standardne električne punionice. Na brzim punionicama omogućuju punjenje istosmjernom strujom (DC) snagama od 50 i više kW te se baterija električnog vozila kapaciteta do 40 kWh može napuniti u manje od pola sata. Standardne punionice imaju priključnu snagu do 22 kW i koriste izmjeničnu struju (AC) te je za punjenje baterije električnog vozila kapaciteta do 40 kWh potrebno od pola sata do nekoliko sati.

Operatori mreže punionica i pružatelji usluga tijekom izrade istraživanja u ovom radu nisu naplaćivali punjenja u gradu Splitu i bile dostupne bez potrebne prethodne identifikacije korisnika. Korisnici aplikacije espoTs mogu vidjeti trenutačnu dostupnost punionica, ali ne mogu vidjeti dostupnost za određeni trenutak u budućnosti te time ne mogu planirati punjenja baterije pa time riskiraju moguće duže čekanje na početak punjenja na odabranoj punionici. Stvaranjem modela iskoristivosti električne punionice možemo predviđati iskoristivosti električne punionice te korisnici mogu dobiti informaciju o dostupnosti električne punionice za određeni trenutak u budućnosti. Time se može postići kraće punjenje baterije na punionici bez potrebe čekanja u redu na punionici. Prikaz trendova upotrebe električnih punionica i predviđanje iskoristivosti može se ponuditi korisnicima u aplikaciji espoTs.

Grad Split ima 170 tisuća stanovnika i tijekom turističke sezone posjeti ga više od 20 milijuna turista svake godine stvarajući veliki pritisak na gradsku infrastrukturu. S modelima iskoristivosti uličnog i vanuličnog parkirališta te modelom iskoristivosti električnih punionica nudi se bolji uvid u predviđanje iskoristivosti parkirališta i električnih punionica koji se na temelju toga mogu odlučiti na upotrebu javnog prijevoza umjesto osobnog vozila ili mogu puniti vozila kod kuće umjesto na električnim punionicama. Ovime se smanjuje pritisak na gradsku infrastrukturu te u slučaju vozila s unutarnjim izgaranjem kojima je potreban parking u gradu, može se reducirati zagađenje zraka poboljšavajući time kvalitetu života u gradu.

[‡]Aplikacija "espoTs" - https://play.google.com/store/apps/details?id=hr.tht.espots

4.4.3Definiranje analiti čkog pristupa

Za ostvarivanje modela iskoristivosti uličnog i vanuličnog parkirališta i modela iskoristivosti električnih punionica moramo definirati analitički pristup kojim ćemo ih ostvariti. Parkirališta opremljena prizemnim senzorima i rampama povezanim s internetom te električne punionice povezane s internetom stvaraju velike količine podataka koje treba obraditi s određenom tehnikom za procesiranje podataka. Eksploatacijska analiza podataka početni je proces analize podataka čija primjena pruža bolje razumijevanje podataka opisujući i definirajući njihove glavne karakteristike, koristeći pritom vizualizacije kao što su histogrami i dijagrami okvira. Prvi korak u procesiranju podataka opisna je analiza koja istražuje i objašnjava prikupljeni skup podataka kroz njegove karakteristike i trendove. Za modele iskoristivosti bit će definirani histogrami i dijagrami okvira za prosječni dan i tjedan, s ciljem uočavanja trendova iskoristivosti uličnog i vanuličnog parkirališta te električnih punionica. Dijagrami okvira mogu prikazati podatke van okvira koji definira i koji je potrebno razriješiti kako bi se postigao što bolji model iskoristivosti. Osim eksploatacijske analize povijesnih podataka, potrebno je predviđati iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta. Predviđanje iskoristivosti može se postići prediktivnom analizom. Prediktivna analiza temelji se na korelacijima unutar povijesnih podataka i rezultatima dobivenim opisnom analizom pomoću kojih se stvara jedan ili više prediktivnih modela. Svaki model definiran je s metodom strojnog učenja (eng. *machine learning - ML*) i podacima koje metoda ML upotrebljava. U ovom je radu korišten pristup nadziranog ML-a s odgovarajućim metodama ML-a za ostvarivanje modela iskoristivosti.

Za ostvarivanje modela iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta upotrebljava se *Random Forest* kao metoda ML-a. Budući da blisko surađujemo s industrijskim partnerima koji su pružili potrebne podatke za modele iskoristivosti, proizvodni proces vrlo je važan faktor koji mora uključivati model s metodom ML-a koja je prikladnija za upotrebu u proizvodnom okruženju. Stoga se za potrebe ostvarivanja modela iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta upotrebljava i metoda ML-a *CatBoost*. *CatBoost* metoda je prikladnija za korištenje u produkcijskim okruženjima zbog jednostavne uporabe, bržeg učenja modela i optimizacije rada na grafičkim procesorima omogućujući brži i skalabilniji rad. *Random Forest* algoritam je koji se temelji na stablu odlučivanja i upotrebljava se za rješavanje različitih regresijskih i klasifikacijskih problema [115] te je uobičajena metoda ML-a u mnogim prediktivnim analizama [116]. *Random Forest* temelji se na ansambl-metodi ML-a *bagging*, gdje se stvara veliki broj paralelnih i nepovezanih stabala odlučivanja. Svako stablo uči na nasumičnom podskupu istih podataka, a konačni rezultat predviđanja definira se kao prosjek rezultata svih stabala. *CatBoost* je, s druge strane, algoritam zasnovan na stablu odlučivanja s gradijentom i moćan je alat za zadatke klasifikacije i regresije u *Big Dati* [117]. *CatBoost* se za razliku od *Random Foresta* temelji na ansambl-metodi učenja zvanoj *gradient boosting* koja kombinira veći broj slabijih modela kako bi se postigao jači model. Svaki slabiji model

predstavlja jedno stablo odlučivanja i povezan je u niz s drugim slabijim modelima. Slijedom svaki slabiji model pokušava smanjiti pogrešku predviđanja prethodnog i uklapa se s ostacima prethodnog slabog učenika, koji se detektiraju definiranom funkcijom gubitka. Konačni model dodaje rezultat svakog koraka i time se postiže jači model.

Svaka metoda ML-a kao ulaz uzima skup varijabli koje se bave svojstvima i specifičnostima skupa podataka na mjerljiv način. Model upotrebljava ulazne varijable u svrhu predviđanja te one imaju i izravan utjecaj na performanse modela. Cilj AI/ML-a jest pronaći skup varijabli kojima model ostvaruje najbolji rezultat u predviđanju jer svaka varijabla modela ne pridonosi podjednako krajnjem rezultatu modela. Metode *Random Forest* i *CatBoost* pružaju informacije o važnosti svake ulazne varijable za ostvarivanje modela. Važnost svake varijable modela može se upotrijebiti kod procesa eliminacije ulaznih varijabli modela kako bi se dobio optimalni skup varijabli kojima se ostvaruje najbolji AI/ML model. Obje će se metode ML-a upotrijebiti za izvedbu regresijskih zadataka u modelima iskoristivosti. *Random Forest* kao metoda ML-a koristi se manjim skupom parametara za definiranje metode u odnosu za *CatBoost* čime se postiže jednostavnije korištenje. No *CatBoost* omogućava samostalne optimizacije parametra i bolje upravljanje kategoričkim varijablama [118]. *Random Forest* i *CatBoost* upotrijebljeni su u ostvarivanju modela iskoristivosti uličnog i vanuličnog parkirališta, dok je za model iskoristivosti električnih punionica upotrijebljen samo *Random Forest*.

Modeli iskoristivosti imat će dva pristupa u stvaranju: osnovni pristup i kontekstni pristup. Osnovni pristup stvaranju modela iskoristivosti uličnog parkirališta služi se povijesnim podacima dobivenim prizemnim senzorima, dok se model iskoristivosti vanuličnog parkirališta koristi povijesnim podacima rampe. Model iskoristivosti električnih punionica upotrebljava povijesne podatke o upotrebi električnih punionica. Kontekstni pristup temelji se na upotrebi kontekstnih podataka koji predstavljaju utjecajni faktor na iskoristivost električnih punionica, uličnih i vanuličnih parkirališta. Evaluacija modela iskoristivosti s različitim metodama ML-a i podatkovnih pristupa provedena je nad stvarnim podacima koje je dao grad Split. Svi se modeli međusobno uspoređuju kako bi identificirali metode ML-a i podatkovnog pristupa koji daje najbolje rezultate.

4.4.4Definiranje, prikupljanje i razumijevanje podataka

Analitički pristup definira modele iskoristivosti koji moraju biti ostvareni za potrebe algoritama usmjeravanja električnih vozila. Za ostvarivanje modela iskoristivosti potrebno je definirati podatke sa slike 4.3, koji se moraju prikupiti i razumjeti. Model iskoristivosti uličnog parkirališta temelji se na podacima o upotrebi uličnog parkirališta prikupljenih s prizemnih parkirališnih senzora postavljenih na svako parkirališno mjesto. Za ostvarivanje modela iskoristivosti vanuličnog parkirališta potrebni su podaci o korištenju vanuličnog parkirališta dohvaćeni s rampe koja predstavlja fizičku barijeru za ulazak i izlazak iz parkirališta. Model iskoristivosti elek-

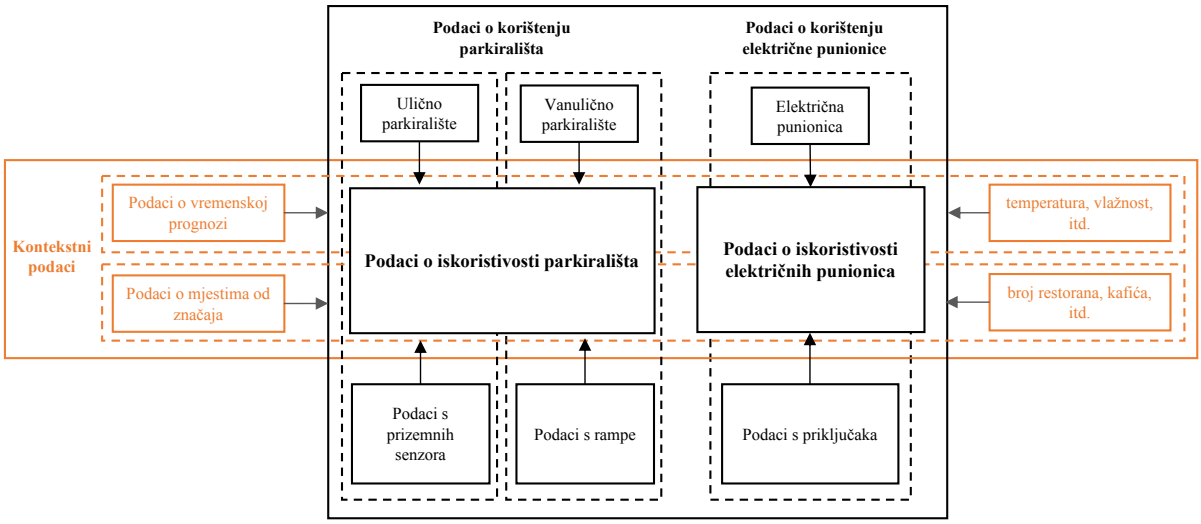

Slika 4.3: Pregled podataka za modele iskoristivosti

trične punionice ostvaruje se podacima o upotrebi električne punionice dobivenih s priključaka električnih punionica. Analitički pristup, uz osnovni, definira i kontekstni pristup za koji je potrebno prikupiti kontekstne podatke vezane uz parkirališta i električne punionice.

Podaci o uličnim parkiralištima

Primarni podaci za ostvarivanje modela iskoristivosti uličnog parkirališta jesu očitanja prizemnih parkirališnih senzora smještenih na svako parkirališno mjesto u gradu Splitu. Generirana senzorska očitanja šalju se u oblak (eng. *cloud*) koji je u vlasništvu grada. U oblaku senzorska

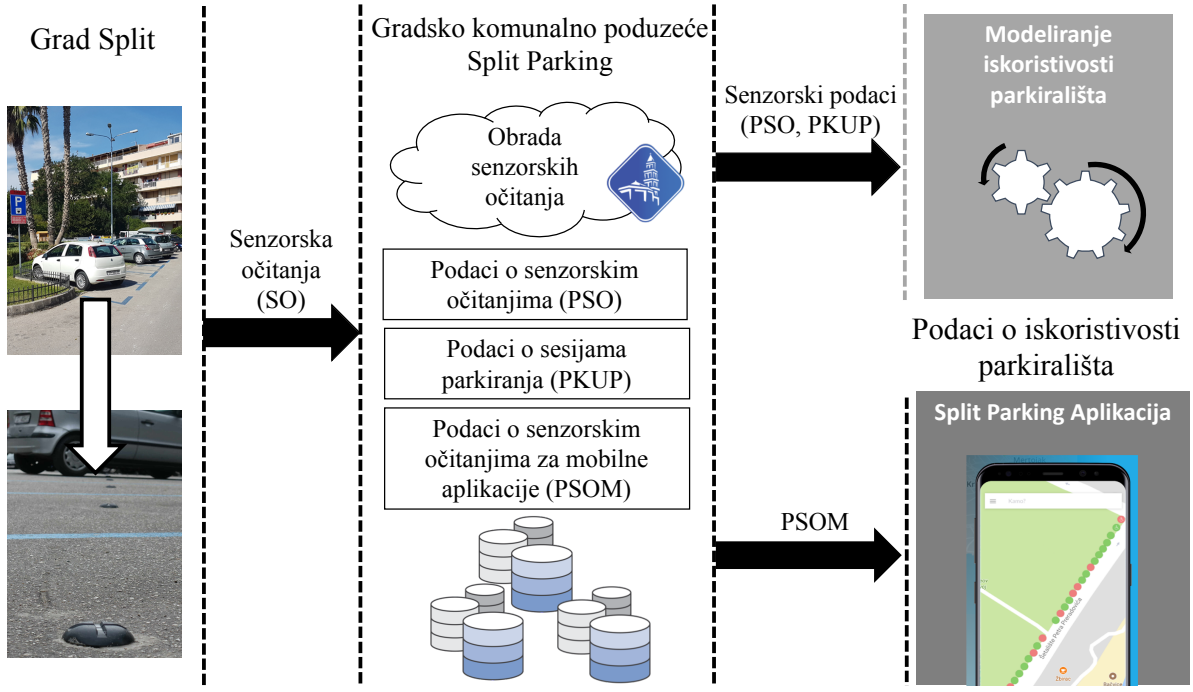

Slika 4.4: Proces prikupljanja podataka o korištenju uličnih parkirališta

Tablica 4.1: Prikaz podataka o senzorskim očitanjima uličnih parkirališta

Id mjesta	Zauzeto	Stvoren
16	1	2018-01-01 13:11:29
1	1	2018-01-01 13:12:54
24	0	2018-01-01 13:19:33
13	0	2018-01-01 13:22:32
8	1	2018-01-01 13:22:19
16	1	2018-01-01 13:30:55
24	0	2018-01-01 13:37:44

se očitanja procesiraju i pritom se stvaraju podaci o senzorskim očitanjima (PSO), podaci o korištenju parkirališta (PKUP) i podaci o senzorskim očitanjima za mobilne aplikacije (PSOM). Podaci PSOM upotrebljavaju se u aplikaciji grada Splita pod nazivom Split Parking za prikazivanje slobodnih i zauzetih parkirališnih mjesta u stvarnom vremenu. Za pristup i upotrebu podataka PSO i PKUP potrebno je dobiti dopuštenje grada Splita. Na temelju dopuštenja, može se pristupiti prikupljanju podataka PSO i PKUP s gradskog oblaka za ostvarivanje modela iskoristivosti uličnog parkirališta. Proces prikupljanja podataka o korištenju uličnih parkirališta prikazan je na slici 4.4. Podaci PSO predstavljaju senzorska opažanja generirana s prizemnih parkirališnih senzora i prikazani su u tablici 4.1. Razlikuju se dva tipa senzorskih opažaja:

•PO ČETAK - predstavlja početak zauzeća parkirališnog mjesta;

•KRAJ - predstavlja završetak zauze ća parkirališnog mjesta;

•STATUS - predstavlja status senzora (razina baterije, radni status).

Svaki zapis podataka PSO sastoji se od sljedećih polja:

•Id mjesta - jedinstveni identifikator mjesta uli čnog parkirališta;

Tablica 4.2: Prikaz podataka o sesijama parkiranja uličnih parkirališta

Id mjesta	Početak	Kraj	Stvoren
2	2017-02-01 08:04:06	2017-02-01 10:24:55	2018-01-10 09:58:47
3	2017-02-01 08:02:23	2017-02-01 17:11:14	2018-01-10 09:58:47
4	2017-02-01 08:15:30	2017-02-01 16:06:42	2018-01-10 09:58:47
5	2017-02-01 08:32:12	2017-02-01 17:02:51	2018-01-10 09:58:47
6	2017-02-01 08:45:36	2017-02-01 17:11:17	2018-01-10 09:58:47
7	2017-02-01 08:15:10	2017-02-01 16:33:39	2018-01-10 09:58:47
8	2017-02-01 08:32:19	2017-02-01 17:26:24	2018-01-10 09:58:47

•Zauzeto - definira zauzetost parkirališnog mjesta, gdje vrijednost 1 ozna čava da je mjesto zauzeto, dok vrijednost 0 označava da je mjesto slobodno;

•Stvoren - definira vrijeme stvaranja zapisa senzorskog o čitanja.

Podaci PSO obrađuju se u gradskom oblaku stvarajući pritom zapise podataka PKUP i PSOM. Podaci PKUP definiraju sesije parkiranja koje su ostvarene na određenom parkirališnom mjestu i primjer podataka je prikazan u tablici 4.2. Svaki zapis iz PKUP-a sastoji se od sljedećih polja:

•Id mjesta - jedinstveni identifikator parkirališnog mjesta;

•Po četak - vrijeme početka sesije parkiranja i jednako je vremenu početka zauzeća prizemnog senzora;

•Kraj - vrijeme završetka sesije parkiranja i jednako je vremenu završetka zauze ća prizemnog senzora;

•Stvoren - vrijeme stvaranja zapisa.

Za potrebe stvaranja modela iskoristivosti uličnog parkirališta prikupljaju se podaci PSO i PKUP. Podaci PKUO za grad Split prikupljeni su za 50 uličnih parkirališta za razdoblje od 1. siječnja 2017. godine i sve do 1. lipnja 2020. godine te sadrže 35.648.520 senzorskih očitanja.

Podaci o vanuličnim parkiralištima

Primarni podaci za ostvarivanje modela iskoristivosti vanuličnog parkirališta jesu očitanja rampe koja služi kao fizička barijera za ulaz i izlaz s parkirališta. Svako očitanje rampe u gradu Splitu šalje se u gradski oblak u kojem se radi obrada podataka. Obradom podataka stvaraju se podaci

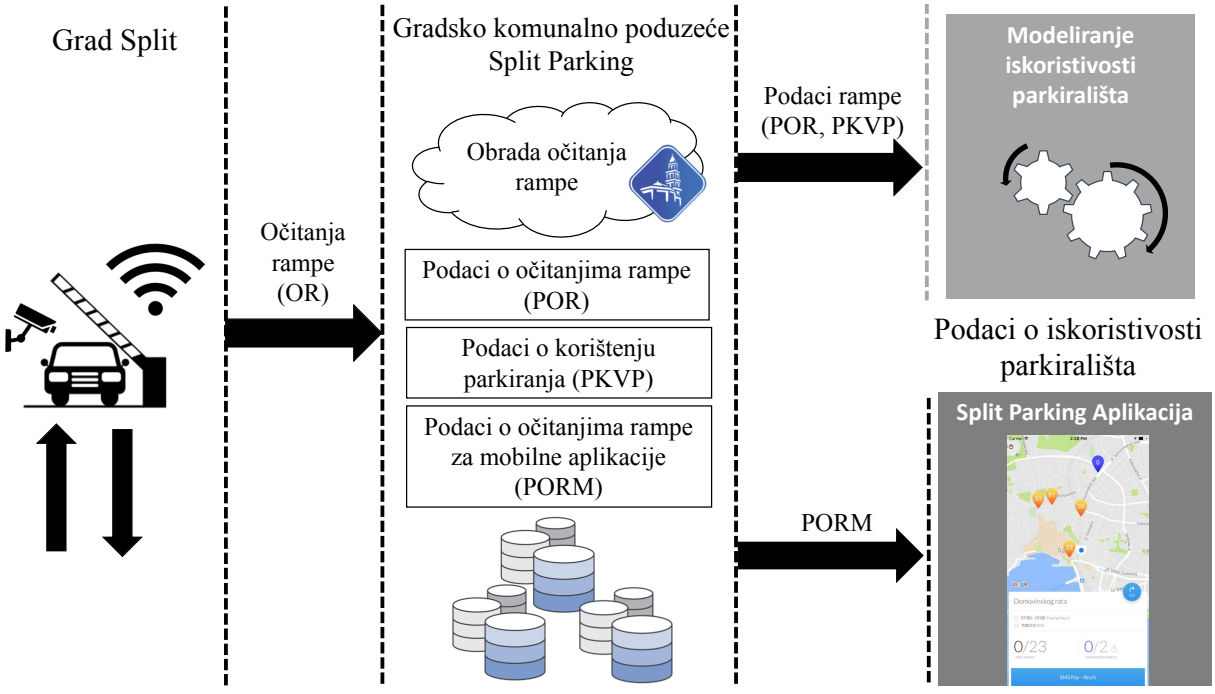

Slika 4.5: Proces prikupljanja podataka o korištenju vanuličnih parkirališta

Tablica 4.3: Prikaz podataka o očitanjima rampe vanuličnog parkirališta

Id Parkiralište	Slobodno	Kapacitet	Stvoren
7	62	245	2018-05-08 17:00:02
10	9	132	2018-05-08 17:00:15
11	6	120	2018-05-08 17:00:53
11	5	120	2018-05-08 17:01:04
2	145	350	2018-05-08 17:01:05
8	31	138	2018-05-08 17:01:15
7	63	245	2018-05-08 17:01:16

o očitanjima rampe (POR), podaci o korištenju parkirališta (PKVP) i podaci o očitanjima rampe za mobilne aplikacije (PORM). Podaci PORM koriste se u aplikaciji grada Splita pod nazivom Split Parking za prikaz broja dostupnih mjesta na određenom vanuličnom parkiralištu. Za pristup i korištenje podataka POR i PKVP potrebno je ishoditi dopuštenje grada Splita. Na temelju dopuštenja, prikupljaju se podaci POR i PKVP iz gradskog oblaka potrebni za ostvarivanje modela iskoristivosti vanuličnog parkirališta. Proces prikupljanja podataka o korištenju vanuličnih parkirališta prikazan je na slici 4.5.

Podaci POR predstavljaju očitanja rampe vanuličnog parkirališta. Rampa vanuličnog parkirališta omogućava ulazak i izlazak vozila s parkirališta, pri čemu uza svako očitanje pomoću kamere identificira vozilo koje je ušlo ili izašlo s parkirališta tako da učita registarsku oznaku vozila. Razlikuju se dva tipa očitanja parkirne rampe:

•ULAZ - rampa je podignuta i omogu ćuje vozilu ulazak u parkiralište.

•IZLAZ - rampa je podignuta i omogu ćuje izlazak vozila iz parkirališta;

U oba slučaja podaci POR šalju informacije o trenutačnom broju slobodnih parkirališnih mjesta i registarsku oznaku vozila koje je ušlo u parkiralište. Broj slobodnih mjesta smanjuje se za jedan ako vozilo ulazi u parkiralište, dok se broj povećava za jedan ako se radi o odlasku vozila s parkirališta. Primjer podataka POR dan je u tablici 4.3. Svaki zapis podataka POR sastoji se od sljedećih polja:

•Id parkirališta - jedinstveni identifikator vanuli čnog parkirališta;

•Slobodno - ozna čava broj slobodnih parkirališnih mjesta na vanuličnom parkiralištu;

•Kapacitet - ozna čava kapacitet vanuličnog parkirališta koji je jednak broju parkirališnih mjesta;

•Stvoren - vrijeme kad je zapis stvoren.

Podaci POR za grad Split prikupljeni su za 10 vanuličnih parkirališta za razdoblje od 1. siječnja 2018. godine do 1. lipnja 2020. godine i sadrži 10.195.093 zapisa. Gradski oblak obrađuje podatke POR i pritom stvara zapise podataka PKVP o sesijama parkiranja na vanuličnom par-

Tablica 4.4: Prikaz podataka o sesijama parkiranja vanuličnih parkirališta

Id parkirališta	Početak	Kraj
7	2018-05-08 17:00:02	2018-05-08 20:01:42
10	2018-05-08 17:00:15	2018-05-08 20:39:48
11	2018-05-08 17:00:53	2018-05-09 07:33:44
11	2018-05-08 17:01:04	2018-05-09 07:38:18
2	2018-05-08 17:01:05	2018-05-08 19:40:30
8	2018-05-08 17:01:15	2018-05-08 18:52:32
7	2018-05-08 17:01:16	2018-05-08 20:02:57

kralištu. Podaci PKVP prikazani su u tablici 4.4 i definiraju vrijeme početka *Početak* i vrijeme završetka *Kraj* svake sesije parkiranja koja je vezana uz određeno parkiralište *Id parkirališta*.

Podaci o električnim punionicama

Za ostvarivanje modela iskoristivosti električnih punionica potrebno je prikupiti podatke o zauzećima priključaka električne punionice. Svaki priključak električne punionice šalje svoje očitanje o promjeni stanja koje definira očitanja električne punionice. Očitanja priključaka električne punionice šalju se u oblak operatora električnih punionica. U oblaku se obrađuju podaci očitanja priključaka električne punionice i pritom se stvaraju podaci o očitanjima elek-

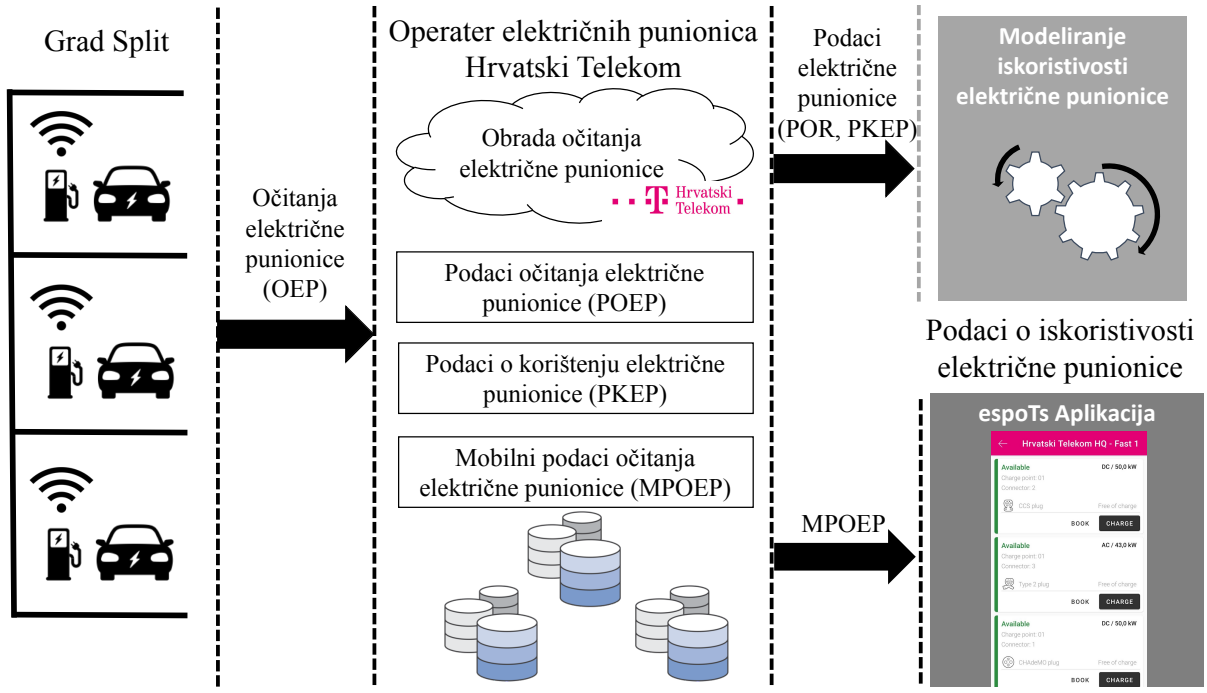

Slika 4.6: Proces prikupljanja podataka o korištenju električnih punionica

trične punionice (POEP), podaci o korištenju električne punionice (PKEP) i podaci o očitanjima električne punionice za mobilnu aplikaciju (MPOER). Podaci MPOER koriste se u aplikacijama operatora električnih punionica. Operator koji je pružio podatke o korištenju električnih punionica jest Hrvatski Telekom koji svojim korisnicima pruža aplikaciju *espoTs* putem koje omogućuju rezervaciju, punjenje i naplatu punjenja električnih vozila. Hrvatski Telekom za umrežavanje i upravljanje električnim punionicama koristi se platformom *OCEAN* tvrtke Etrel[§].

Primjer podataka POEP prikazan je u tablici 4.5. Zapisi podataka POEP-a sastoje se od sljedećih polja:

•Id punionice - jedinstveni identifikator elektri čne punionice;

•Id priklju čka - jedinstveni identifikator priključka električne punionice;

•Status - vrijednost o čitanja statusa priključaka;

•Stvoren - vrijeme stvaranja zapisa.

Svako očitanje električne punionice može imati jednu od sljedećih vrijednosti statusa priključka:

•DOSTUPAN - priklju čak je dostupan i može ga se upotrijebiti za punjenje baterije električnog vozila;

•REZERVIRAN - priklju čak je rezerviran pomoću aplikacije ili portala operatora električnih punionica;

•PUNJENJE - priklju čak je zauzet i upotrebljava se za punjenje baterije električnog vozila;

•IZVAN FUNKCIJE - priklju čak je zbog tehničkih poteškoća izvan funkcije i nije dostupan za korištenje;

•NEPOZNAT - operator elektri čnih punionica izgubio je internetsku vezu s priključkom i ne zna u kojem je statusu.

Na temelju podataka POEP stvaraju se podaci PKEP koji definiraju sesije punjenja električnih vozila na punionici. Primjer podataka PKEP prikazan je tablici 4.6 i sastoji se od sljedećih

[§]https://etrel.com/ocean/ - Etrel OCEAN platforma za ostvarivanje umrežavanja i upravljanja električnim punionicama

Tablica 4.5: Prikaz podataka očitanja električnih punionica

Id priključka	Status	Stvoren
137011	DOSTUPAN	2020-05-08 17:47:45
137012	DOSTUPAN	2020-05-08 17:47:45
2091321	PUNJENJE	2020-05-08 17:56:08
137012	DOSTUPAN	2020-05-08 21:06:30
1631171	PUNJENJE	2020-05-08 21:56:28
313011	DOSTUPAN	2020-05-08 23:09:11
1912	PUNJENJE	2020-05-08 23:20:47

Tablica 4.6: Prikaz podataka o korištenju električne punionice

Id punionice	Id priključka	Početak	Kraj
93	130011	2020-05-08 17:25:58	2020-05-09 10:29:00
102	137011	2020-05-08 17:47:45	2020-05-08 21:06:28
104	2091321	2020-05-08 17:56:08	2020-05-09 07:51:51
157	303023	2020-05-08 19:32:39	2020-05-10 17:33:46
107	2011291	2020-05-08 20:19:28	2020-05-09 07:50:46
94	131013	2020-05-08 20:33:52	2020-05-09 09:42:50
25	1811	2020-05-08 20:55:41	2020-05-11 10:42:03

polja:

- Id punionice - jedinstveni identifikator elektri čne punionice;
- Id priklju čka - jedinstveni identifikator priključka električne punionice;
- Po četak - vrijeme početka punjenja električnog vozila;
- Kraj - vrijeme završetka punjenja elektri čnog vozila.

Za model iskoristivosti električnih punionica prikupljaju se podaci POEP i PKEP. Podaci o očitanjima električnih punionica prikupljeni su za 138 električnih punionica operatora Hrvatski Telekom za razdoblje od 12. prosinca 2019. godine do 1. srpnja 2021. godine i sadrži 265.459 zapisa.

Kontekstni podaci

Analitički pristup osim osnovnog definira i kontekstni pristup za model iskoristivosti. Za kontekstni pristup potrebni su kontekstni podaci. Kontekstni podaci koji će biti korišteni za modele

Tablica 4.7: Primjer podataka o mjestima od značaja

Id	Kategorija	Geo-širina	Geo-dužina
1011	cafe	45,3038988	13,6891309
1012	supermarket	43,3547829	16,9557345
1013	pub	43,3487023	16,9525416
1014	supermarket	43,3675815	16,931498
1015	post_office	43,3674094	16,9316041
1016	supermarket	43,355986	16,949403
1017	pub	43,3408403	16,9616757

Tablica 4.8: Primjer podataka o vremenskoj prognozi za jedan dan (24 sata)

Vrijeme	T	V	TL	TLT	SV	BV	OV
2018-07-10 00:12	28	43	1.012,30	-0,20	S	3	vedro
2018-07-10 00:13	30	37	1.011,90	-0,60	SW	4	vedro
2018-07-10 00:14	30	37	1.011,70	-0,80	SW	5	vedro
2018-07-10 00:15	29	40	1.011,50	-0,70	SW	6	vedro
2018-07-10 00:16	29	39	1.011,10	-0,80	SW	6	vedro
2018-07-10 00:17	28	42	1.011,00	-0,70	SW	6	vedro
2018-07-10 00:18	27	48	1.011,60	0,00	SW	5	vjetar

iskoristivosti jesu: mjesta od značaja (eng. *Point-of-Interest (PoI)*) i vremenska prognoza. Podaci PoI tip su kontekstnih podataka koji se koriste u kontekstnom pristupu stvaranja modela iskoristivosti koji se dohvaćaju sa sustava *Open Street Map*[¶]. Sustav *Open Street Map* pruža informacije o različitim mjestima od značaja kojih trenutačno ima preko 7 milijardi i koja su podijeljena u više različitih kategorija označena sa svojim kodom. Podaci PoI prikupljeni su za Hrvatsku i prikazani su u tablici 4.7. Svaki zapis podataka PoI sastoji se od jedinstvenog identifikatora zapisa *Id*, kategorije mjesta od značaja *Kategorija*, geografsku širinu *Geo-širina* i geografsku dužinu *Geo-dužina*.

Drugi tip kontekstnih podataka jesu povijesni podaci o vremenskoj prognozi za grad Split koji su dohvaćeni s Hrvatskog državnog hidrometeorološkog zavoda[‖]. Podaci za vremensku prognozu sakupljaju se za svakih sat vremena u danu i sadrže sljedeće informacije: temperatura (T), vlažnost (V), tlak (TL), tendencija tlaka (TLT), brzina vjetra (BV), smjer vjetra (SV), opis vremena (OV). Primjer podataka o vremenskoj prognozi prikazan je u tablici 4.8. Povijesni podaci o vremenskoj prognozi prikupljeni su od 10. srpnja 2011. godine pa sve do 1. lipnja 2020. godine.

4.4.5Priprema podataka

U fazi pripreme podataka, podaci se pripremaju tako da su pogodniji za stvaranje modela iskoristivosti. Za stvaranje modela iskoristivosti u osnovnom pristupu potrebno je pripremiti sljedeće podatke:

- •podaci o iskoristivosti uli čnog parkirališta (PIUP);
- •podaci o iskoristivosti vanuli čnog parkirališta (PIVP);
- •podaci o iskoristivosti elektri čnih punionica (PIEP).

[¶]www.openstreetmap.org

[‖]*Hrvatski državni hidrometeorološki zavod* državno je tijelo u Hrvatskoj

Za pripremu svakog skupa podataka potrebno je prethodno odraditi čišćenje podataka koji će se koristiti za stvaranje podataka o iskoristivosti. Nakon što se podaci očiste od krivih zapisa, pristupa se izračunu mjere iskoristivosti.

Mjera iskoristivosti izračunava se za svakih sat vremena zasebno za svaku električnu punionicu, uličnо i vanuličnо parkiralište. Vrijednost mjere iskoristivosti označava iskorištenost električne punionice, uličnog i vanuličnog parkirališta unutar sat vremena i izražena je u postocima. Najmanja mjera iskoristivosti može biti jednaka vrijednosti 0%, dok najveća vrijednost mjere iskoristivosti može biti 100%. Izračun mjere iskoristivosti definirano je izrazom 4.1 gdje O označava objekt za koji se izračunava mjera iskoristivosti, dok t označava sat u danu za koji se izračunava mjera iskoristivosti. Objekt O za naš slučaj može biti električna punionica, uličnо ili vanuličnо parkiralište. Mjera iskoristivosti za O izračunava se tako da se zbroje sve duljine zapisa korištenja ZK objekta O za vrijeme t i podijeli se s kapacitetom objekta O. Skup zapisa korištenja PZK, ovisno o objektu O, može biti definiran s podacima o korištenju uličnih parkirališta (PKUP), ili s podacima o korištenju vanuličnih parkirališta (PKVP) ili s podacima o korištenju električnih punionica (PKEP). Duljina zapisa korištenja ZK u satima za objekta O i sat u danu t izračunava se prema izrazu 4.2, gdje ZK_p označava vrijeme početka zapisa korištenja ZK, dok ZK_k označava vrijeme završetka zapisa korištenja ZK.

Za stvaranje modela iskoristivosti u kontekstnom pristupu potrebno je pripremiti sljedeće podatke:

•podaci o kontekstnoj iskoristivosti uli čnog parkirališta (PKIUP);

•podaci o kontekstnoj iskoristivosti vanuli čnog parkirališta (PKIVP);

•podaci o kontekstnoj iskoristivosti elektri čnih punionica (PKIEP).

Podaci za modele iskoristivosti u kontekstnom pristupu proširenje su podataka iz osnovnog pristupa na način da im se dodaju informacije o kontekstu. Definirana su dva konteksta koji će se koristiti i koji su prethodno prikupljeni: mjesta od značaja i vremenska prognoza. Ako je tijekom pripreme podataka za modele iskoristivosti potrebno uključiti neke dodatne podatke, tada se treba vratiti korak natrag u fazu prikupljanja podataka.

$$U(O,t) = \frac{\sum_{i=1}^{N} D(ZK_i,t)}{O_{kapacitet}}; \quad ZK_i \in PZK(O,t) \tag{4.1}$$

$$D(ZK,t) = \begin{cases} 1 & : \ ZK_p < t \ i \ ZK_k > t+1 \\ (t+1) - ZK_p & : \ ZK_k >= t \ i \ ZK_k > t+1 \\ ZK_k - t & : \ ZK_p < t \ i \ ZK_k <= t+1 \\ ZK_k - ZK_p & : \ ZK_p >= t \ i \ ZK_k <= t+1 \end{cases} \tag{4.2}$$

Podaci iskoristivosti uličnog parkirališta

Za stvaranje podataka PIUP potrebni su podaci PKUP i PSO prikupljeni za grad Split. PSO podaci koriste se za procjenu podataka PKUP, gdje se provjerava ima li svaki zapis korištenja iz PKUP-a odgovarajuće senzorsko očitanje u PSO-u. Ispostavilo se da neki zapisi u PKUP-u nemaju odgovarajuće zapise u PSO-u ili ih je gradsko komunalno poduzeće loše obradilo. Prema tome potrebno je odraditi čišćenje podataka PKUP kako bi se ostvario što bolji skup podataka PIUP. Proces čišćenja podataka PKUP odvija se u devet koraka.

Korak 1 provjerava postoje li zapisi korištenja u kojima nije definirano vrijeme početka ili vrijeme završetka zauzetosti parkirališnog mjesta. To ukazuje na moguća lažna očitovanja prizemnog senzora (tip opažaja POČETAK ili KRAJ) i time procesiranje podataka PSO može rezultirati zapisima podataka PKUP sa samo postavljenim vremenom početka ili završetka. Takvi su zapisi uklonjeni iz PKUP-a.

Korak 2 provjerava postoje li zapisi korištenja u kojima je vrijeme početka jednako vremenu završetka. Nije moguće imati zapis korištenja koji počinje i završava u isto vrijeme. To se može deklarirati kao pogreška u obradi podataka i takvi se zapisi uklanjaju iz PKUP-a.

Korak 3 traži zapise korištenja u kojima je vrijeme početka veće od vremena završetka. U ovom slučaju nije moguće imati zapis korištenja koji završava prije nego što je počeo. Takvi se podaci uklanjaju iz PKUP-a.

Korak 4 traži zapise korištenja koji traju jednako ili kraće od jedne minute. Parkiranje u trajanju jednakom ili kraćem od jedne minute tumači se kao slučaj vrlo kratkog zaustavljanja vozila na parkirališnom mjestu bez namjere parkiranja. Takvi zapisi korištenja označeni su kao nevažeći i uklanjaju se iz PKUP-a.

Korak 5 uklanja udvostručene zapise korištenja iz PKUP-a. Može se dogoditi da zbog određene greške u obradi podataka neka senzorska očitanja iz PSO-a budu obrađena više puta u gradskom oblaku.

Korak 6 identificira preklapajuće zapise korištenja u PKUP-u. To u stvarnom svijetu može značiti da su dva vozila parkirana na istom parkirališnom mjestu u isto vrijeme, što nije izvedivo. Preklapajući zapisi korištenja rješavaju se uklanjanjem nevažećeg suvišnog zapisa korištenja, pri čemu se svaki put dulji preklapajući zapis korištenja smatra nevažećim.

Korak 7 uklanja zapise korištenja za parkirališna mjesta namijenjena za osobe s invaliditetom. U okviru ovog rada, kapacitet parkirališta definira se kao broj parkirališnih mjesta koja nisu namijenjena za osobe s invaliditetom. Razlog tome je što PKUP podaci ukazuju na nisku korištenost parkirališnih mjesta namijenjene za osobe s invaliditetom. PKUP sadrži samo 9.177 zapisa korištenja za parkirališna mjesta namijenjena za osobe s invaliditetom, što dokazuje njihovu nisku korištenost. Uz ovako definiran kapacitet parkirališta, pokazalo se da dva parkirališta imaju samo parkirališna mjesta namijenjena za osobe s invaliditetom te su stoga uklonjena, čime se broj parkirališta smanjio s 50 na 48.

Tablica 4.9: Prikaz rezultata čišćenja podataka o korištenju uličnih parkirališta

Korak	Prije	Poslije	Uklonjeno	Ostalo (%)	Parkirališta
1	10.677.644	10.675.600	2.044	99,98	50
2	10.675.600	10.589.380	86.220	99,17	50
3	10.589.380	10.582.985	6.395	99,11	50
4	10.582.985	7.982.685	2.600.300	74,76	50
5	7.982.685	7.936.255	46.430	74,32	50
6	7.936.255	7.929.808	6.447	74,26	50
7	7.929.808	7.920.631	9.177	74,17	48
8	7.920.631	7.920.631	0	74,17	44
9	7.920.631	7.781.068	139.563	72,87	44

Korak 8 uklanja parkirališta za koja nemamo nikakve zapise u PSO-u, a time ni zapise u PKUP-u. Takvom provjerom identificirana su četiri parkirališta koja nisu imala zapise u PSO-u od 1. siječnja 2017. do 1. lipnja 2020. Identificirana parkirališta uklonjena su s popisa parkirališta za koja će se pripremati podaci i time se broj parkirališta smanjio na 44.

Korak 9 posljednji je korak koji provjerava količinu zapisa u PSO-u na godišnjoj razini za svako parkiralište. Provjerom je utvrđeno da samo jedno parkiralište ima zapise u PSO-u za 2017. godinu, jer je jedino bilo pokriveno s parkirališnim senzorima. Iz tog razloga zapisi korištenja za identificirano parkiralište uklonjeni su iz PKUP-a za 2017. godinu i time sada PKUP sadrži zapise korištenja samo od 1. siječnja 2018. godine pa nadalje.

Tablica 4.9 prikazuje rezultate svakog koraka čišćenja PKUP-a. Može se vidjeti da je korak 4 uklonio većinu zapisa korištenja iz PKUP-a. Konačni skup podataka PKUP iznosi 72,87% veličine izvornog skupa podataka i sadrži 7.781.068 zapisa korištenja za 44 parkirališta počevši od 1. siječnja 2018. godine pa nadalje.

Konačni skup podataka PKUP koristi se za stvaranje podataka PIUP i PKIUP. Za stvaranje podataka PIUP prvo se izračunava mjera iskoristivosti za svako ulično parkiralište i za svaki sat počevši od 1. siječnja 2018. godine pa sve do 1. lipnja 2020. godine. Mjera iskoristivosti izračunava se prema izrazu 4.1 gdje je objekt O svako ulično parkiralište iz PKUP-a, a skup zapisa korištenja PZK definiran je skupom podataka $PKUP$. Svaki zapis PIUP-a sastoji se od sljedećih polja:

•Id parkirališta - jedinstveni identifikator parkirališta;

•Vrijeme - vrijeme za koje se izra čunava mjera iskoristivosti;

•Iskoristivost - vrijednost izra čunate mjere iskoristivosti.

Primjer podataka PIUP prikazan je u tablici 4.10.

Tablica 4.10: Primjer podataka o iskoristivosti uličnog parkirališta (prikaz perioda od 24 sata dan je dodatkom 6 u tablici 6.1)

Id parkirališta	Vrijeme	Iskoristivost (%)
1	2018-01-01 12:00:00	75,83
1	2018-01-01 13:00:00	72,39
1	2018-01-01 14:00:00	72,83
1	2018-01-01 15:00:00	81,74
1	2018-01-01 16:00:00	81,74
1	2018-01-01 17:00:00	78,46
1	2018-01-01 18:00:00	77,36
1	2018-01-01 19:00:00	74,92
1	2018-01-01 20:00:00	67,93
1	2018-01-01 21:00:00	65,04
1	2018-01-01 22:00:00	63,56
1	2018-01-01 23:00:00	58,33

Podaci iskoristivosti vanuličnog parkirališta

Za ostvarivanje modela iskoristivosti vanuličnog parkirališta potrebni su podaci POR i PKVP grada Splita. Pomoću podataka POR provodi se provjera valjanosti podataka PKVP provjeravajući pritom ima li svaki zapis iz PKVP-a pripadajuće očitanje rampe iz POR-a. Provjera valjanosti podataka PKVP pokazala je određene nepravilnosti između podataka POR i pripadajućih zapisa u podacima PKVP. Iz tog razloga potrebno je odraditi čišćenje podataka POR i ponovno stvarati podatke PKVP jer je vrlo teško odrediti pripadajući zapis korištenja na temelju zapisa iz POR-a (polje *Stvoren* iz POR-a ne podudara se s poljem *Početak* iz PKVP-a). Proces čišćenja podataka POR odvija se u dva koraka.

Korak 1 provjera postoje li zapisi podataka POR u kojima je rampa poslala informaciju o broju slobodnih parkirališta veću od definiranog kapaciteta vanuličnog parkirališta. Rezultat je takvih zapisa u POR-u stvaranje dodatnih zapisa korištenja u PKVP-u koji mogu rezultirati krivom vrijednošću za mjeru iskoristivosti te u krajnjem slučaju mjera iskoristivosti može biti

Tablica 4.11: Prikaz rezultata čišćenja podataka o korištenju vanuličnih parkirališta

Korak	Prije	Poslije	Uklonjeno	Ostalo (%)	Parkirališta
1	10.195.093	10.191.051	4.042	99,96	10
2	10.191.051	10.156.596	34.330	99,63	10

Tablica 4.12: Primjer podataka o iskoristivosti vanuličnog parkirališta (prikaz perioda od 24 sata dan je dodatkom 6 u tablici 6.2)

Id parkirališta	Vrijeme	Iskoristivost (%)
6	2019-01-01 12:00:00	80,64
6	2019-01-01 13:00:00	98,99
6	2019-01-01 14:00:00	95,73
6	2019-01-01 15:00:00	96,64
6	2019-01-01 16:00:00	95,11
6	2019-01-01 17:00:00	73,16
6	2019-01-01 18:00:00	60,63
6	2019-01-01 19:00:00	52,06
6	2019-01-01 20:00:00	45,21
6	2019-01-01 21:00:00	38,78
6	2019-01-01 22:00:00	36,31
6	2019-01-01 23:00:00	34,99

veća od 100%. Takvi zapisi uklonjeni su iz podataka PKVP-a.

Korak 2 provjerava postoje li udvostručena očitanja rampe u podacima POR. Udvostručena očitanja rampe povezana su s ponovnim slanjem očitanja rampe iz određenog tehničkog razloga kako bi se očitanje u oblak dostavilo na daljnje procesiranje. Svi zapisi korištenja koji predstavljaju udvostručene zapise uklonjeni su iz podataka POR.

Rezultat čišćenja podataka POR prikazan je u tablici 4.11. Iz izvornog skupa podataka POR uklonjeno je 38.497 zapisa očitanja rampe i time je definiran završni skup podataka POR s 10.156.596 zapisa očitanja rampe vanuličnih parkirališta koji definira 99,63% izvornog skupa podataka POR. Iz definiranog skupa podatka POR ponovno se stvara skup podataka PKVP tvoreći pritom 3.712.278 zapisa korištenja vanuličnih parkirališta. Konačni skup podataka PKVP koristi se za stvaranje podataka PIVP i PKIVP. Stvaranje podataka PIVP započinje prvo s izračunom mjere iskoristivosti za svako vanulično parkiralište za svaki sat počevši od 1. siječnja 2018. godine pa sve do 1. lipnja 2020. godine. Mjera iskoristivosti se izračunava prema izrazu 4.1 gdje objekt O je definiran vanuličnim parkiralištem iz podataka PKVP, a skup zapisa korištenja PZK je definiran skupom PKVP. Svaki zapis PIVP-a se sastoji od sljedećih polja:

•Id parkiralište - jedinstveni identifikator parkirališta;

•Vrijeme - vrijeme za koje se izra čunava mjera iskoristivosti;

•Iskoristivost - vrijednost izra čunate mjere iskoristivosti.

Primjer podatka PIVP prikazan je u tablici 4.12.

Podaci iskoristivosti električne punionice

Za ostvarivanje modela iskoristivosti električnih punionica potrebni su podaci POEP i PKEP iz faze prikupljanja podataka. Pomoću podataka POEP radi se provjera valjanosti podataka PKEP s ciljem otkrivanja nepravilnosti između ta dva skupa podataka. Provjera valjanosti podatka nije pokazala nikakve nepravilnosti, ali dodatnom analizom podataka PKEP utvrđeno je postojanje udvostručenih zapisa korištenja. Otkriveno je 2.069 zapisa koji su udvostručeni te su uklonjeni iz skupa podataka PKEP. Finalni skup podataka PKEP sastoji se od 92.672 zapisa korištenja električnih punionica u Hrvatskoj koji su u vlasništvu operatora Hrvatski Telekom.

Konačni skup PKEP koristi se za stvaranje PIEP i PKIEP. Stvaranje podataka PIEP započinje prvo s izračunom mjere iskoristivosti za svaku električnu punionicu i to za svaki sat počevši od 12. prosinca 2019. godine pa sve do 1. siječnja 2022. godine. Mjera iskoristivosti se izračunava prema izrazu 4.1 gdje je objekt O definiran električnom punionicom iz podataka PKEP, a skup zapisa korištenja PZK je definiran skupom PKEP. Svaki zapis PIEP-a sastoji se od sljedećih polja:

- Id punionice - jedinstveni identifikator elektri čne punionice;
- Vrijeme - vrijeme za koje se izra čunava mjera iskoristivosti;
- Iskoristivost - vrijednost izra čunate mjere iskoristivosti.

Primjer podataka PIEP prikazan je u tablici 4.13.

Tablica 4.13: Primjer podataka o iskoristivosti električne punionice (prikaz perioda od 24 sata dan je dodatkom 6 u tablici 6.3)

Id punionice	Vrijeme	Iskoristivost (%)
46	2020-06-01 12:00:00	0,00
46	2020-06-01 13:00:00	0,00
46	2020-06-01 14:00:00	0,00
46	2020-06-01 15:00:00	0,00
46	2020-06-01 16:00:00	96,39
46	2020-06-01 17:00:00	100,00
46	2020-06-01 18:00:00	100,00
46	2020-06-01 19:00:00	100,00
46	2020-06-01 20:00:00	92,31
46	2020-06-01 21:00:00	0,00
46	2020-06-01 22:00:00	0,00
46	2020-06-01 23:00:00	0,00

Kontekstno obogaćivanje podataka o iskoristivosti

Za stvaranje podataka PKIUP, PKIVP i PKIEP potrebno je proširiti skupove podataka definirane za osnovni pristup s kontekstnim podacima. Koriste se dvije vrste konteksta: vremenska prognoza i mjesta od značaja (*eng. Points of Interest (PoI)*). Za svaku vrstu konteksta stvara se zaseban skup podataka o kontekstnoj iskoristivosti podataka, pri čemu za kontekst *vremenska prognoza* stvorit će se skup podataka o kontekstnoj iskoristivosti s vremenskom prognozom (PKI_{VP}) dok za PoI će se stvoriti skup podataka o kontekstnoj iskoristivosti s mjestima od značaja (PKI_{PoI}). Kontekstno obogaćivanje provodi se za podatke o iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta, pa prema tome definiramo sljedeće zapisa:

- $PKIUP_{VP}$ - podaci o kontekstnoj iskoristivosti uličnih parkirališta s vremenskom prognozom;
- $PKIUP_{PoI}$ - podaci o kontekstnoj iskoristivosti uličnih parkirališta s mjestima od značaja;
- $PKIVP_{VP}$ - podaci o kontekstnoj iskoristivosti vanuličnih parkirališta s vremenskom prognozom;
- $PKIVP_{PoI}$ - podaci o kontekstnoj iskoristivosti vanuličnih parkirališta s mjestima od značaja;
- $PKIEP_{VP}$ - podaci o kontekstnoj iskoristivosti električnih punionica s vremenskom prognozom;
- $PKIEP_{PoI}$ - podaci o kontekstnoj iskoristivosti električnih punionica s mjestima od značaja.

U fazi prikupljanja podataka prikupljeni su svi potrebni kontekstni podaci. Provedena je provjera valjanosti prikupljenih kontekstnih podataka kako bi se otkrili mogući pogrešni zapisi ili zapisi koji nedostaju. Provjera valjanosti pokazala je da su prikupljeni podaci ispravni. Za podatke o vremenskoj prognozi uočeno je da Hrvatski hidrometeorološki zavod definira 95 različitih kategorija za opis vremena. Te su kategorije grupirane i transformirane u sedam apstraktnijih kategorija za opis vremena, kao što je prikazano na slici 4.7. Prema tome, polje "opis vremena" može sadržavati jednu od sljedećih vrijednosti: vjetrovito, sunčano, oblačno, kiša,

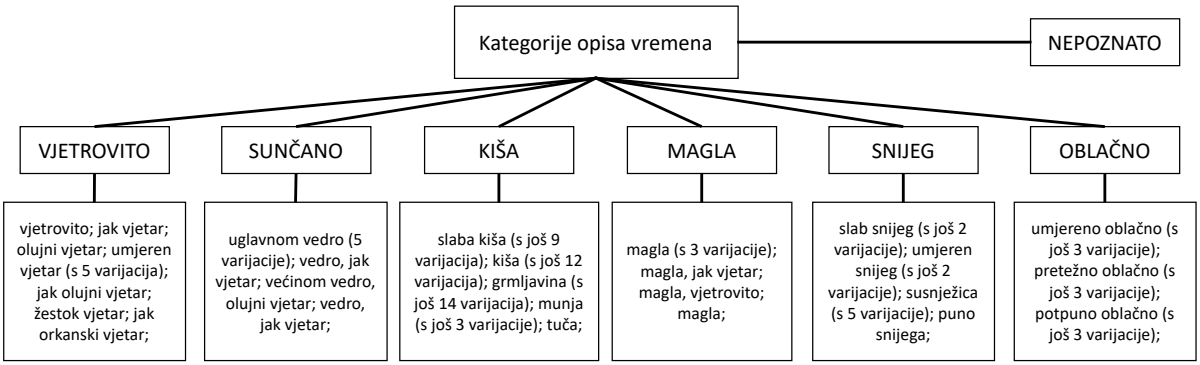

Slika 4.7: Prikaz kategorija za opis vremenske prognoze

Tablica 4.14: Primjer kontekstnih podataka vremenske prognoze koji se nadodaju svakom zapisu podataka o iskoristivosti stvorenih za osnovni pristup

Id	Vrijeme	T	V	TL	TLT	BV	SV	OP
1	2018-01-01 00:00:00	9.0	68,0	1.020,8	0,0	3,0	E	vjetrovito
1	2018-01-01 01:00:00	9.0	72,0	1.020,0	-0,8	3,0	NE	oblačno
1	2018-01-01 02:00:00	9.0	66,0	1.020,2	0,0	4,0	E	vjetrovito
1	2018-01-01 03:00:00	9.0	70,0	1.019,8	0,0	4,0	SE	vjetrovito
1	2018-01-01 04:00:00	10.0	69,0	1.019,0	-0,9	4,0	E	oblačno

snijeg, magla i nepoznato. Svaki zapis PKI_{VP}-a proširen je sa sljedećim poljima: temperatura (T), vlažnost (V), tlak (TL), tendencija tlaka (TTL), brzina vjetra (BV), smjer vjetra (SV), opis vremena (OP). Primjer podataka PKI_{VP} prikazan je u tablici 4.14, gdje polje *Id* odnosi se na neki od identifikatora zapisa iz PIUP-a, PIVP-a ili PIEP-a.

U slučaju podataka o mjestima od značaja kao kontekstnih podataka potrebno je definirati kategorizaciju za mjesta od značaja. Kategorizacija je prikazana na slici 4.8 i definirana je na temelju kategorizacije dane u radu [119]. Definirane su sljedeće kategorije za mjesta od značaja: *trgovina, piće, hrana, zabava, sport, turizam, prijevoz, smještaj, religija, zdravstvo, obrazovanje, zajednica, posao i financije*. Za svako ulično i vanulično parkiralište uzimaju se mjesta od značaja koja se nalaze unutar radijusa od 250 metara. Vrijednost radijusa predstavlja udaljenost koju je neka osoba voljna prijeći od ishodišne točke pa do točke odredišta [120]. Za slučaj električnih punionica uzimaju se u obzir mjesta od značaja koja se nalaze unutar radijusa od 500 metara, gdje ovako definiran radijus predstavlja najveću udaljenost unutar koje određeno mjesto od značaja može imati utjecaj na iskoristivost električne punionice [79]. Primjer podataka PKI_{PoI} prikazan je tablici 4.15, gdje se polje *Id* referira na određeni zapis iz PIUP-a, PIVP-a ili PIEP-a.

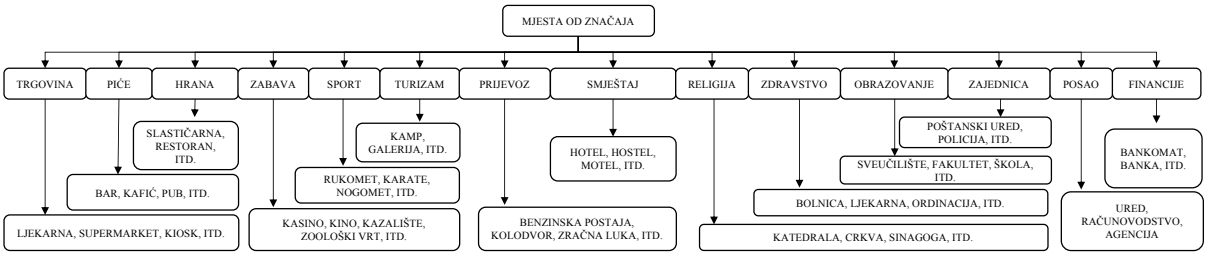

Slika 4.8: Prikaz kategorija za mjesta od značaja

Tablica 4.15: Primjer kontekstnih podataka za električne punionice (Id: 3, 110), ulična parkirališta (Id: 25, 14) i vanulična parkirališta (Id: 7,2) - prikazane su PoI vrijednosti samo za podskup definiranih PoI kategorija)

Id	Hrana	Piće	Trgovina	Smještaj	Turizam	Posao
7	2	1	6	5	0	0
2	1	0	5	0	0	0
3	19	7	11	6	4	1
110	0	1	0	0	1	0
25	2	6	17	0	0	1
14	4	1	3	0	3	0

4.4.6Stvaranje, procjena i korištenje modela iskoristivosti

U fazi stvaranja modela iskoristivosti stvaraju se modeli iskoristivosti na temelju definiranih pristupa podacima i metoda ML-a iz faze definiranja analitičkog pristupa. Na temelju definiranih pristupa podacima i metoda ML-a razlikujemo sedam modela iskoristivosti za električne punionice, ulična i vanulična parkirališta:

- *Model 0* - *dummy* model iskoristivosti;
- *Model 1* - osnovni model iskoristivosti s metodom *Random Forest*;
- *Model 2* - osnovni model iskoristivosti s metodom *CatBoost*;
- *Model 3* - kontekstni model iskoristivosti s metodom *Random Forest* i vremenskom prognozom kao kontekst;
- *Model 4* - kontekstni model iskoristivosti s metodom *CatBoost* i vremenskom prognozom kao kontekst;
- *Model 5* - kontekstni model iskoristivosti s metodom *Random Forest* i mjestima od značaja kao kontekst;
- *Model 6* - kontekstni model iskoristivosti s metodom *CatBoost* i mjestima od značaja kao kontekst;

Za predviđanje iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta definiran je i *dummy* model *Model 0* koji predviđa iskoristivost tako da uzima vrijednost iskoristivosti koja je bila dan prije. Na primjer, ako želimo znati kakva je iskoristivost za neko parkiralište u ponedjeljak u 13 sati, tada će vrijednost iskoristivosti biti jednaka vrijednosti iskoristivosti za dan prije u 13:00.

Za svaku metodu ML-a potrebno je definirati ulazne varijable modela i izlaznu varijablu za koju se radi predviđanje vrijednosti. Metoda ML-a na temelju povijesnih podatka otkriva različite obrasce ponašanja i uočava korelacije između definiranih ulaznih varijabli modela i izlazne varijable modela [121]. Izlazna varijabla modela iskoristivosti jest iskoristivost određena

u podacima PIUP, PIVP i PIEP. Ulazne varijable modela referiraju se u prediktivnoj analizi kao opisne varijable modela te su mjerljiva svojstva skupa podataka koje model upotrebljava i definirana su poljima tog skupa podataka [122]. Definiranje ulaznih varijabli modela iskoristivosti potrebno je izvršiti inženjeringom ulaznih varijabli modela na pripremljenim podacima PIUP, PIVP i PIEP. Inženjering ulaznih varijabli modela proces je definiranja ulaznih varijabli modela unutar kojeg se uz postojeće ulazne varijable modela proizašle iz skupa podataka koje model upotrebljava, definiraju dodatne ulazne varijable modela kako bi se postigla što bolja izvedba odabrane metode ML-a [123].

Inženjering ulaznih varijabli za modele iskoristivosti u fazi stvaranja modela izvršava se prvo za podatke PIUP i PIVP kojima se definiraju ulazne varijable modela za parkirališta, a zatim se izvršava za podatke PIEP kojima se definiraju ulazne varijable modela za električne punionice. Ulazne varijable modela za osnovni i kontekstni pristup u stvaranju modela iskoristivosti prikazane su na slici 4.9. Skup ulaznih varijabli *VRIJEME* definiran je pomoću polja *VRIJEME* u podacima PIUP, PIVP i PIEP. Ulazna varijabla *TIP DANA* predstavlja tip dana koji može biti radni dan ili vikend (subota i nedjelja). U slučaju da se radi o radnom danu, vrijednost varijable *TIP DANA* bit će 0, a ako se radi o vikendu će biti 1. Ulazna varijabla *GODIŠNJE DOBA* predstavlja godišnje doba i utvrđena je pomoću polja *VRIJEME* iz podataka PIUP-a, PIVP-a ili PIEP-a. Vrijednost varijable *GODIŠNJE DOBA* može biti *PROLJEĆE, LJETO, JESEN* i *ZIMA*. Ulazne varijable *PRAZNIK* i *DAN NAKON PRAZNIKA* označavaju je li na dan kad je evidentirana iskoristivost iz podataka modela iskoristivosti bio državni praznik u Hrvatskoj ili se radilo o danu nakon praznika. Ako je za polje *VRIJEME* zapisa iskoristivosti utvrđeno da se radi o državnom praznika ili danu nakon državnog praznika, postavlja se vrijednost 1, a s druge strane, u suprotnom se slučaju postavlja vrijednost 0.

Ulazna varijabla *NAPLATA PARKINGA* ukazuje na to naplaćuje li se trenutačno parking ili

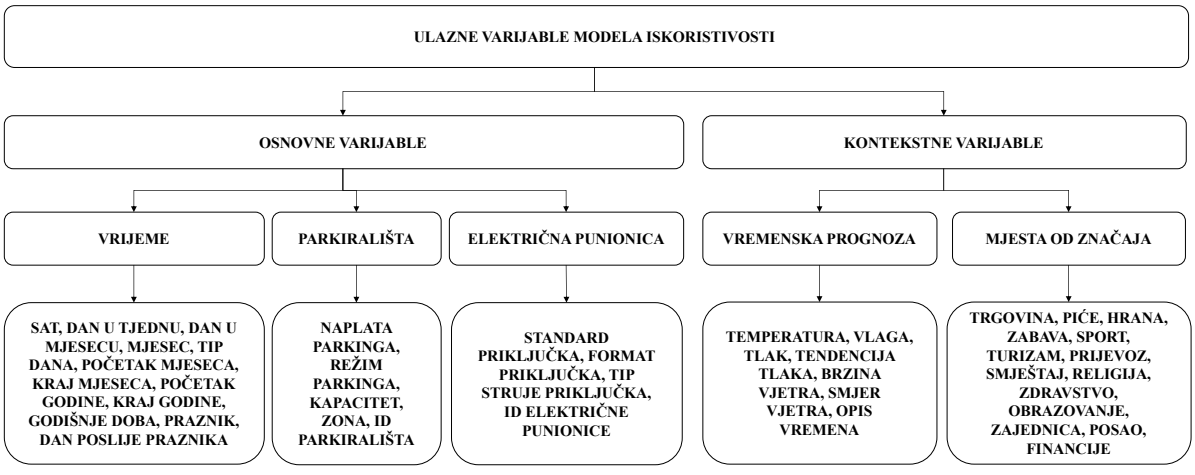

Slika 4.9: Prikaz ulaznih varijabli modela iskoristivosti

ne. Od ponedjeljka do petka u gradu Splitu naplaćuje se parking od 6 sati ujutro pa sve do 21 sat navečer za parkirališta u prvoj zoni, dok se za ostala parkirališta u drugim zonama naplaćuje od 7 sati do 19 sati. Subotom se parking naplaćuje od 7 sati do 14 sati, a u nedjelju nema naplate parkinga. Vrijednost 1 varijable *NAPLATA PARKINGA* označava da se korištenje parkirališta naplaćuje, a vrijednost 0 da nema naplate. Ulazna varijabla *REŽIM PARKINGA* označava primjenjuje li se trenutačno zimski ili ljetni režim naplate korištenja parkirališta. Zimski režim naplate parkiranja počinje od listopada pa sve do lipnja, nakon čega počinje ljetni režim naplate. Vrijednost 1 za varijablu *REŽIM PARKINGA* označava da se radi o zimskom režimu, a vrijednost 0 da se radi o ljetnom režimu parkinga. Ulazne varijable *KAPACITET* i *ZONA* definirane su prikupljenim informacijama o parkiralištima u fazi prikupljanja podataka gdje je kapacitet parkirališta definiran brojem parkirališnih mjesta, dok zona u kojoj se parkiralište nalazi može biti jedna od sljedećih vrijednosti: 1, 2, 3 i 4. Ostale ulazne varijable vezane su uz polja koja su definirana za podatke PIUP i PIVP te su opisana u fazi pripreme podataka.

Sljedeći skup ulaznih varijabli vezan je uz modele iskoristivosti električnih punionica. Ulazne varijable *STANDARD IEC 62196 T2, STANDARD CHADEMO, STANDARD IEC 62196 T2 COMBO* i *STANDARD DOMESTIC G* označavaju broj priključaka koje električna punionica posjeduje za određeni standard. Skup ulaznih varijabli za definiranje standarda vezan je samo uz standarde koji se koriste na električnim punionicama operatora Hrvatski Telekom. Ulazne varijable *FORMAT UTIČNICA* i *FORMAT KABEL* određuju broj priključaka određenog formata koje električna punionica posjeduje. Operator Hrvatski Telekom razlikuje dva tipa formata priključka: utičnica i kabel. Ulazne varijable *TIP STRUJE DC, TIP STRUJE AC 1 FAZA* i *TIP STRUJE AC 3 FAZA* označavaju broj priključaka električne punionice koje pružaju određeni tip snage punjenja čime se definira brže ili sporije punjenje električnog vozila. Tip struje *DC* definira vrlo brzo punjenje putem izmjenične struje dok *AC 1 FAZA* definira sporo punjenje istosmjernom strujom, a *AC 3 FAZA* definira brzo punjenje također putem istosmjerne struje. Ostale ulazne varijable definirane su već opisom podataka PIEP.

Ulazne varijable kao što su *GODIŠNJE DOBA* nemaju numeričku reprezentaciju vrijednosti, već kategoričku. U slučaju kategoričkih ulaznih varijabli, potrebno je upotrijebiti kodiranje ulaznih varijabli kako bi metoda ML-a mogla ispravno obraditi takve značajke. Za kodiranje kategoričkih ulaznih varijabli upotrebljava se *One-Hot Encoding*, gdje se za svaku kategoriju kategoričke ulazne varijable stvara nova ulazna varijabla koja vrijednošću 1 ukazuje na postojanje određene kategorije, dok vrijednošću 0 ukazuje na nepostojanje te kategorije za određeni zapis iz skupa podataka koji upotrebljava metoda ML-a [124]. Za stvaranje modela iskoristivosti koriste se metode ML-a *Random Forest* i *CatBoost*. Svaka metoda ima skup ulaznih parametra koje je potrebno prethodno podesiti za što bolju izvedbu modela. Za podešavanja ulaznih parametara metoda ML-a koristi se metoda *Random Search*. Podešavanje parametra metode ML-a odvija se prije faze treniranja modela i poslije nje. Nakon inicijalnog podešavanja ulaznih pa-

rametara metode ML-a, provodi se eliminacija ulaznih varijabli modela. Eliminacija ulaznih varijabli modela provodi se metodom rekurzivne eliminacije varijabli, gdje se u svakoj iteraciji eliminira najmanje značajna ulazna varijabla modela te se model po eliminaciji varijable ponovno trenira. Ovo je ponavljajuć proces koji se zaustavlja nakon što ostvari najbolji skup ulaznih varijabli kojim se ostvaruje najbolji rezultat modela.

Procjena modela iskoristivosti prikazana na slici 4.10 provodi se upotrebom metoda *Hold-Out* i *KFold Cross-Validation*. Metoda *Hold-Out* dijeli izvorni skup podataka u dva odvojena skupa podataka, od kojih se jedan koristi za treniranje modela, a drugi za testiranje modela. Omjer podjele podataka koji se koristi jest 25% podataka za testiranje i 75% za podataka za treniranje modela. Metoda *KFold Cross-Validation (KFold-CV)* koristi se za procjenu modela pomoću podskupova podataka iz izvornog skupa podataka provjeravajući time je li model dovoljno generičan te daje li dobre rezultate za različite varijacije podataka. Metoda dijeli izvorni skup podataka na K broj podskupova, gdje se svaki podskup u određenoj iteraciji upotrebljava kao skup podataka za testiranje modela. Pomoću metode *Hold-Out* u fazi procjene modela iskoristivosti radi se usporedba ostvarenih modela kako bi se odabrao onaj najbolji, dok pomoću metode *KFold-CV* provjeravamo je li ostvareni model dovoljno otporan na varijacije u podacima.

Za potvrđivanje uspješnosti modela iskoristivosti upotrebljavaju se sljedeće statističke mjere: koeficijent determinacije (R^2), srednja apsolutna pogreška (eng. *mean absolute error* (MAE)) i srednja kvadratna pogreška (eng. *mean squared error* (MSE)). R^2 je mjera izvedbe regresijskog modela koja daje postotak varijance izlazne varijable objašnjene ulaznim varijablama [125]. Definirana je jednadžbom 4.3 gdje je ukupni zbroj kvadrata reziduala između stvarnih y i predviđenih $\hat{y}$ vrijednosti podijeljen s ukupnim zbrojem kvadrata između stvarne y i srednje $\bar{y}$ vrijednosti. Vrijednost mjere R^2 jednaka 1 označava da se predviđene vrijednosti regresijskog

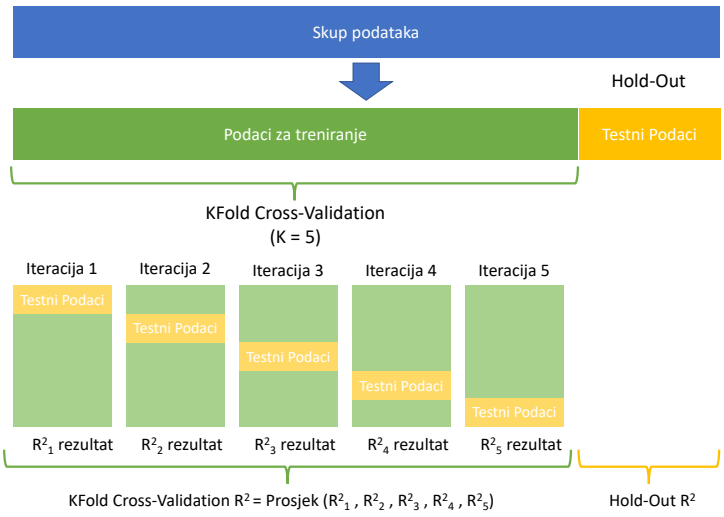

Slika 4.10: Provjera valjanosti modela iskoristivosti s metodama *KFold Cross-Validation* i *Hold-Out*

modela savršeno podudaraju sa stvarnim podacima. Mjera MAE definirana je jednadžbom 4.4 i pokazuje stopu pogreške između predviđene vrijednosti $\hat{y}$ i stvarne vrijednosti y. Mjera MSE definirana je jednadžbom 4.5 i predstavlja srednju kvadratnu razliku između predviđene vrijednosti $\hat{y}$ i stvarne vrijednosti y. Mjere MAE i MSE s vrijednostima bližim 0 ukazuju na bolji model [126].

$$R^2 = 1 - \frac{\sum_{i=1}^{n} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{n} (y_i - \bar{y})^2} \tag{4.3}$$

$$MAE = \frac{\sum_{i=1}^{n} |\hat{y}_i - y_i|}{n} \tag{4.4}$$

$$MSE = \frac{\sum_{i=1}^{n} (y_i - \hat{y}_i)^2}{n} \tag{4.5}$$

U fazi procjene modela iskoristivosti odabire se najbolji model iskoristivosti tako da se uspoređuju vrijednosti statističkih mjera R^2, MAE i MSE svakog modela. Model iskoristivosti s najvećom vrijednošću mjere R^2 i najmanjim vrijednostima mjera MAE i MSE proglašava se najboljim. Ako mjere ostvarene za modele iskoristivosti nisu zadovoljavajuće, poduzima se korak natrag u fazu stvaranja modela kako bi se ostvario bolji modeli iskoristivosti. Postoji mogućnost da daljnja poboljšanja modela iskoristivosti nisu moguća te se u tom slučaju poduzima korak prema fazi razumijevanja domene. Po odabiru najboljeg modela iskoristivosti za električne punionice, ulična i vanulična parkirališta, modeli se mogu implementirati unutar prethodno definiranih algoritama za usmjeravanje električnih vozila. Nadalje, ostvareni modeli mogu se koristiti i u mobilnim aplikacijama pomoću kojih korisnici mogu ostvariti brži pronalazak slobodnog parkirališnog mjesta ili slobodne električne punionice.

4.4.7Rezultati modela iskoristivosti

Model iskoristivosti za ulična i vanulična parkirališta stvoren je za parkirališta u gradu Splitu, dok je model iskoristivosti električnih punionica stvoren za električne punionice operatora Hrvatski Telekom u Hrvatskoj. Za ostvarivanje modela iskoristivosti uličnih i vanuličnih parkirališta upotrebljavaju se 44 uličnih parkirališta i 10 vanuličnih, koja su prikazana na slici 4.11, gdje je pod *a* prikaz karte s lokacijama svih parkirališta, dok *b* i *c* prikazuju distribuciju kapaciteta uličnih i vanuličnih parkirališta, pri čemu je kapacitet definiran brojem parkirališnih mjesta koje parkiralište posjeduje. Iz distribucije kapaciteta možemo vidjeti da su ulična parkirališta u pravilu manja, dok vanulična imaju veći broj parkirališnih mjesta, što rezultira većim brojem zapisa o parkiranju za jedno vanulično parkiralište u odnosu na jedno ulično parkiralište.

Model iskoristivosti za električne punionice stvoren je za električne punionice operatora Hrvatski Telekom u Hrvatskoj. Hrvatski Telekom u Hrvatskoj trenutno ima 138 električnih

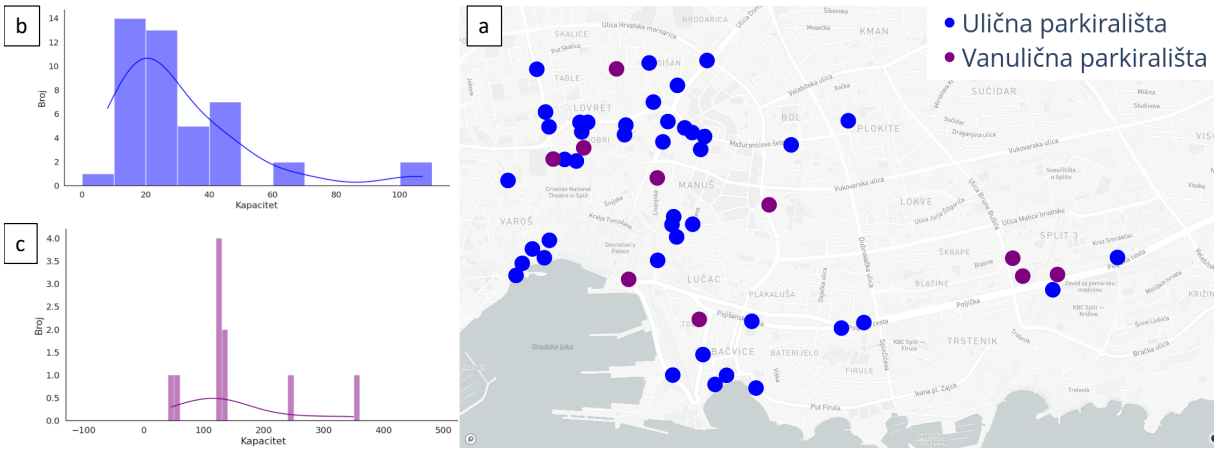

Slika 4.11: Prikaz uličnih i vanuličnih parkirališta u gradu Splitu: a) Karta s lokacijama uličnih i vanuličnih parkirališta; b) Distribucija kapaciteta uličnih parkirališta; c) Distribucija kapaciteta vanuličnih parkirališta

punionica od kojih se sedam nalazi u gradu Splitu. Na slici 4.12 prikazane su električne punionice korištene u ostvarivanju modela iskoristivosti, gdje su pod *a* prikazane lokacije električnih punionica na karti, a *b* prikazuje distribuciju kapaciteta korištenih električnih punionica te *c* prikazuje lokacije električnih punionica za grad Split koje se upotrebljavaju u simulaciji višeagentskog sustava za usmjeravanje električnih vozila. Kapacitet električnih punionica definiran je brojem priključaka koje električna punionica posjeduje za pružanje punjenja električnog vozila.

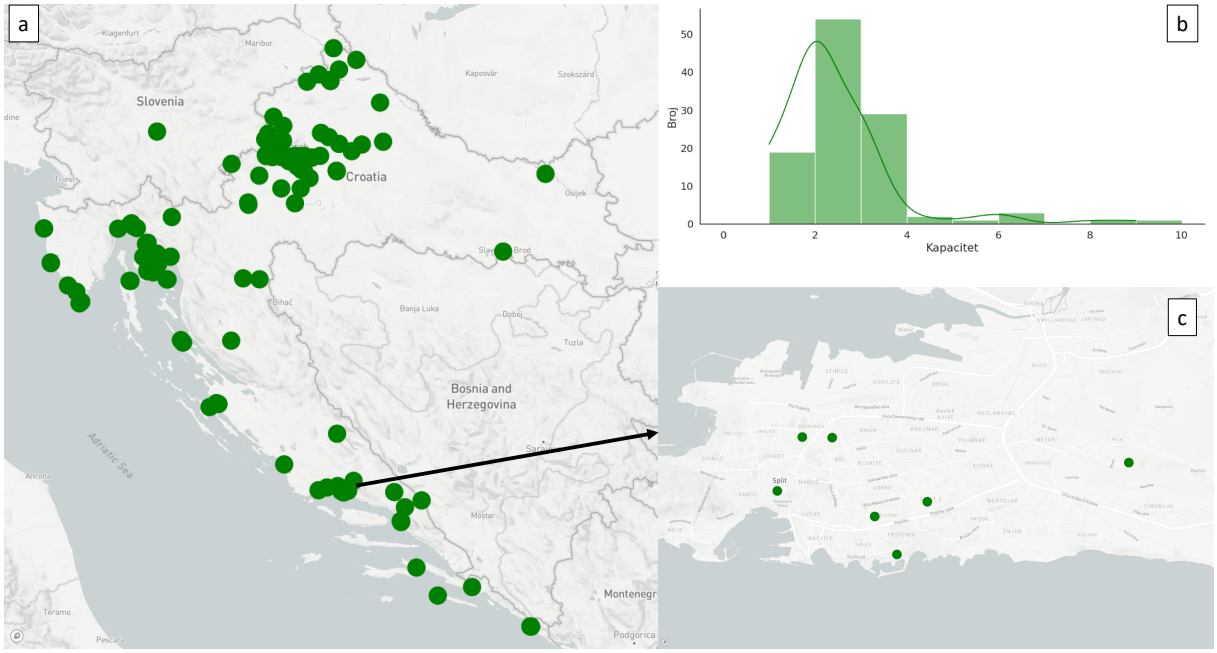

Slika 4.12: Prikaz električnih punionica u Hrvatskoj: a) Karta s lokacijama električnih punionica; b) Prikaz distribucije kapaciteta električnih punionica; c) Prikaz električnih punionica u gradu Splitu

Deskriptivna analiza

Deskriptivna analiza provedena je nad skupovima podataka PIUP, PIVP i PIEP. Iskoristivost uličnih i vanuličnih parkirališta u gradu Splitu i iskoristivost električnih punionica za operatora Hrvatski Telekom u Hrvatskoj prikazani su na slici 4.13. Za prikaz iskoristivosti uličnih parkirališta izuzeta je vrijednost iskoristivosti 0% jer takvih zapisa ima 50.813. Iskoristivost uličnih parkirališta prema slici 4.13 kreće se između 38% i 75% s prosjekom od 59%. Iskoristivost vanuličnih parkirališta za grad Split kreće se između 36% i 87% s prosjekom od 61%, dok se iskoristivost električnih punionica prema slici 4.13 kreće između 28% i 81% s prosjekom od 55%. Iz ovoga možemo zaključiti da se ulična parkirališta u gradu Split u prosjeku nešto manje koriste od vanuličnih parkirališta, dok se električne punionice operatora Hrvatski Telekom u Hrvatskoj u prosjeku manje koriste od uličnih i vanuličnih parkirališta u gradu Split. Razlog ovome jest postojanje manjeg broja korisnika koji upotrebljavaju električne punionice u odnosu na broj korisnika koji se koriste uslugom parkiranja na parkiralištima.

Slika 4.14 prikazuje prosječan dan za električne punionice, ulična i vanulična parkirališta. Može se vidjeti da se u prosjeku ulična parkirališta koriste više od vanuličnih parkirališta. Ulična i vanulična parkirališta tijekom dana u periodu od 8 sati do 17 sati imaju povećanu iskoristivost što se može povezati s time da se koriste za dolazak i odlazak s radnog mjesta. Radno vrijeme vanuličnih parkirališta jest 0-24 sata, dok ulična parkirališta, ovisno o zoni kojoj pripadaju, imaju radno vrijeme do 19 ili 21 sat, što rezultira povećanjem iskoristivosti uličnih parkirališta u odnosu na vanulična parkirališta u periodu od 17 sati pa sve do ponoći. Električne punionice zbog vrlo malog kapaciteta koji u prosjeku iznosi 1 ili 2 uzrokuje vrlo nagle poraste u iskoristivosti te se ona u prosjeku kreće oko 0%, što označava da se punionica uopće ne koristi

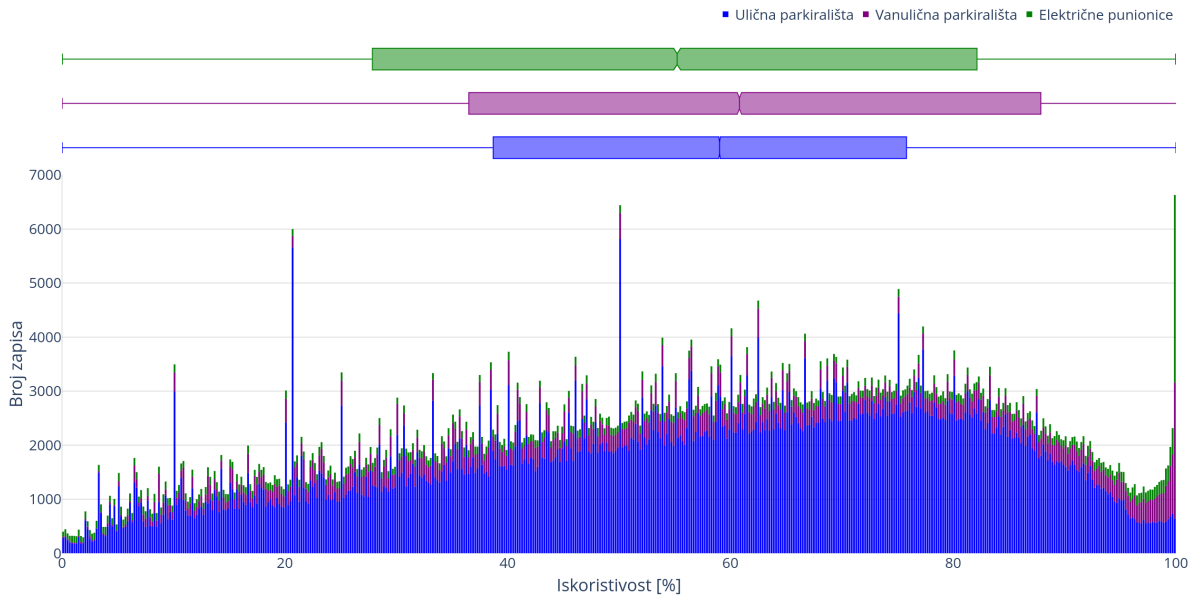

Slika 4.13: Distribucija iskoristivosti električnih punionica u Hrvatskoj te uličnih i vanuličnih parkirališta u gradu Splitu

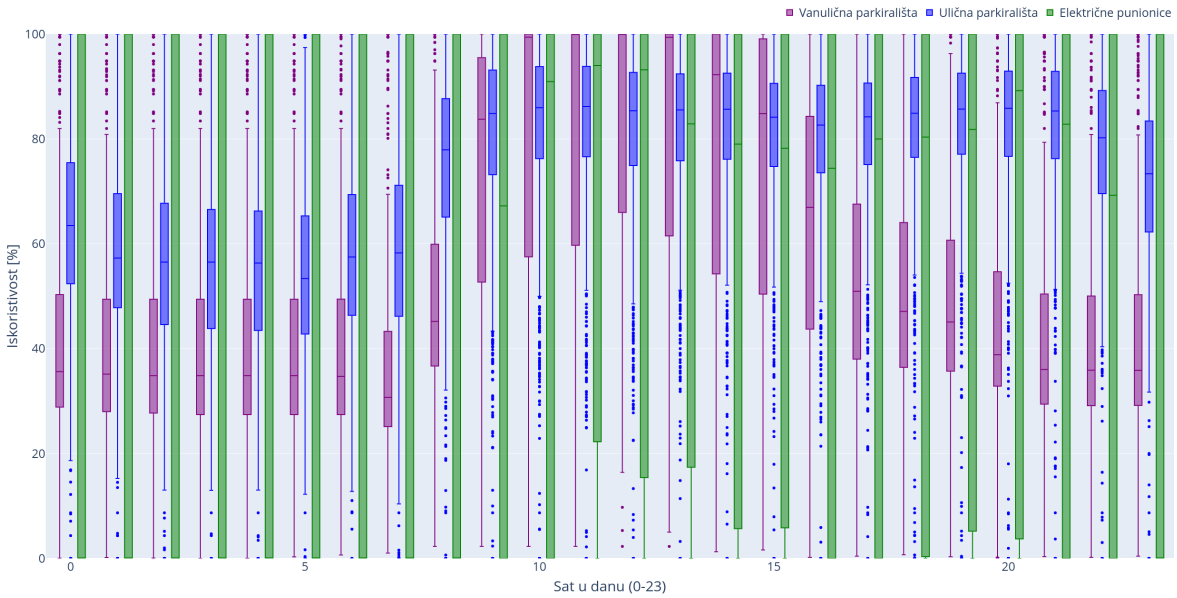

Slika 4.14: Prikaz prosječnog dana za ulična i vanulična parkirališta u gradu Splitu i električnih punionica za Hrvatsku

ili 100%, što označava da se svi priključci punionice upotrebljavaju unutar sat vremena. Iz slike 4.14 vidljivo je da se električne punionice koriste više u periodu od 10 sati pa sve do 16 sati, što se može povezati s trendom punjenja vozila tijekom obavljanja dnevnog posla ili obavljanja kupovine u trgovini ili trgovačkom centru. Dodatan skok u korištenju punionica jest u periodu od 19 sati pa do 21 sat što se može povezati s odlaskom u restoran ili rekreacijski centar pri čemu se vozilo ostavlja na punjenju kod punionice.

Slika 4.15 prikazuje prosječan tjedan električnih punionica, uličnih i vanuličnih parkirališta.

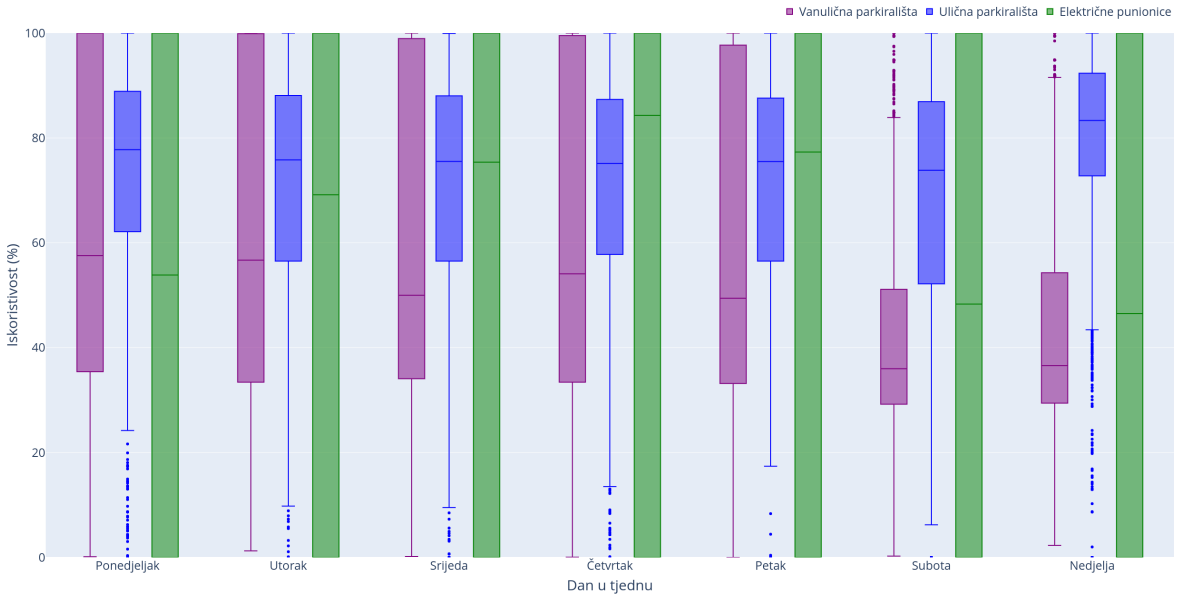

Slika 4.15: Prikaz prosječnog tjedna za ulična i vanulična parkirališta u gradu Splitu i električnih punionica za Hrvatsku

Vidljivo je da ulična parkirališta tijekom cijelog tjedna imaju veću iskoristivost od vanuličnih parkirališta, pri čemu im je tijekom vikenda iskoristivost u porastu, dok je kod vanuličnih parkirališta u padu. Razlog je tome naplata vanuličnih parkirališta tijekom cijelog tjedna, dok su ulična parkirališta tijekom nedjelje besplatna, a tijekom subote naplata završava već u 14 sati. Električne punionice tijekom radnih dana u tjednu bilježe povećanu iskoristivost, dok se tijekom vikenda manje koriste. Razlog tome može biti dolazak i odlazak na radno mjesto tijekom radnih dana u tjednu, pri čemu korisnici ostavljaju vozila na punionicama da se pune.

Prediktivna analiza

Faza definiranje analitičkog pristupa određuje osnovni i kontekstni pristup u izradi modela iskoristivosti koja se kombiniraju s metodama ML-a *Random Forest* i *CatBoost*. U kontekstnom pristupu stvaranja modela iskoristivosti koriste se mjesta od značaja i vremenska prognoza kao kontekstni podaci. Ovime dobivamo šest modela iskoristivosti za predviđanje iskoristivosti koje treba međusobno usporediti kako bi se utvrdio najbolji model iskoristivosti. Dodatno se definira i *dummy* model koji vrši predviđanje prema definiciji danoj u fazi stvaranja modela. Model iskoristivosti stvara se za električne punionice, ulična i vanulična parkirališta te se time u konačnici ostvaruje 21 model iskoristivosti. Za stvaranje modela iskoristivosti korišteno je računalo s 64 GB RAM-memorije i procesorom Intel Xeon E5-2650 koje se koristi operativnim sustavom Linux Fedora. Prikaz rezultata svih modela prikazan je u tablici 4.16.

Modeli iskoristivosti za ulična parkirališta za osnovni pristup upotrebljavaju podatke PIUP, a za kontekstni pristup podatke PKIUP, pri čemu za kontekst *mjesta od značaja* koriste podatke PKIUP_{PoI} dok za kontekst *vremenska prognoza* koriste PKIUP_{VP}. Rezultati modela iskoristivosti dani su u tablici 4.16, gdje se može vidjeti da model iskoristivosti koji upotrebljava kontekstni pristup s kontekstom mjesta od značaja daje najbolje rezultate za R^2, MAE i MSE. Najbolji model ostvaruje R^2 od 92,84% što je za 4,68% bolje od najboljeg modela iskoristivosti u osnovnom pristupu koji ima R^2 od 88,16%, dok je najlošiji model *dummy*, model koji ostvaruje R^2 od 61,29%. Nadalje, može se vidjeti da u osnovnom i kontekstnom pristupu uvijek metoda ML-a *CatBoost* daje bolje rezultate u predviđanju iskoristivosti od metode *Random Forest*. U osnovnom pristupu metoda *Random Forest* ostvaruje R^2 od 84,31%, što je slabije za 3,85% od metode *CatBoost* koja ostvaruje R^2 od 88,16% te je ujedno najbolji model za osnovni pristup. U kontekstnom pristupu za kontekst *vremenska prognoza CatBoost* ostvaruje R^2 od 88,83% što je bolje za 1,7% od metode *Random Forest* s R^2 od 87,13%. *Random Forest* u slučaju konteksta ostvaruje bolji R^2 rezultat od 1,55%, dok *CatBoost* bilježi poboljšanje od 4,01%. U oba slučaja konteksta, modeli s kontekstom mjesta od značaja daju bolje predviđanje iskoristivosti od modela s kontekstom vremenska prognoza. Na temelju tablice 4.16 model 6 najbolji je model iskoristivosti za predviđanje iskoristivosti uličnih parkirališta i uzima se u obzir kod algoritama za usmjeravanje električnih vozila definiranih u poglavlju 4.3.

Tablica 4.16: Rezultati modela iskoristivosti (Istaknuti su najbolji modeli iskoristivosti za električne punionice, ulična i vanulična parkirališta)

	Kontekst	Model	R^2	MAE	MSE
Ulično parkiralište	-	Model 0	61,29	11,52	272,41
	-	Model 1	84,31	7,54	110,34
	-	Model 2	88,16	6,99	82,27
	Vremenska prognoza	Model 3	87,13	6,85	90,57
	Vremenska prognoza	Model 4	88,83	6,71	78,62
	PoI	Model 5	88,68	6,11	76,55
	PoI	**Model 6**	**92,84**	**5,15**	**48,43**
Vanulično parkiralište	-	Model 0	67,65	9,89	264,81
	-	Model 1	88,27	6,41	96,04
	-	Model 2	95,98	3,97	32,85
	Vremenska prognoza	Model 3	92,49	4,89	61,94
	Vremenska prognoza	Model 4	96,35	3,57	30,40
	PoI	Model 5	92,80	4,68	59,41
	PoI	**Model 6**	**97,04**	**3,15**	**24,45**
Električna punionica	-	Model 0	32,54	13,15	1217,64
	-	Model 1	91,55	4,62	178,18
	-	Model 2	90,95	6,05	190,87
	Vremenska prognoza	Model 3	89,51	6,01	221,26
	Vremenska prognoza	Model 4	88,83	7,74	235,72
	PoI	Model 5	91,68	4,60	177,76
	PoI	**Model 6**	**91,78**	**5,51**	**175,99**

Na slici 4.16 pod *a* prikazana je važnost ulaznih varijabli svih modela iskoristivosti uličnih parkirališta osim modela *dummy*. Može se vidjeti da u svih 6 modela iskoristivosti varijable *ID PARKIRALIŠTA*, *SAT*, *DAN U MJESECU* i *MJESEC* vrlo su važne varijable. Uključivanjem konteksta, ove varijable bilježe drugačije važnosti ovisno o kontekstu, pri čemu im određeni kontekst smanjuje važnost, dok drugi povećava. Varijabla *SAT* bilježi najveću važnost za kontekst *mjesta od značaja*, dok za kontekst *vremenska prognoza* bilježi najmanju važnost. Slično ponašanje imaju i varijable *DAN U MJESECU* i *MJESEC* za promjenu tipa konteksta, gdje varijable za kontekst *mjesta od značaja* bilježe veću važnost od konteksta vremenska prognoza. Varijabla *KAPACITET* je primjerice vrlo važna varijabla u modelima 1, 2, 3 i 4, ali uključiva-

njem konteksta mjesta od značaja u potpunosti gubi važnost u predviđanju iskoristivosti, dok za kontekst *vremenska prognoza* bilježi znatno povećanje važnosti. Kontekstne varijable *PIĆE*, *HRANA* i *ZABAVA* konteksta mjesta od značaja te kontekstne varijable *TEMPERATURA* i *TLAK* konteksta vremenska prognoza, najvažnije su kontekstne varijable u modelu iskoristivosti uličnih parkirališta te uzrokuju smanjivanje važnosti osnovnih varijabli. Na slici 6.2 dodatka 6 prikazuje se važnost svih varijabli koje modeli iskoristivosti uličnih parkirališta koriste i može se vidjeti da varijable su konteksta mjesta od značaja brojnije od varijabli konteksta vremenska prognoza, što dovodi do zaključka da je kontekst *mjesta od značaja* bolji kontekst za korištenje u predviđanju iskoristivosti uličnih parkirališta. Brojnost kontekstnih varijabli uzrokuje i veće preuzimanje važnosti s varijabli iz osnovnog pristupa, što dokazuje važnost konteksta u predviđanju iskoristivosti uličnih parkirališta.

Modeli iskoristivosti za vanulična parkirališta za osnovni pristup koriste se podacima PIVP, dok se za kontekstni pristup koriste podacima PKIVP_{VP} u slučaju konteksta vremenske prognoze ili PKIVP_{PoI} u slučaju konteksta mjesta od značaja. Rezultati modela iskoristivosti za vanulična parkirališta prikazana su u tablici 4.16, pri čemu je model 6 označen kao najbolji model za predviđanje iskoristivosti vanuličnih parkirališta. Model 6 ima R^2 od 97,04% i bolji je od najboljeg modela iz osnovnog pristupa za 1,06% te upotrebljava *CatBoost* kao metodu ML-a i kontekstni pristup, pri čemu kao kontekst upotrebljava mjesta od značaja. *Dummy* model predstavljen modelom 0 najlošiji je model iskoristivosti s R^2 od 67,65%. U osnovnom i kontekstnom pristupu metoda *CatBoost* postiže bolje rezultate, pri čemu u osnovnom pristupu postiže 7,71% bolji rezultat R^2 od metode *Random Forest*, dok u kontekstnom pristupu razlika iznosi 3,86% za kontekst *vremenska prognoza* te 4,24% za kontekst *mjesta od značaja*. Model 6 kao najbolji model iskoristivosti odabran je za predviđanje iskoristivosti vanuličnih parkirališta i koristi se u algoritmima za usmjeravanje električnih vozila definiranih u poglavlju 4.3.

Na slici 4.16 pod *b* je prikazana važnost ulaznih varijabli svih modela iskoristivosti vanuličnih parkirališta osim modela *dummy*. Može se vidjeti da su u svih 6 modela iskoristivosti varijable *SAT*, *DAN U TJEDNU* i *MJESEC* vrlo važne varijable za predviđanje iskoristivosti. Za razliku od modela iskoristivosti uličnih parkirališta gdje, ovisno o kontekstu koji se koristi, važnost varijable može se smanjivati za jedan tip konteksta, dok se za drugi može povećati, ovdje za varijablu *SAT* bilježi se porast važnosti za svaki tip konteksta, pri čemu za kontekst *mjesta od značaja* ostvaruje najveću važnost za predviđanje iskoristivosti. Varijable *ID PARKIRALIŠTE* i *KAPACITET* imaju jednako ponašanje kao i kod modela iskoristivosti uličnih parkirališta te za kontekst *mjesta od značaja* imaju vrlo malu, gotovo nikakvu važnost kod predviđanja iskoristivosti. Kontekstne varijable *PIĆE*, *SMJEŠTAJ* i *ZDRAVSTVO* konteksta mjesta od značaja te varijabla *TEMPERATURA* konteksta vremenska prognoza važne su za predviđanje iskoristivosti vanuličnih parkirališta, pri čemu smanjuju važnost osnovnih varijabli kao što su varijable *DAN U TJEDNU* i *MJESEC*. U dodatku 6 na slici 6.1 prikazana je cjelokupna važnost svih varijabli

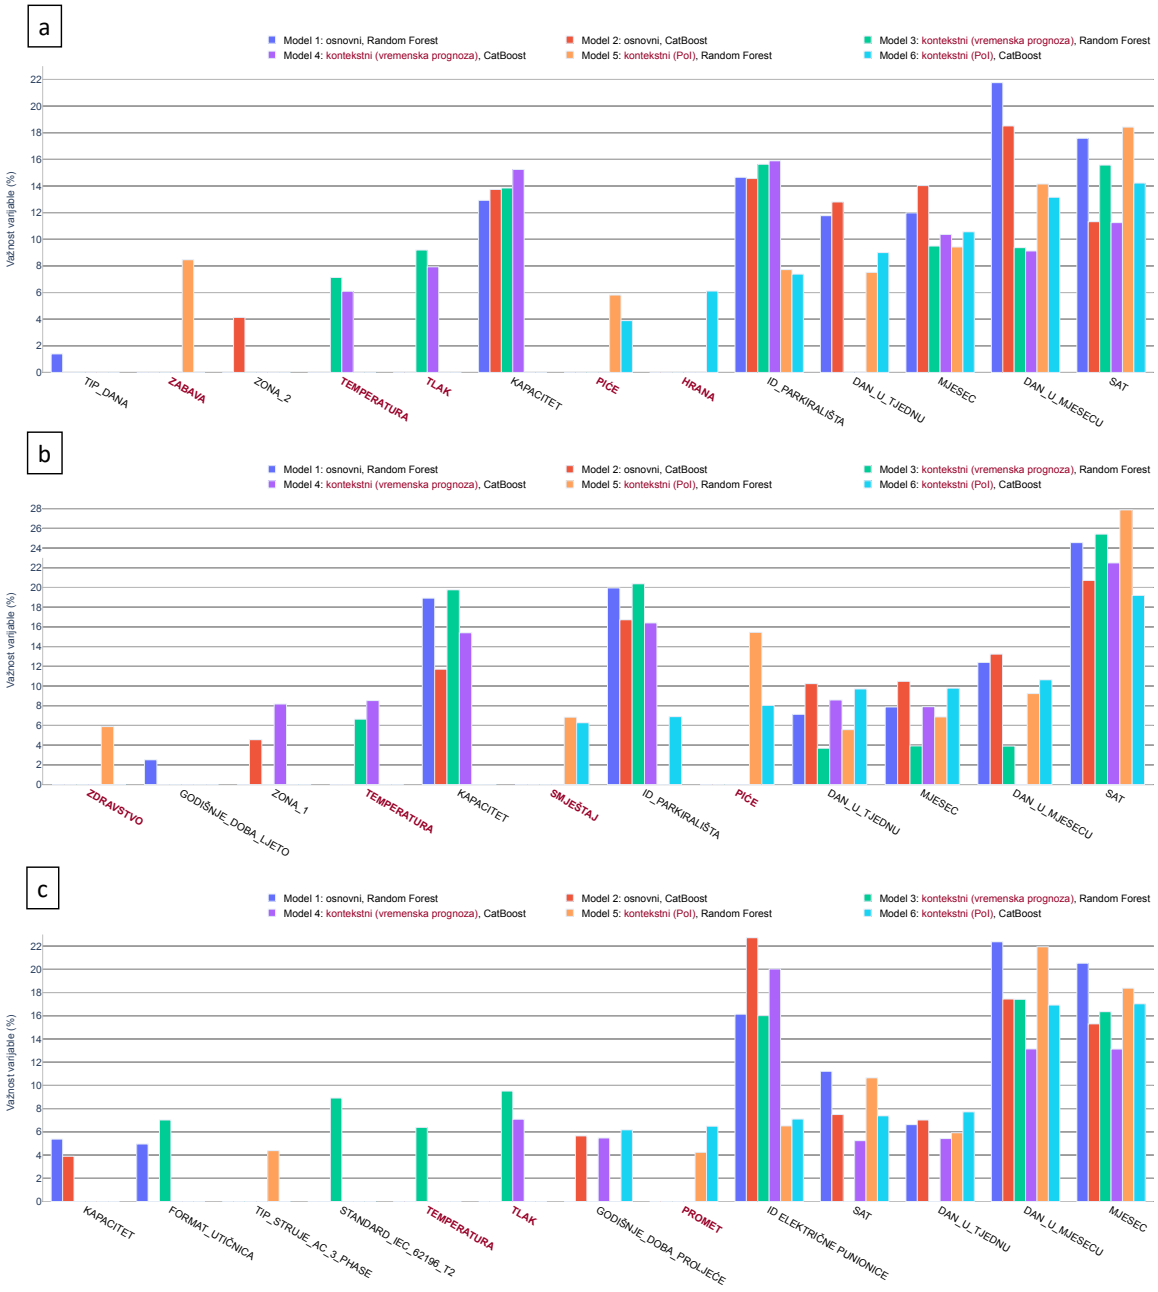

Slika 4.16: Prikaz prvih sedam najvažnijih ulaznih varijabli modela iskoristivosti: a) ulična parkirališta; b) vanulična parkirališta, c) električne punionice

koje modeli iskoristivosti vanuličnih parkirališta koriste te je vidljivo prevladavanje kontekstnih varijabli, posebice konteksta mjesta od značaja. To dovodi do zaključka da korištenje konteksta u predviđanju modela iskoristivosti pospješuje rezultate modela.

Modeli iskoristivosti za električne punionice upotrebljavaju za osnovni pristup podatke PIEP, dok se za kontekstni pristup u slučaju konteksta mjesta od značaja koriste podacima PKIEP_{PoI}, a za kontekst *vremenska prognoza* podacima PKIEP_{VP}. Rezultati modela iskoristivosti električnih punionica prikazani su u tablici 4.16, gdje se može vidjeti da model s kontekstnim pristupom za kontekst *mjesta od značaja* i s metodom *CatBoost* daje najbolje vrijednosti R^2, MAE i MSE.

Model 6 ostvaruje R^2 od 91,78%, što je nešto bolje od najboljeg modela s osnovnim pristupom, pri čemu je najbolji osnovni model ostvaren metodom *Random Forest* i ostvaruje R^2 od 91,55%. Modeli 3 i 4 koriste kontekstni pristup s kontekstom vremenska prognoza i ostvaruju slabije rezultate od ostalih modela, pri čemu i dalje bolje od *dummy* modela. *Dummy* model najslabiji je model s iznosom R^2 od 32,54%. Može se zaključiti da modeli iskoristivosti električnih punionica bolje rade s kontekstnim pristupom, ali samo za određene kontekste, gdje je u ovom slučaju to kontekst *mjesta od značaja*. Vremenska prognoza nije pokazala pozitivan utjecaj na predviđanje iskoristivosti električnih punionica, pri čemu je najbolji model s kontekstom vremenske prognoze slabiji od modela 6 kao najboljeg modela iskoristivosti za R^2 od 2,27%, dok je od najboljeg modela u osnovnom pristupu slabiji za R^2 od 0,23%. Za razliku od modela iskoristivosti uličnih i vanuličnih parkirališta kod modela iskoristivosti električnih punionica, metoda *Random Forest* za osnovni pristup i kontekstni pristup s kontekstom vremenske prognoze daje bolje rezultate od metode *CatBoost*. Rezultati modela iskoristivosti električnih punionica vrlo su slični, što se može vidjeti u razlici R^2 za Model 1 i 2, koja iznosi 0,60%, Modela 3 i 4 koja iznosi 0,68% te Modela 5 i 6 gdje razlika R^2 iznosi samo 0,10%. To nije slučaj kod modela iskoristivosti uličnih i vanuličnih parkirališta gdje razlike R^2 mogu biti veće i od 5%. Za najbolji model iskoristivosti električnih punionica označen je Model 6 i koristi se u algoritmima za usmjeravanje električnih vozila definiranih u poglavlju 4.3.

Na slici 4.16 pod *c* prikazana je važnost ulaznih varijabli svih modela iskoristivosti električnih punionica osim modela *dummy*. Može se vidjeti da su varijable *MJESEC* i *DAN U MJESECU* vrlo važne kod predviđanja iskoristivosti za sve modele. Varijabla *ID ELEKTRIČNE PUNIONICE* također je vrlo važna varijabla kod predviđanja iskoristivosti, ali njena važnost pada značajno uključivanjem kontekstnih varijabli konteksta mjesta od značaja. Varijable *SAT* i *DAN U TJEDNU* imaju vrlo nisku važnost za model 3 koji koristi kontekstni pristup s kontekstom vremenska prognoza i metodom *Random Forest*, čiju su važnost preuzele kontekstne varijable *TEMPERATURA* i *TLAK*. Osim varijable *ID ELEKTIRČNE PUNIONICE*, varijable *FORMAT UTIČNICE* i *TIP STRUJE AC 3 PHASE* te *STANDARD IEC 62196 T2* označavaju varijable specifične za električne punionice i one pridonose predviđanju iskoristivosti tek u slučaju korištenja metode *Random Forest*, dok metoda *CatBoost* ne prepoznaje ove varijable kao vrlo značajne za predviđanje. U dodatku 6 na slici 6.3 prikazana je cjelokupna važnost svih varijabli koje modeli iskoristivosti električnih punionica upotrebljavaju i može se vidjeti brojnost kontekstnih varijabli, posebice konteksta mjesta od značaja. Modeli iskoristivosti upotrebljavaju devet varijabli konteksta mjesta od značaja, dok se samo tri koriste varijablom konteksta vremenska prognoza, što dokazuje važnost konteksta mjesta od značaja za predviđanje iskoristivosti električnih punionica.

Poglavlje 5

Višeagentska platforma za simulaciju transportnog sustava flote električnih vozila

U ovom poglavlju opisana je višeagentska platforma za ostvarivanje modela višeagentskog sustava za usmjeravanje električnih vozila (VAS-UEV) iz poglavlja 3 koji koristi algoritme za usmjeravanje električnih vozila iz poglavlja 4. Višeagentska platforma za simulaciju transportnog sustava flote električnih vozila implementira model VAS-UEV koji je definiran skupom agenata, procesa i međuagentske komunikacije. Pomoću višeagentske platforme mogu se provoditi simulacije različitih scenarija iz stvarnog svijeta čija je svrha rješavanje kompleksnih problema ili optimizacije procesa iz stvarnog svijeta na financijski prihvatljiv način omogućujući pritom dublji uvid u sami sustav [127]. Postoji široki skup alata za ostvarivanje višeagentskih platformi [16], ali za implementaciju višeagentske platforme za simulaciju transportnog sustava flote električnih vozila upotrebljava se alat *AnyLogic*. Alat *AnyLogic* pokazao se kao dobar za provođenje simulacija usmjeravanja vozila i optimizacije procesa kroz višemetodni pristup koji uključuje višeagentski pristup i pristup obrade diskretnih događaja [128].

Poglavlje 5.1 opisuje izvedbu višeagentske platforme za simulaciju transportnog sustava flote električnih vozila opisan s modelom VAS-UEV korištenjem alata *AnyLogic*. Ostvarena platforma koristi se za funkcijsku analizu koja je prikazana u poglavlju 5.2. Funkcijska analiza sastoji se od prikaza simulacije usmjeravanja električnih vozila pomoću osnovnih algoritama i algoritama zasnovanim na AI-u. Dodatno, funkcijskom analizom opisana je simulacija optimizacije veličine flote koja je potrebna za provođenje simulacija usmjeravanja električnih vozila. Poglavlje 5.3 predstavlja tehno-ekonomsku analizu ostvarene platforme kroz mjerljive pokazatelje uspješnosti provođenja simulacija modela VAS-UEV koja se odnose na povećanje održivosti gradskih komunalnih procesa te poboljšanje korisničkog iskustva u korištenju električnih punionica i gradskih parkirališta.

5.1Izvedba platforme za simulaciju

Model VAS-UEV ostvaren je alatom *AnyLogic* za grad Split u svrhu obavljanja čišćenja gradskih parkirališnih površina pomoću električnih čistilica. Alat *AnyLogic* samostalna je aplikacija izvedena pomoću programskog jezika *Java* koji podržava višemetodno modeliranje koje se može sastojati od višeagentskog modeliranja, modeliranja diskretnih događaja i modeliranja dinamike sustava. Za model VAS-UEV koristi se višeagentsko modeliranje i modeliranje diskretnih događaja. Alat *AnyLogic* može se koristiti na osobnom računalu, pri čemu minimalne specifikacije sustava navedene u dodatku 6 moraju biti podržane, ili u oblaku gdje *AnyLogic* pruža mogućnost dijeljenja projekta s drugim sudionicima i omogućuje bržu izvedbu vrlo zahtjevnih simulacija. Višeagentsko modeliranje u alatu *AnyLogic* omogućuje ostvarivanje agenata definiranih u modelu VAS-UEV pomoću dijagrama stanja, statičkih i dinamičkih varijabli. *AnyLogic* dodatno za svaki agent definira prezentacijski sloj pomoću kojeg prikazuje agente tijekom simulacije. Modeliranje diskretnih događaja u alatu *AnyLogic* predstavlja apstrakciju određenog procesa kojim se pojednostavljuje shvaćanje i praćenje izvođenja samog procesa.

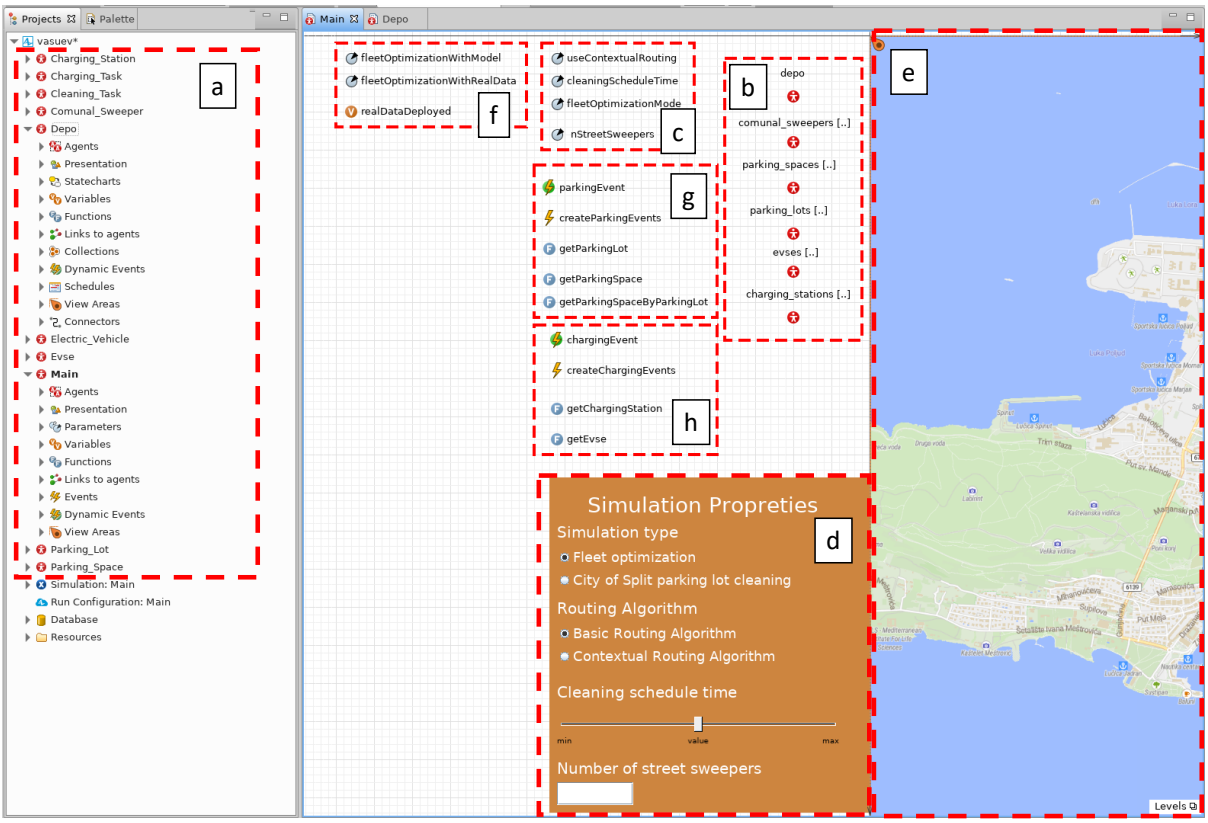

Slika 5.1: Prikaz platforme za simulaciju transportnog sustava električnih vozila definiranog višeagentskim modelom za usmjeravanje električnih vozila: a) prikaz agenata b) definicija agenata u korijenskom agentu c) parametri simulacije d) vizualno sučelje za upravljanje parametrima simulacije e) geografska karta za simulaciju usmjeravanja električnih vozila f) parametri modula optimizacije broja vozila u floti g) funkcije za ostvarivanje zauzeća parkirališta pomoću stvarnih podataka korištenja h) funkcije za ostvarivanje zauzeća električnih punionica pomoću stvarnih podataka korištenja

Ulaz u proces diskretan je događaj u obliku agenta. Model VAS-UEV definira nekoliko diskretnih događaja koji se ostvaruju tijekom rada i vezani su uz izvršavanje zadataka, korištenje električnih punionica i gradskih parkirališnih mjesta. Diskretni događaji modela VAS-UEV ostvareni su kao agenti jer to zahtijeva modeliranje diskretnih događaja u alatu *AnyLogic*. Izvedba platforme za simulaciju transportnog sustava flote električnih vozila definirana modelom VAS-UEV prikazana je na slici 5.1, pri čemu su pojedini dijelovi opisani u nastavku.

5.1.1Implementacija agenata

Za ostvarivanje modela VAS-UEV u alatu *AnyLogic* prvo je potrebno definirati sve tipove agenata koji će se koristiti. Opis modela VAS-UEV u poglavlju 3 ostvaren je višeagentskim modeliranjem i modeliranjem diskretnih događaja alata *AnyLogic* definirajući pritom tipove agenata modela VAS-UEV za korištenje u alatu *AnyLogic*. Alat *AnyLogic* upotrebljava hijerarhijski pristup u korištenju agenata pri čemu se izgrađuje stablo agenata. Korijen tog stabla predstavlja agenta najviše razine koji je početna točka simulacije. Agent najviše razine predstavlja najveću apstrakciju modela koji se želi ostvariti u alatu *AnyLogic*, ali nije dio definicije modela VAS-UEV, već je to specifičnost rada alata i potrebno ga je definirati. Stvaranjem platforme za simulaciju transportnog sustava u alatu *AnyLogic* stvara se prvo agent najviše razine pod imenom *Main*. Agent *Main* zadužen je za stvaranje agenata u platformi za simulaciju i upravlja životnim ciklusom svakog agenta tijekom simulacije. Prezentacijski sloj agenta *Main* predstavlja glavni prezentacijski sloj platforme za simulaciju koji je vidljiv korisniku tijekom izvođenja simulacije.

Nakon definiranja agenta *Main* definiraju se ostali agenti modela VAS-UEV koji su prikazani na slici 5.1 pod *a*. Model VAS-UEV definira agenta *Električno vozilo* kao apstraktnoga agenta kojeg mogu naslijediti agenti koji specificiraju određeni tip električnog vozila. U modelu VAS-UEV agent *Električna čistilica* nasljeđuje agenta *Električno vozilo* i definiran je u platformi agentom *Comunal Sweeper*, dok je agent *Električno vozilo* definirano agentom *Electric Vehicle*. Agent *Spremište vozila* u platformi definiran je agentom *Depo*, dok je agent *Električna punionica* definiran agentom *Charging Station* pri čemu je svaki priključak punionice (eng. *electric vehicle suplay equipment (evse)*) definiran kao agent *Evse*. Agent *Parkiralište* definiran je agentom *Parking Lot* te u slučaju uličnih parkirališta koja su opremljena prizemnim senzorima definiran je agent *Parking Space* koji predstavlja parkirališno mjesto. Svaki od definiranih tipova agenata dodaje se u agent *Main*, kao što je prikazano na slici 5.1 pod *b*, čime se radi statička inicijalizacija agenata koji će biti korišteni u simulaciji. Statička inicijalizacija agenta za simulaciju u agentu *Main* može se raditi na tri načina: pomoću baze podataka, kao lista agenata i kao pojedinačni agent. Inicijalizacija agenta *Električna punionica* prikazana je na slici 5.2 te prikazuje inicijalizaciju liste agenata pomoću tablice *charging stations* iz baze podataka gdje svaki zapis u tablici definira jednog agenta u listi.

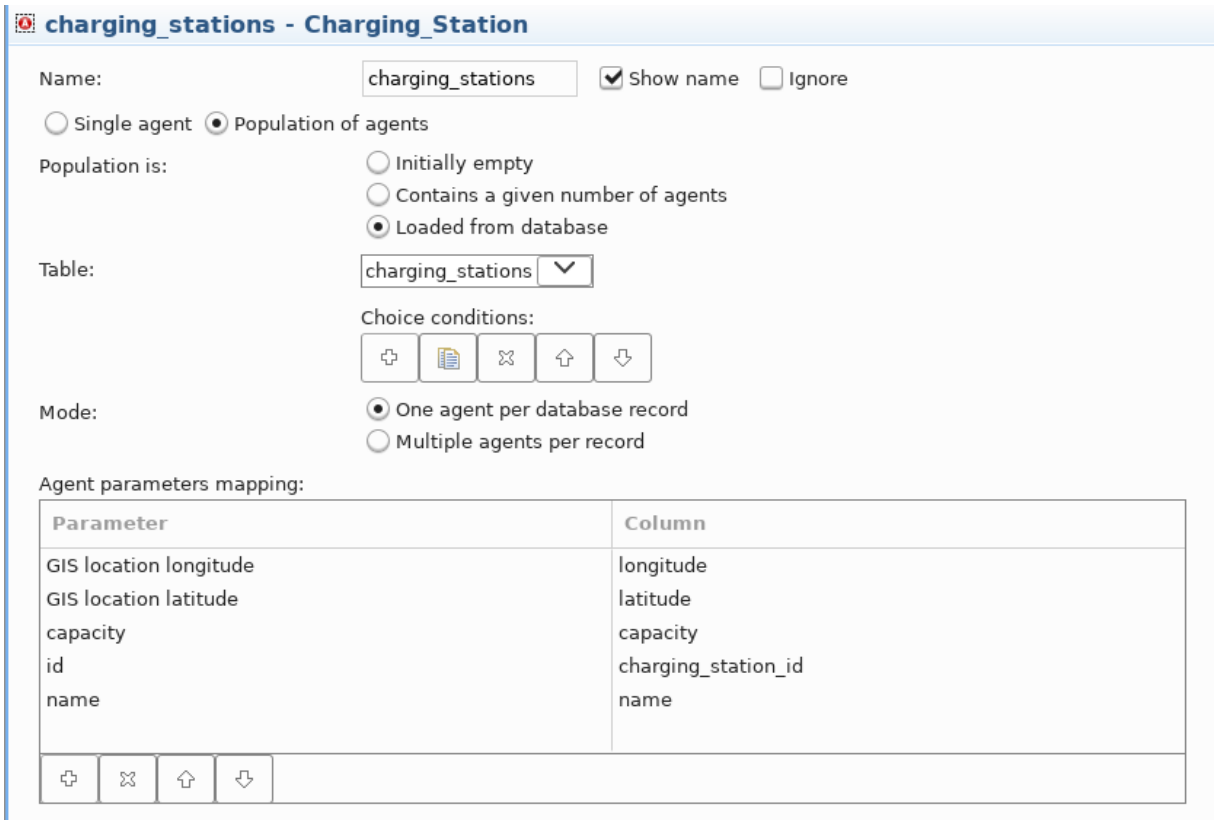

Slika 5.2: Prikaz stvaranja agenta električna punionica pomoću zapisa iz baze podataka

Agent *Parkiralište*, *Parkirališno mjesto* i *Evse* također se stvaraju na isti način kao i agent *Električna punionica* pomoću tablica iz base podataka. Agenti *Parkirališno mjesto* i *Evse* dio su agenata *Parkiralište* i *Električna punionica* te se dodjela agenata izvršava na početku rada agenata *Parkiralište* i *Električna punionica*. Dodjela agenata *Parkirališno mjesto* agentu *Parkiralište* prikazano je na slici 5.3 pod *b* gdje se može vidjeti da se provjerava je li parkirališno

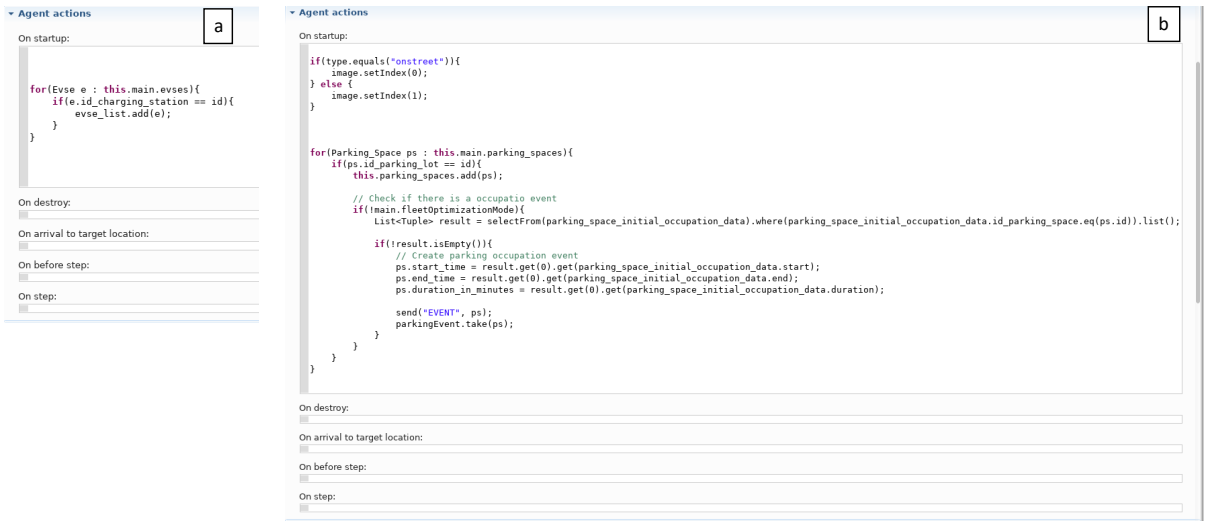

Slika 5.3: Prikaz dodjele agenata drugim agentima na početku rada simulacije: a) dodjela agenata *parkirališno mjesto* agentu *Parkiralište*; b) dodjela agenata *Evse* agentu *Električna punionica*

mjesto na početku simulacije zauzeto ili slobodno, čime se definira početno stanje agenta *Parkirališno mjesto* u dijagramu stanja. Na slici 5.3 pod *a* prikazana je dodjela agenata *Evse* agentima *Električna punionica*, pri čemu nema provjere početne dostupnosti jer se ustanovilo uvidom u podatke o korištenju da su svi priključci električnih punionica bili slobodni u trenutku pokretanja simulacije.

Agent *Električna čistilica* modela VAS-UEV definira se u agentu *Main* kao lista agenata, što se može vidjeti na slici 5.1 pod *b*, pri čemu se specificiraju vrijednosti statičkih parametara agenta. Lista agenata *Električna čistilica* predstavlja flotu vozila modela VAS-UEV. Flota električnih čistilica modela VAS-UEV homogena je i svako je vozilo jednakih karakteristika. Električna čistilica *RASCO Lynx Charge*[*] tvrtke RASCO[†] korištena je za ostvarivanje agenta *Električna čistilica*. Specifikacija električne čistilice *RASCO Lynx Charge* prikazana je u dodatku 6 na slici 6.4. Prikaz stvaranja flote agenta *Električna čistilica* s vrijednostima povezanim uz karakteristike električne čistilice *RASCO Lynx Charge* prikazana je na slici 5.4.

Model VAS-UEV definira samo jedno spremište vozila i zato se u agent *Main* dodaje samo

[*]RASCO Lynx Charge električna čistilica opis i specifikacija: https://rasco.hr/en/news/electric-street-sweeper/
[†]RASCO je proizvođač opreme za održavanje prometne infrastrukture sa sjedištem u Hrvatskoj

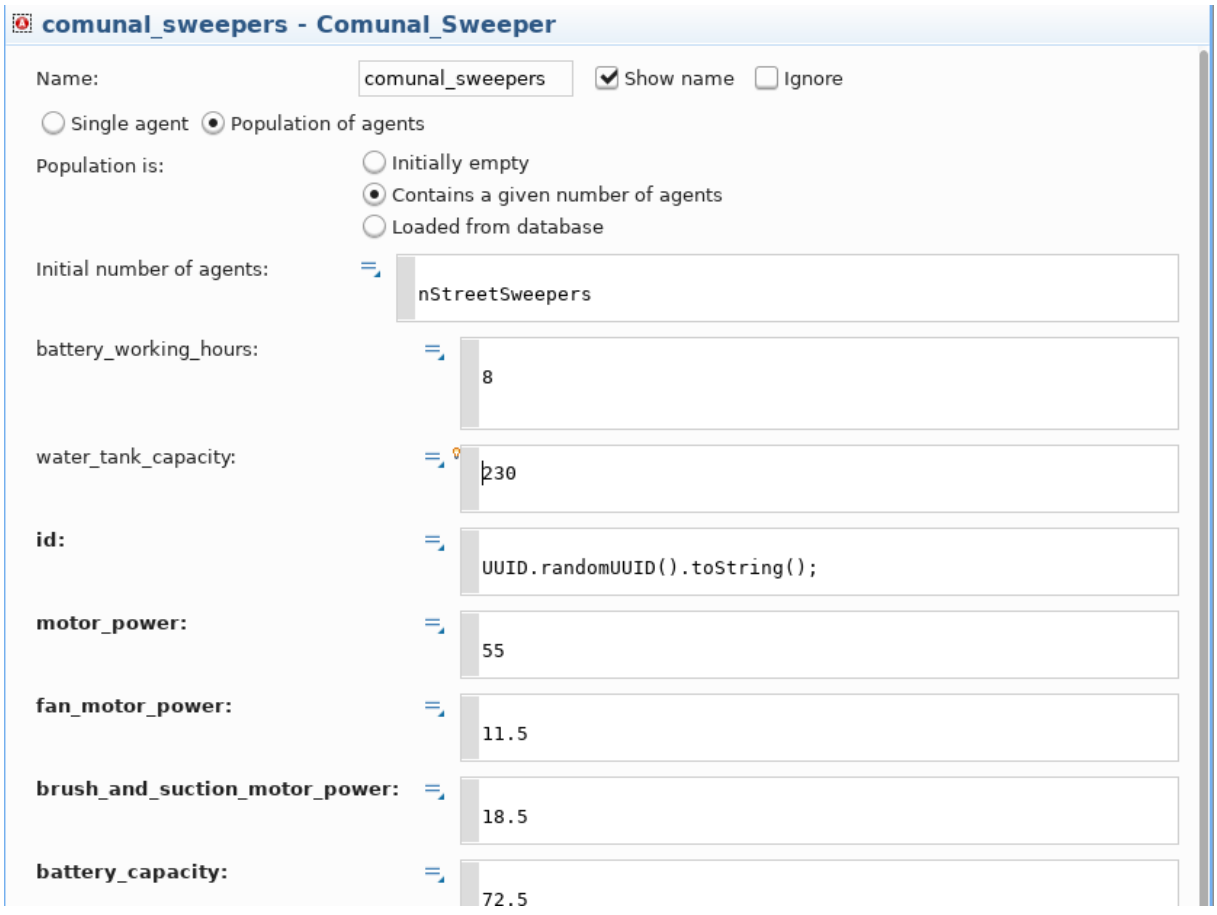

Slika 5.4: Prikaz stvaranja flote agenata električna čistilica s vrijednostima povezanim uz karakteristike električne čistilice RASCO Lynx Charge

jedan agent *Spremište vozila*. Prikaz inicijalizacije agenta *Spremište vozila* u agentu *Main* dan je na slici 5.5 pod *a* gdje je vidljivo da se upotrebljava samo jedan agent *Spremište vozila* čija je geolokacija definirana sa statičkom geotočkom *depo_location* na karti koja odgovara sjedištu komunalne službe grada Splita. Na slici 5.5 pod *b* prikazana je inicijalizacija agenta *Spremište vozila* na početku simulacije gdje se dodjeljuje flota električnih vozila u obliku agenata *Električna čistilica* koja će biti korištena za obavljanje zadataka.

Na slici 5.1 pod *b* prikazan je rezultat statičkog definiranja agenata u agentu *Main*. Osim

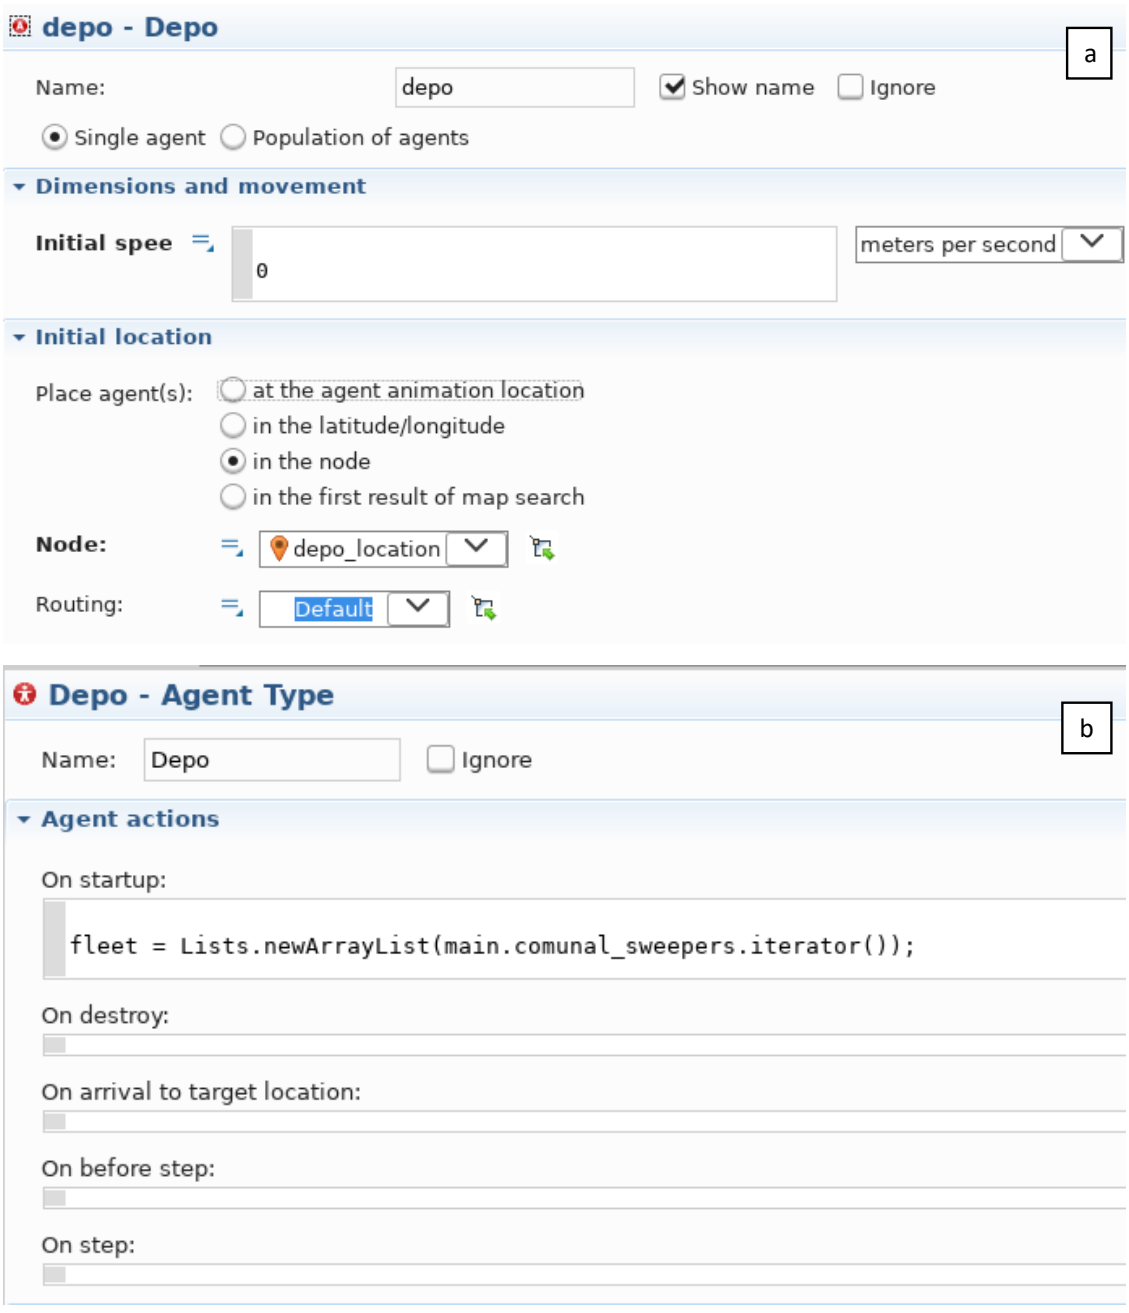

Slika 5.5: Prikaz implementacije agenta *Spremište vozila*: a) inicijalizacija u agentu *Main*; b) inicijalizacija na početku simulacije

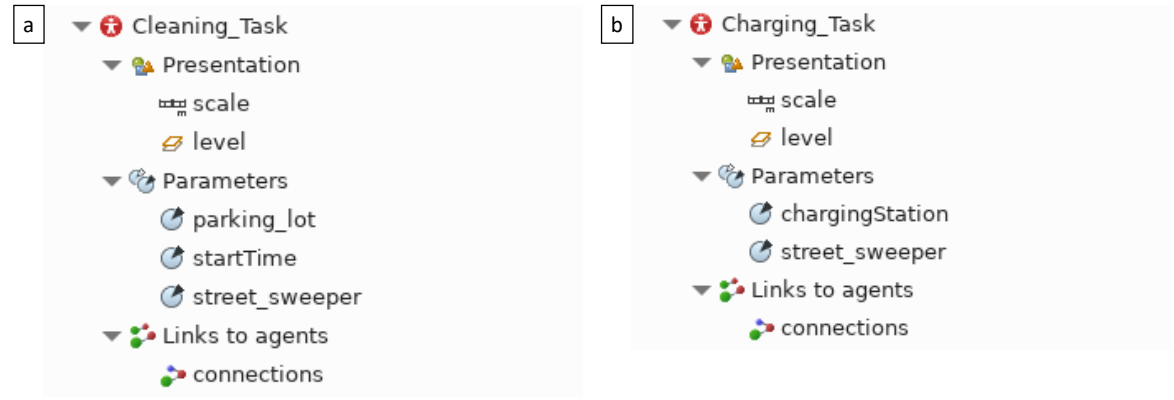

Slika 5.6: Prikaz definicije agenata: a) agent *Zadatak za čišćenje* b) agent *Zadatak za punjenje*

statičke inicijalizacije agenata u agentu *Main*, *AnyLogic* podržava i dinamičko stvaranje agenata tijekom izvođenja simulacije. Primjer takvih agenata jesu agenti povezani sa zadacima za čišćenje i punjenje na električnim punionicama koji predstavljaju ulaze u procese za obradu diskretnih događaja. Modeliranje diskretnih događaja u alatu *AnyLogic* zahtijeva da ulaz u proces bude agent. Prema tome zadaci za čišćenje i punjenje na električnim punionicama definirani su kao tipovi agenta *Cleaning Task* i *Charging Task* prikazani na slici 5.1 pod *a*. Definicija agenta *Cleaning Task* prikazana je na slici 5.6 pod *a* i sastoji se od dviju statičkih varijabli, pri čemu varijabla *parking lot* definira parkiralište koje se mora očistiti, dok varijabla *street sweeper* definira čistilicu koja će taj zadatak obaviti. Agent *Charging Task* prikazan je na slici 5.6 pod *b* i definiran je dvjema statičkim varijablama, pri čemu varijabla *street sweeper* definira električnu čistilicu koja izvršava zadatak punjenja na električnoj punionici koja je definirana varijablom *charging station*. Pomoću agenata *Cleaning Task* i *Charging Task* model VAS-UEV definira razmjenu zadataka za čišćenje i punjenje između pokretnih i stacionarnih agenata unutar kojih su sadržane sve potrebne informacije te njihovo stvaranje rade drugi agenti, pri čemu agenta *Cleaning Task* stvara agent *Spremište vozila*, dok agenta *Charging Task* stvara agent *Električna čistilica*.

5.1.2Implementacija procesa

Za ostvarivanje modela VAS-UEV potrebno je implementirati procese vezane uz punjenje električne čistilice na električnim punionicama, proces za izvršavanje zadataka, proces za upravljanje flotom i procese zauzeća parkirališnih mjesta i električnih punionica. Osim navedenih procesa, potrebno je implementirati funkcije potrošnje baterije uzrokovane radom i kretanjem električne čistilice, funkcije pražnjenja i punjenja vodenog spremnika, funkcije stvaranja i dodjele zadataka za čišćenje parkirališnih površina i funkcije dodjele električne punionice električnim čistilicama.

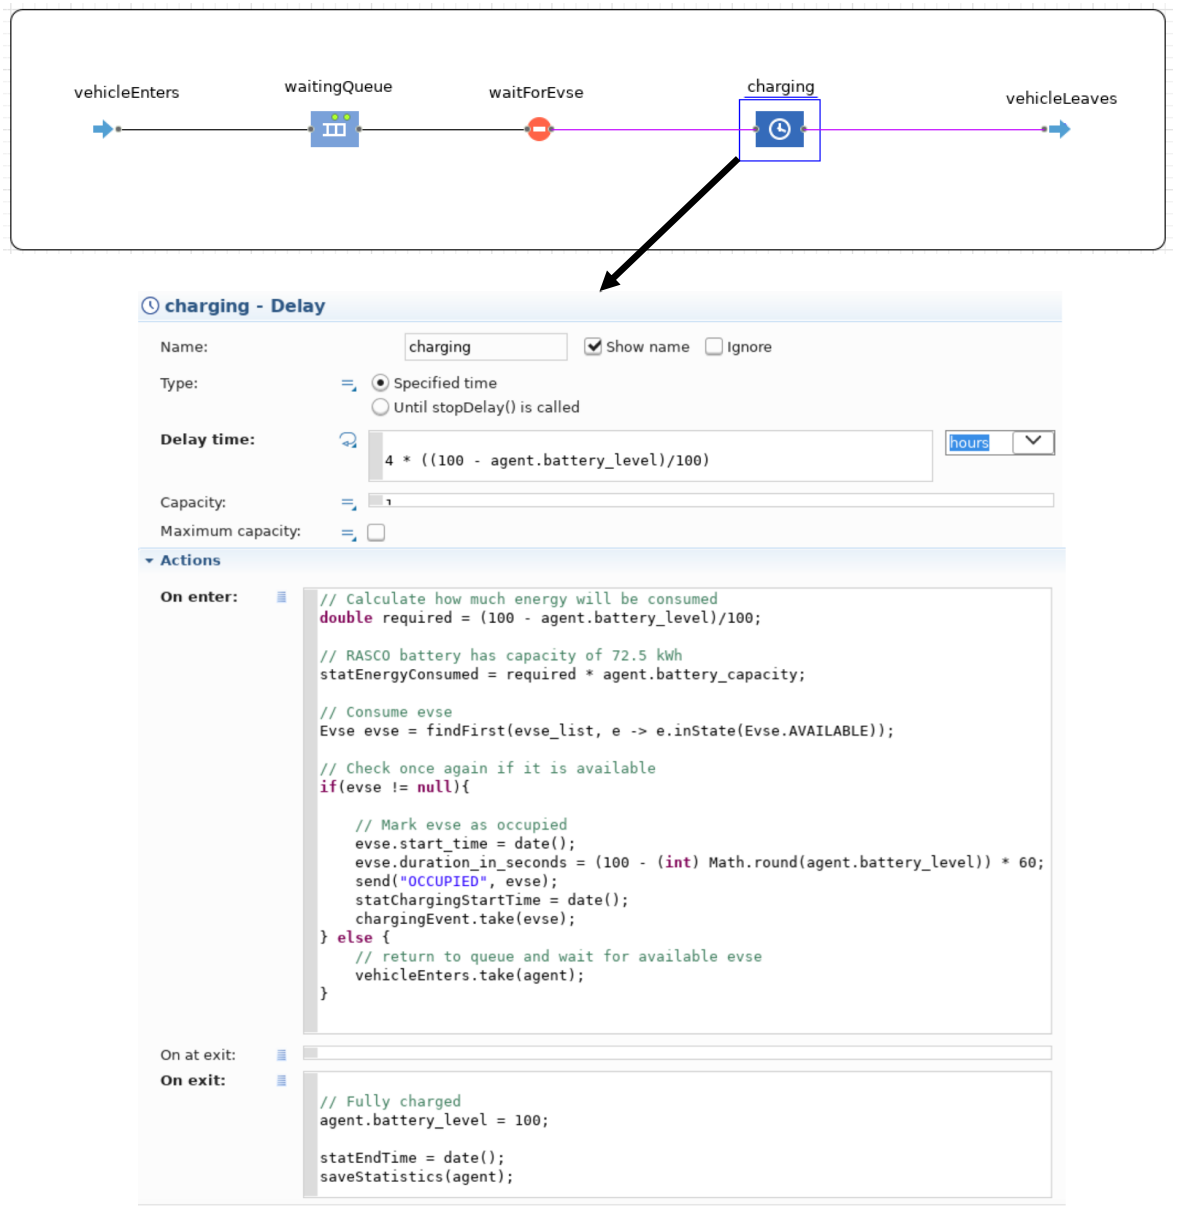

Slika 5.7: Prikaz implementacije procesa punjenja električne čistilice na električnoj punionici

Procesi u modelu VAS-UEV definirani su u poglavlju 3 i vezani su uz obradu diskretnih događaja. Proces punjenja električne čistilice na električnoj punionici prima na ulaz agenta *Električna čistilica* koji se dolaskom do agenta *Električna punionica* stavlja u red čekanja za prvi slobodan priključak za punjenje. U trenutku kad postoji priključak za punjenje koji je slobodan, pokreće se proces punjenja koji mora imati implementiranu funkciju punjenja baterije električnog vozila. Na slici 5.7 prikazana je funkcija punjenja električne čistilice unutar procesa. Trajanje procesa određeno je unutar bloka *Delay time* i izračunava se tako da se razina baterije iskazana u postocima pomnoži s brojem sati potrebnih da se čistilica *RASCO Lynx Charge* napuni od 0% do 100%. Specifikacija *RASCO Lynx Charge* čistilice definira četiri sata za punjenje potpuno prazne baterije do punog kapaciteta.

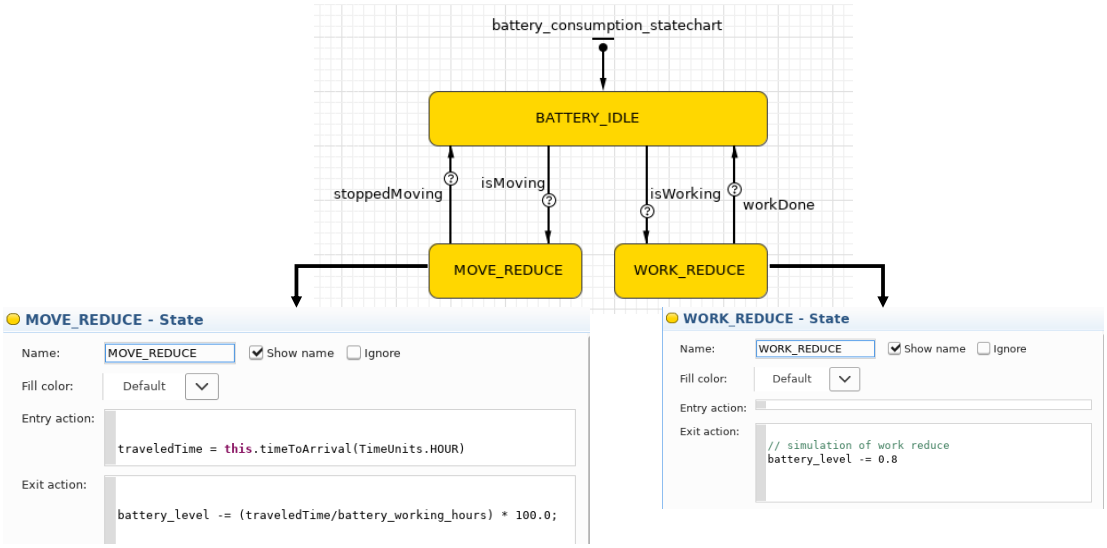

Slika 5.8: Prikaz procesa pražnjenja baterije električne čistilice

Dijagrami stanja vezani uz rad baterije definiraju potrošnju baterije na temelju kretanja i rada električne čistilice. Potrebno je definirati funkciju koja će u trenutku prelaska baterije iz stanja *BATERY IDLE* u stanje *MOVE REDUCE* smanjiti razinu baterije u stanju *MOVE REDUCE*. Funkcija za smanjivanje razine baterije na temelju kretanja električne čistilice prvo izračunava potrošeno vrijeme na kretanje te oduzima od definiranog maksimalnog operativnog vremena koje čistilica *RASCO Lynx Charge* može ostvariti i koje je specifikacijom čistilice postavljeno na osam sati. Funkcija za smanjivanje razine baterije na temelju rada čišćenja parkirališnih površina postavljena je fiksna vrijednost od 0,80% razine baterije u svrhu simulacije. Funkcije vezane uz pražnjenje baterije prikazane su na slici 5.8. Električna čistilica za čišćenje koristi se vodenim spremnikom koji se prazni prilikom čišćenja parkirališnih površina. Rad vodenog spremnika definiran je dijagramom stanja koji se prelaskom iz stanja *WATER TANK IDLE* u stanje *REDUCE WATER LEVEL* koristi funkcijom smanjivanja razine vode u spremniku. Funkcija je prikazana na slici 5.9 i za potrebe simulacije definirano je da se po parkirališnom mjestu potroši pet litara vode.

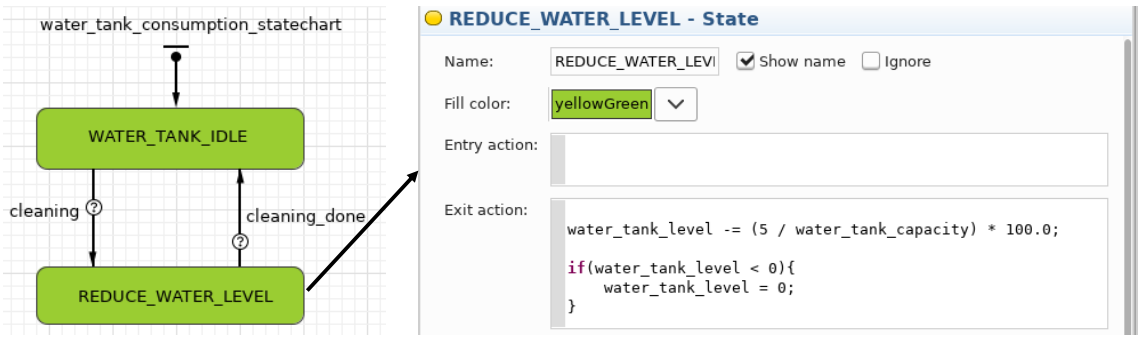

Slika 5.9: Prikaz implementacije funkcije pražnjenja vodenog spremnika električne čistilice

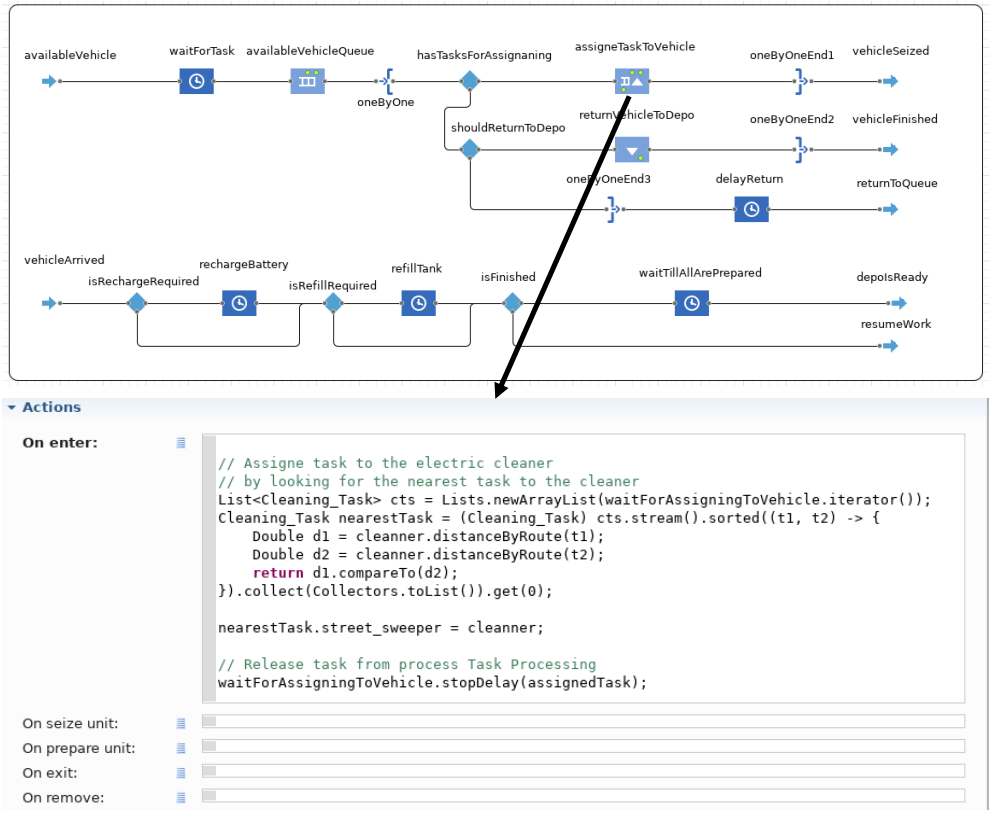

Slika 5.10: Prikaz implementacije funkcije dodjele zadatka električnoj čistilici koja se koristi osnovnim algoritmom

Agent *spremište vozila* implementira proces za obradu zadataka i proces za upravljanje flotom električnih čistilica. Proces upravljanja flotom električnih čistilica koristi se funkcijom dodjele zadatka za čišćenje električnoj čistilici koji predstavlja implementaciju algoritma usmjeravanja prema parkiralištu u fazi izvršavanja. Prikaz funkcije koja se koristi osnovnim algoritmom iz poglavlja 4.2 predstavljen je na slici 5.10 gdje se može vidjeti da se dodjeljuje zadatak onoj čistilici koja je najbliža lokaciji parkirališta definiranog u zadatku za čišćenje. Drugi proces agenta *Spremište vozila* definiran je za upravljanje obradom zadataka. Proces se ne koristi nikakvim dodatnim funkcijama prilikom svog izvršavanja, već su dovoljne definicije elemenata procesa definirane paketom alata *AnyLogic* za modeliranje diskretnih događaja.

Agent *Spremište vozila* koristi se funkcijom za stvaranje zadataka za čišćenje koji predstavljaju algoritam za usmjeravanje prema parkiralištu u fazi planiranja, pri čemu se određuje funkcija za stvaranje zadataka koja može odgovarati definiciji algoritma određenog u poglavlju 4.2.1 ili algoritmu zasnovanog na AI-u definiranog u poglavlju 4.3. Funkcija za stvaranje zadataka s osnovnim algoritmom prikazana je na slici 5.11 i stvara svaki zadatak s istim početkom izvršavanja koje je jednako početku operativnoga radnog vremena komunalnih službi grada Splita u 6 sati ujutro. Funkcija za stvaranje zadataka s algoritmom zasnovanim na AI-u prikazana na slici 5.11 i za određivanje početka izvršavanja zadatka koristi se modelom umjetne

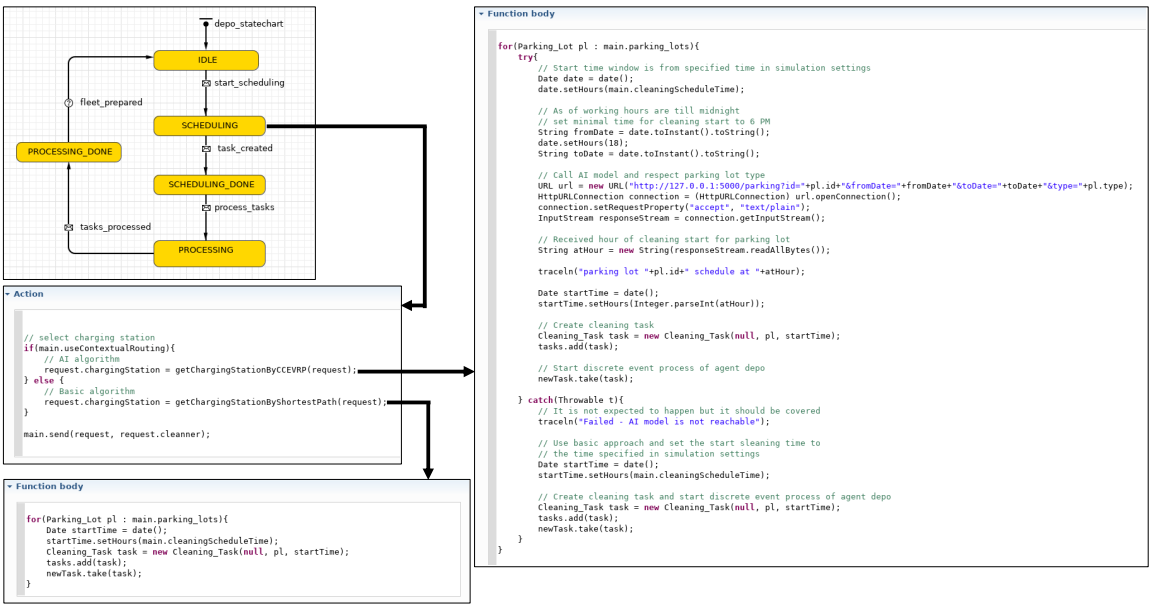

Slika 5.11: Prikaz implementacije funkcije stvaranja zadataka za čišćenje

inteligencije pri čemu ovisno o tipu parkirališta obavlja poziv prema modelu iskoristivosti za ulična ili vanulična parkirališta. Funkcija za stvaranje zadataka prikazana na slici 5.11 izvršava se prelaskom agenta *spremište vozila* u stanje *SCHEDULING* u kojem se ovisno o postavljenom parametru simulacije *use contextual routing* koristi osnovnim algoritmom ili algoritmom zasnovanom na AI-u za stvaranje zadataka. Ciklus za stvaranje zadataka za čišćenje definiran je u agentu *Main* koji se koristi elementom višeagentskog modeliranja alata *AnyLogic* pod nazivom planer (eng. *Scheduler*) kojim se definira cikličko izvršavanje stvaranje zadataka u agentu *Spremište vozila*. Implementacija elementa *Scheduler* prikazan je na slici 5.12 te jasno određuje izvršavanje stvaranja zadataka svaki dan u 1 sat ujutro.

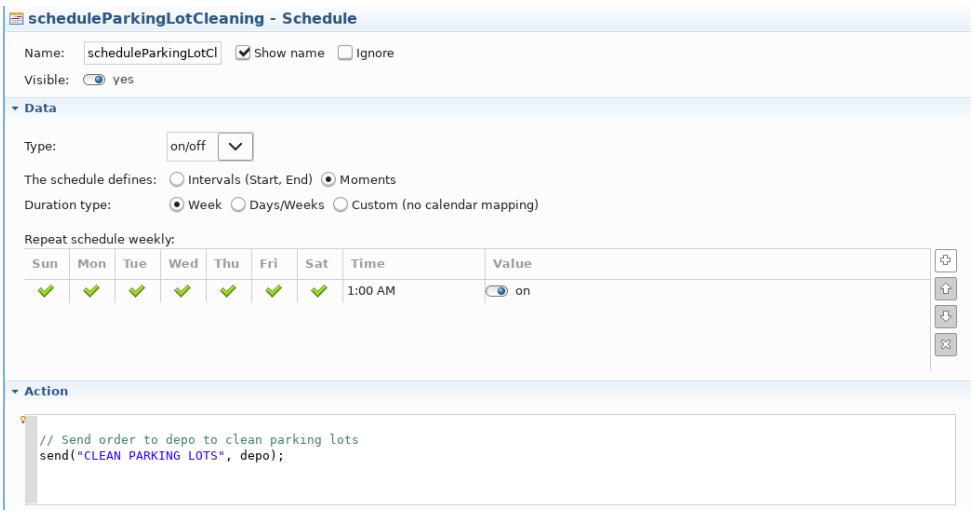

Slika 5.12: Prikaz implementacije planera za pokretanje stvaranja zadataka za čišćenje u agentu *Spremište vozila*

Agent *Spremište vozila* implementira funkciju dodjele električne punionice agentu *Električna čistilica* koja je definirana algoritmom za usmjeravanje prema električnoj punionici prikazanog u poglavlju 4.2 za osnovni pristup i u poglavlju 4.3 za pristup zasnovan na AI-u. Agent *Spremište vozila* po primitku poruke agenta *Električna čistilica* u obliku zadatka za punjenje poziva funkciju za dodjelu električne punionice. Ovisno o parametru *use contextual routing* u postavkama simulacije, funkcija se koristi osnovnim algoritmom ili algoritmom zasnovanom na AI-u. Osnovni algoritam usmjerava električnu čistilicu prema najbližoj električnoj punionici, dok funkcija definirana algoritmom zasnovanim na AI-u šalje zahtjev prema modelu iskoristivosti električne punionice za predviđanje iskoristivosti svih električnih punionica u gradu Splitu za sljedećih sat vremena. Odabire se električna punionica koja je najbliža električnoj čistilici s najmanjom mjerom iskoristivosti. Prikaz funkcije za dodjelu električne punionice za osnovni algoritam i algoritam zasnovan na AI-u prikazan je na slici 5.13.

Za potrebe provođenja simulacije potrebno je modelirati zauzeće parkirališta i električnih punionica. Zauzeće parkirališta definirano je funkcijama prikazanim na slici 5.1 pod g. Baza podataka alata *AnyLogic* sadrži zapise o popunjenosti pojedinog parkirališnog mjesta od 1. siječnja 2021. godine do 1. srpnja 2021. godine. Vremenski raspon podataka ovisi o definiciji trajanja simulacije i potrebno je osigurati podatke o korištenju parkirališta za definirano vrijeme trajanja simulacije. Funkcija korištenja parkirališta provjerava svaku minutu postoje li zapisi u bazi podataka o popunjenosti pojedinog parkirališnog mjesta. Ako postoji zapis korištenja za određeno parkirališno mjesto, onda se agent *Parkirališno mjesto* prosljeđuje na ulaz procesa korištenja parkirališnih mjesta agenta *Parkiralište* kojem to mjesto pripada označava-

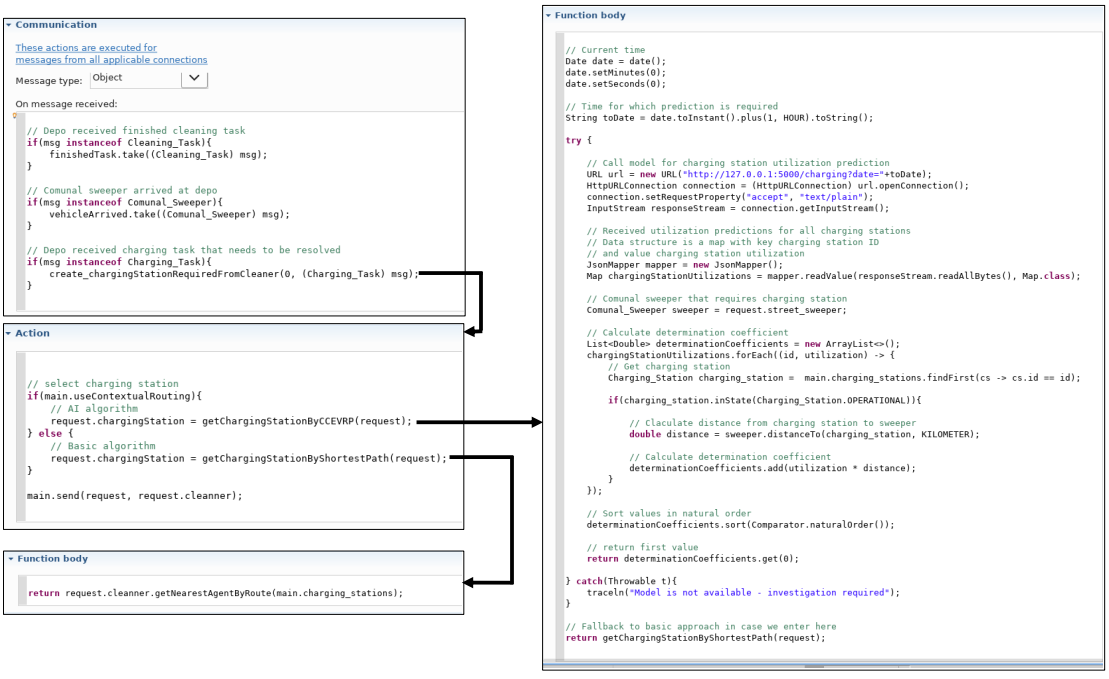

Slika 5.13: Prikaz implementacije procesa dodjele električne punionice u agentu *Spremište vozila*

jući pritom događaj popunjenosti parkirališnog mjesta kao diskretan događaj. Upravo zbog toga parkirališno mjesto mora biti ostvareno u obliku agenta *Parkirališno mjesto* koje se po dolasku u proces korištenja parkirališnih mjesta postavlja u stanje *PARKING EVENT*. Po ostvarivanju vremena početka korištenja parkirališta, agent *Parkirališno mjesto* prelazi u stanje *OCCUPIED* i time se označava da je mjesto zauzeto. Agent *Parkirališno mjesto* sadrži informacije od kad do kad zauzeće mjesta traje te po prestanku zauzeća mjesta, proces korištenja parkirališnog mjesta postavlja agenta *Parkirališno mjesto* natrag u stanje *FREE*.

Modeliranje zauzeća električnih punionica ostvareno je funkcijama korištenja električnih punionica prikazanih na slici 5.1 pod *h*. Za svaku električnu punionicu prikupljeni su podaci o korištenju priključaka koje punionica sadrži za period trajanja simulacije. Funkcija korištenja električnih punionica svake minute provjerava u bazi podataka postoje li zapisi za korištenje pojedinog priključka električne punionice te ako postoji, prosljeđuje agenta *Evse* na ulaz procesa zauzeća priključka agenta *Električna punionica* kojem taj priključak pripada. Proces zauzeća priključka obrađuje diskretne događaje i time se priključak mora ostvariti u obliku agenta *Evse*. Agent *Evse* sadrži informacije o vremenu početka i kraja zauzeća te se po ulasku u proces zauzeća priključka postavlja u stanje *OCCUPIED*, a po ostvarivanju vremena početka prelazi u stanje *IN USE*. Ovime priključak više nije dostupan niti jednom agentu *Električna čistilica*. Po završetku zauzeća, koje označava prestanak punjenja električnog vozila na priključku, agent *Evse* prelazi u stanje *AVAILABLE*.

5.1.3Implementacija prezentacijskog sloja

Za ostvarivanje simulacije u alatu *AnyLogic* potrebno je definirati prezentacijski sloj koji je vidljiv korisniku simulacije. Prezentacijski sloj može biti definiran na više načina u alatu *AnyLogic* i ovisi o tipu simulacije. Platforma za simulaciju transportnog sustava provodi usmjeravanje električnih vozila u prostoru ostvarenog u obliku geografske karte. Geografska karta u alatu *AnyLogic* ostvarena je pomoću karte *Open Street Map*[‡] te omogućuje usmjeravanje električnih vozila između dviju geolokacija po principu najkraće rute ili najbrže rute. Platforma za simulaciju transportnog sustava koristi se kartom za grad Split unutar kojeg je potrebno usmjeravati električne čistilice u svrhu čišćenja parkirališnih površina. Karta je prikazana na slici 5.14 u koju se mogu dodati definirani agenti modela VAS-UEV, specificirajući pritom geolokaciju agenta s geografskom širinom i dužinom. Agenti *Električna čistilica*, *Spremište vozila*, *Električna punionica* i *Parkiralište* modela VAS-UEV dodani su na kartu.

Glavni prezentacijski sloj alata *AnyLogic* ostvaruje se agentom *Main* koji uključuje prezentacijske slojeve ostalih agenata. Svaki agent u alatu *AnyLogic* definira svoj prezentacijski sloj pomoću slike, određenog 2D- ili 3D-oblika, ili se uopće ne koristi nikakvim prezentacijskim slojem. Agenti *Električna čistilica*, *Električna punionica*, *Parkiralište* i *Parkirališno mjesto*

[‡]Karta "Open Street Map" - https://www.openstreetmap.org

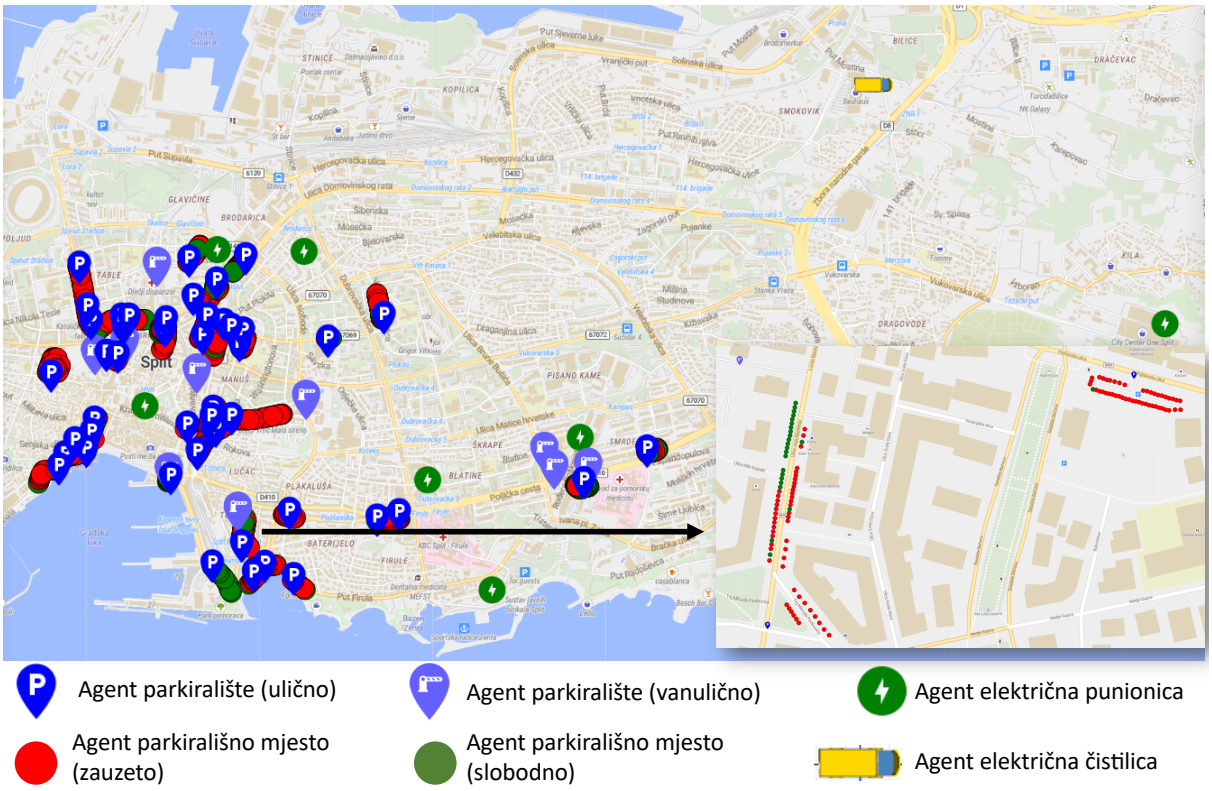

Slika 5.14: Prikaz prezentacijskog sloja platforme za simulaciju transportnog sustava flote električnih vozila

koriste se prezentacijskim slojem koji je prikazan na slici 5.14. Ostali agenti platforme za simulaciju ne koriste se nikakvim prezentacijskim slojem i nisu vidljivi tijekom simulacije. Primjer takvih agenata jesu agent *Zadatak za čišćenje* i agent *Zadatak za punjenje*.

5.1.4Baza podataka

Baza podataka platforme za simulaciju transportnog sustava flote električnih vozila prikazana je na slici 5.15. Sastoji se od tablica predviđenih za podatke o parkiralištima, električnim punionicama, pohrani statistike provođenja simulacije i tablica potrebnih za provođenje optimizacije broja vozila u floti. Tablica *parking lots* sadrži informacije potrebne za stvaranje agenta *Parkiralište*, pri čemu polje *parking type* definira tip parkirališta koje može biti ulično ili vanulično. Svako parkiralište sastoji se od parkirališnih mjesta koja se moraju ostvariti u obliku agenta. Za stvaranje agenata *Parkirališno mjesto* upotrebljava se tablica *parking space*. Funkcija korištenja parkirališta modelira zauzeće parkirališnih mjesta tako da provjerava u tablici *parking space occupation data* postoji li zapis korištenja parkirališnog mjesta za određeno vrijeme. U početku pokretanja simulacije potrebno je napraviti inicijalizaciju zauzeća parkirališnih mjesta pomoću tablice *parking space initial occupation data* koja sadrži zapise zauzeća parkirališnih mjesta koja su zauzeta u trenutku koji je definiran kao početak simulacije.

Slika 5.15: Prikaz dijagrama relacija baze podataka korištene u platformi za simulaciju transportnog sustava flote električnih vozila

Za stvaranje agenata *Električna punionica* upotrebljava se tablica *charging stations* koja sadrži sve potrebe informacije o električnim punionicama operatora Hrvatski Telekom u Hrvatskoj. Svaka električna punionica sastoji se od nekoliko priključaka pomoću kojih se omogućuje punjenje električnih vozila. Svaki priključak ostvaruje se u obliku agenta te se za stvaranje agenata *Evse* koristi tablicom *evse*. Funkcija korištenja priključka električnih punionica modelira zauzeće priključaka tako da provjerava u tablici *evse occupation data* postojanje zapisa o punjenju električnog vozila na određenom priključku za određeno vrijeme.

Rezultati provođenja simulacije pohranjuju se u tablice za statistiku. Tablica *results cleaning* predstavlja statističke podatke o izvršavanju pojedinih ciklusa čišćenja. Ciklus čišćenja počinje stvaranjem svih zadataka za čišćenje parkirališta i završava kad električne čistilice izvrše sve stvorene zadatke. Polje *simulation* u tablici *results cleaning* predstavlja tip simulacije za koju se

pohranjuju statistički podaci. Polje *cleaning utilization* predstavlja mjeru uspješnosti čišćenja prikazanu u poglavlju 5.3. Tablica *results charging* predstavlja statističke podatke električnih čistilica vezane uz korištenje električnih punionica. Svaki zapis predstavlja trajanje punjenja na električnoj punionici koje započinje dolaskom električne čistilice na električnu punionicu i završava odlaskom električne čistilice s punionice. Polje *charging utilization* u tablici *results charging* predstavlja mjeru uspješnosti korištenja električnih punionica prikazanu u poglavlju 5.3.

Tablice *parking lot avg occupation* i *parking lot model occupation* koriste se u platformi za simulaciju transportnog sustava flote električnih vozila u modulu optimizacije veličine floti. Modul optimizacije veličine flote definira tri scenarija provođenja optimizacije, pri čemu se scenarij koji se temelji na korištenju stvarnih podataka o korištenju parkirališta koristi tablicom *parking lot avg occupation*, gdje je za svako parkiralište izračunata prosječna vrijednost popunjenosti. Za scenarij koji se temelji na korištenju modela iskoristivosti uličnih i vanuličnih parkirališta, modul optimizacije veličine flote koristi se tablicom *parking lot model occupation* koja za svako parkiralište sadrži zapis o prosječnoj iskoristivosti parkirališta.

5.1.5Postavke simulacije

Platforma za simulaciju definirana je parametrima kojima se određuje izvršavanje simulacije. Na slici 5.16 prikazane su postavke za provođenje simulacije grupiranih u četiri dijela. Prvi dio postavki simulacije definira ime simulacije, agenta najviše razine i najviše dozvoljene radne memorije koja se može koristiti za izvođenje simulacije. Platforma za simulaciju transportnog sustava flote električnih vozila može koristiti do 4.096 Mb radne memorije prilikom izvođenja simulacije.

Drugi dio postavki simulacije vezani su uz parametre simulacije koji su definirani u agentu najviše razine prikazane na slici 5.1 pod *c*. Parametar *use contextual routing* definira tip algoritama iz poglavlja 4 koji se uzimaju u obzir, pri čemu ako je parametar označen, uzimaju se algoritmi zasnovani na AI-u, dok se u suprotnom slučaju uzimaju osnovni algoritmi. Parametrom *cleaning schedule time* definira se početak vremenskog okvira unutar kojeg se moraju izvršiti zadaci čišćenja. Parametar je proizvoljan i može se podesiti proizvoljno. Parametrom *n street sweepers* definira se broj vozila u floti koji će se koristiti u simulaciji te se postavlja proizvoljno ili se broj vozila može dobiti pomoću modula optimizacije veličine flote. Izmjena definiranih parametara može se raditi i tijekom izvršavanja simulacije pomoću vizualnog sučelja prikazanog na slici 5.1 pod *d*.

Platforma za simulaciju transportnog sustava definira modul optimizacije veličine flote parametrom *fleet optimization mode*. Ako je parametar *fleet optimization mode* odabran u postavkama simulacije, odvija se optimizacija broja vozila u floti. Ako parametar nije odabran, obavlja se simulacija transportnog sustava definiranog modelom VAS-UEV. Modul optimiza-

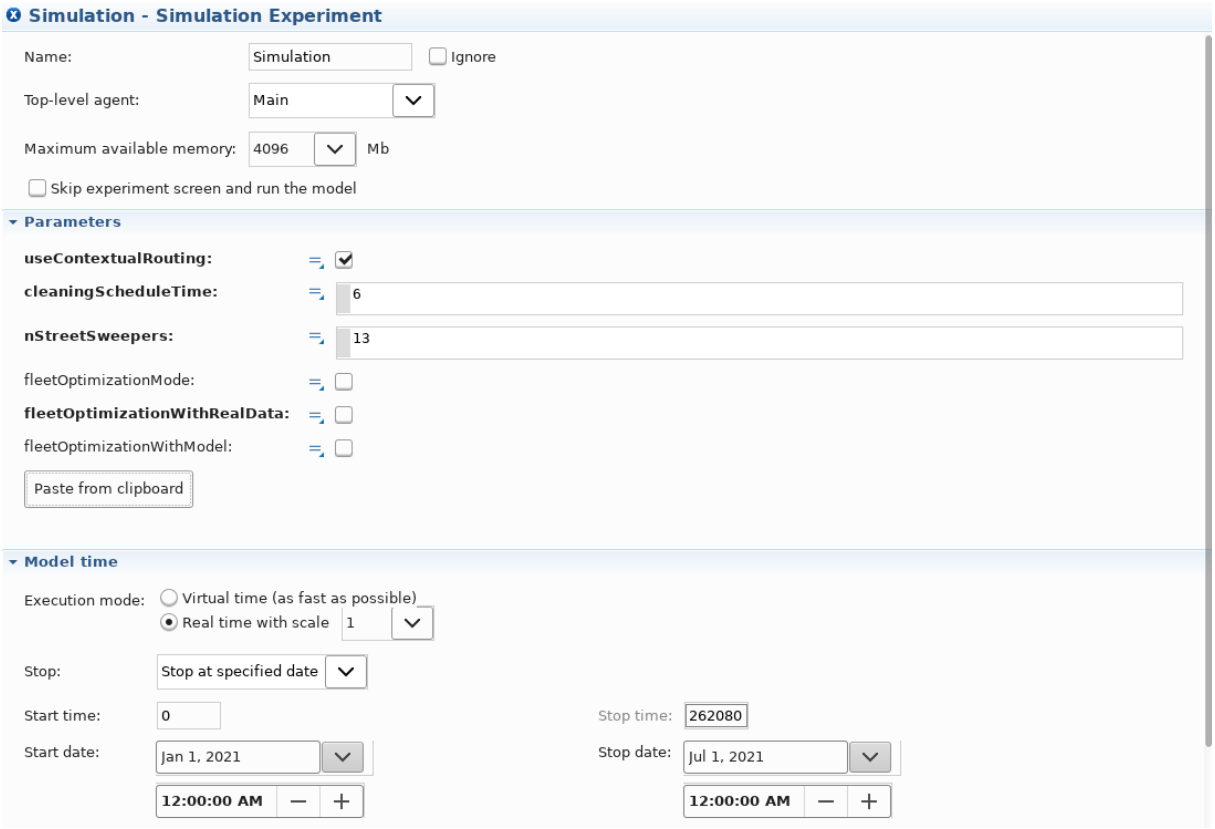

Slika 5.16: Prikaz postavki platforme za simulaciju transportnog sustava flote električnih vozila

cije veličine flote određuje se dodatnim parametrima *fleet optimization with real data* i *fleet optimization with model* prikazanih na slici 5.1 pod f. Dodatnim parametrima za optimizaciju veličine flote definira se način provođenja zauzeća parkirališnih mjesta, pri čemu se uz odabir parametra *fleet optimization with real data* upotrebljavaju stvarni povijesni podaci zauzeća parkirališta, dok se odabirom parametra *fleet optimization with model* predviđa iskoristivost svakog parkirališta modelima iskoristivosti parkirališta. Ako niti jedan parametar nije odabran, sva se parkirališta definiraju praznim prilikom optimizacije veličine flote.

Treći dio postavki simulacije odnosi se na definiranje trajanja simulacije i brzina izvođenja simulacije. Vrijeme trajanja simulacije je šest mjeseci te počinje od ponoći 1. siječnja 2021. godine do ponoći 1. srpnja 2021. godine. Ovaj je period odabran jer su svi modeli iskoristivosti učeni nad povijesnim podacima do 2021. godine. Brzina izvođenja simulacije može se postaviti na virtualno najbržu moguću brzinu ili se može odabrati skaliranje vremenskih jedinica simulacije tako da na primjer ako se odabere brzina 6, onda to označava da će se šest vremenskih jedinica modela izvršiti unutar jedne sekunde.

5.2Funkcijska analiza ostvarene platforme

Funkcijska analiza platforme za simulaciju transportnog sustava flote električnih vozila uključuje analizu provođenja simulacije modela *višeagentskog sustava za usmjeravanje električnih vozila (VAS-UEV)* definiranog u poglavlju 3 korištenjem osnovnih algoritama i algoritama zasnovanim na AI-u iz poglavlja 4. Prema tome, funkcijska analiza analizira dva tipa simulacija nad ostvarenom platformom:

- **Simulacija A** - simulacija osnovnog usmjeravanja električnih vozila;
- **Simulacija B** - simulacija kontekstnog usmjeravanja električnih vozila;

gdje se simulacija A koristi osnovnim algoritmima za usmjeravanje prema parkiralištima i električnim punionicama, dok se simulacija B koristi algoritmima zasnovanim na AI-u pri čemu se koriste modeli iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta. Model VAS-UEV definira flotu električnih vozila koja je jednaka broju električnih čistilica zaduženih za čišćenje gradskih parkirališnih površina u gradu Splitu. Prije izvršavanja simulacija pomoću algoritama za usmjeravanje električnih vozila potrebno je definirati veličinu flote. Flota vozila zadužena je za čišćenje 48 uličnih i 10 vanuličnih parkirališta u gradu Splitu. Električna čistilica punjenje baterije može obaviti na 7 električnih punionica dostupnih u gradu Splitu operatora Hrvatski Telekom. Simulacija transportnog sustava flote električnih vozila definiranog modelom VAS-UEV provodi se za vremensko razdoblje od 1. siječnja 2021. godine do 1. srpnja 2021. godine, dok su modeli iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta ostvareni s povijesnim podacima do 1. siječnja 2021. godine. Električna čistilica korištena za simulaciju jest čisitlica tvrtke RASCO pod nazivom *RASCO Lynx Charge*.

5.2.1Optimizacija veli čine flote električnih vozila

Modul optimizacije veličine flote električnih vozila platforme za simulaciju provodi optimizaciju tako da traži minimalni broj vozila u floti koji će izvršiti čišćenje svih parkirališnih površina u gradu Split unutar definiranog vremena. Definirano razdoblje počinje u 6 sati ujutro, što odgovara početku operativnog radnog vremena gradske komunalne službe i završava u ponoć do kad moraju biti očišćene sve gradske parkirališne površine. Veličina vremenskog razdoblja iznosi 18 sati. Simulacija tijekom svog rada iterativno povećava broj vozila u floti počevši s jednim vozilom. Simulacija se zaustavlja u trenutku kad se ostvari maksimalni broj vozila predviđen za simulaciju optimizacije veličine flote. Maksimalni broj predviđen za optimizaciju veličine flote jest 58 i jednak je broju parkirališta u gradu Splitu te ujedno označava broj iteracija simulacije za optimizaciju veličine flote. Platforma za simulaciju transportnog sustava za optimizaciju veličine flote u prvom koraku stvara 58 vozila u floti električnih čistilica koje se nalaze na lokaciji spremište vozila. Potom iterativno povećava korištenje broja vozila iz flote za obavljanje zadataka za čišćenje parkirališta.

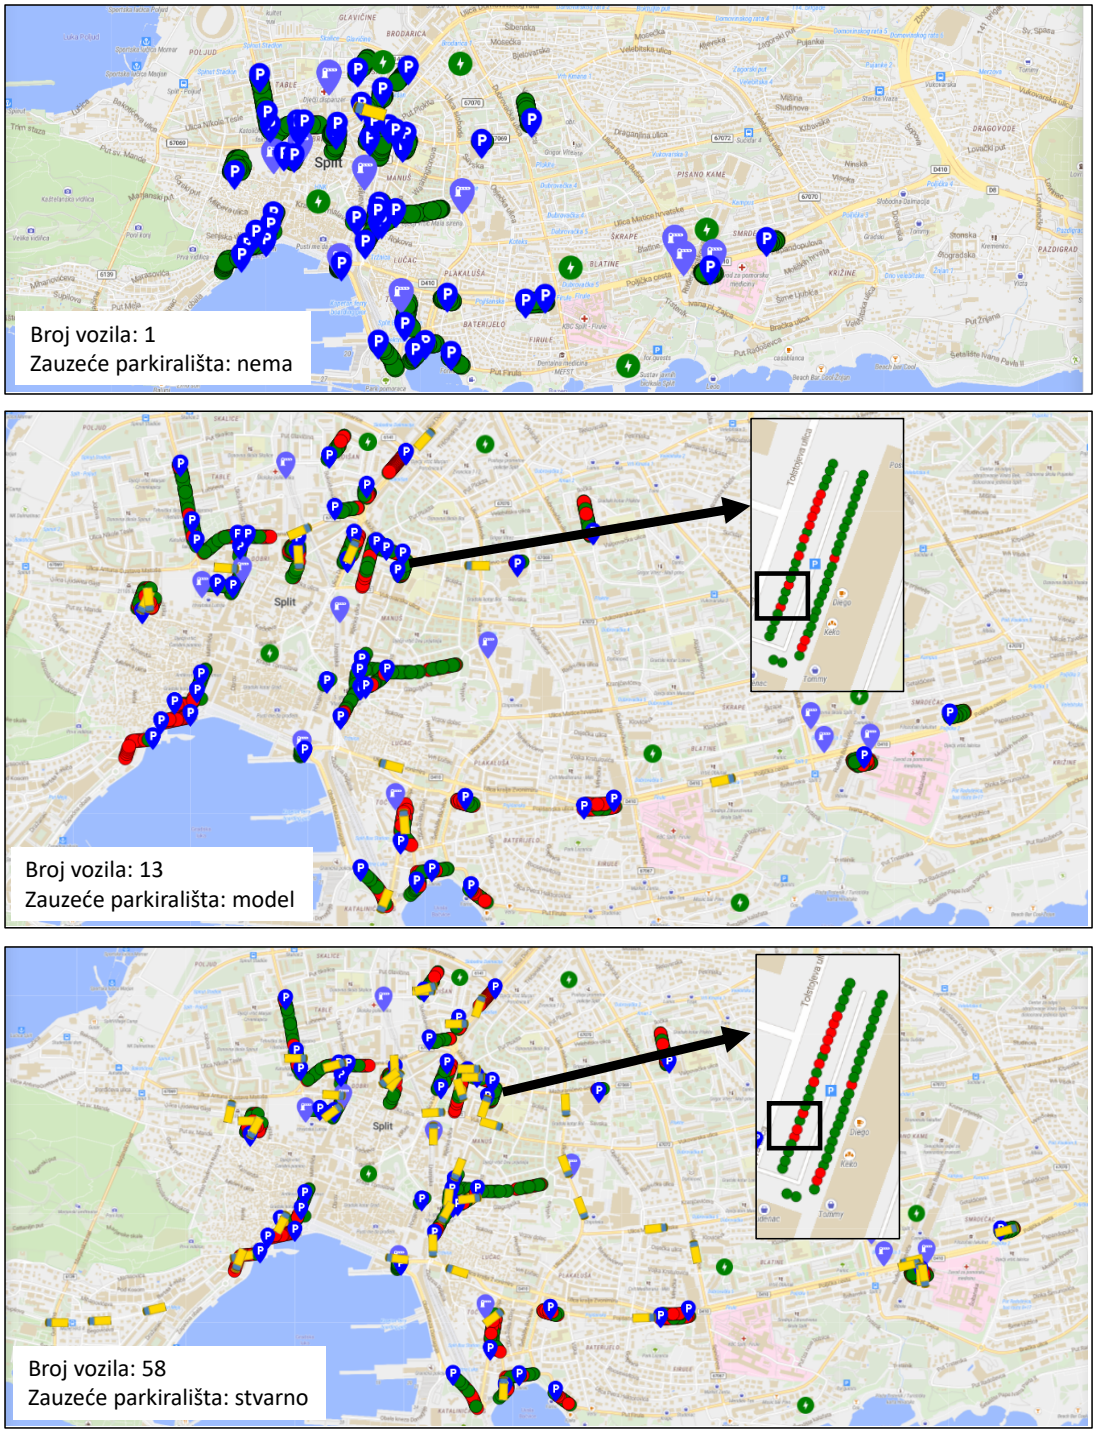

Slika 5.17: Prikaz izvršavanja simulacije optimizacije veličine flote

Osim definicije broja vozila u floti potrebno je definirati zauzeće parkirališnih mjesta tijekom simulacije optimizacije veličine flote. Platforma za simulaciju definira u postavkama parametre kojima se određuje tip zauzeća parkirališta. Odabirom parametra *fleet optimization with real data* koriste se stvarni podaci o zauzeću parkirališta, pri čemu se pomoću tablice *parking lot avg occupation data* u bazi podataka uzimaju prosječna zauzeća svakog parkirališta. Ako

je odabran parametar *fleet optimization with model* u postavkama simulacije, onda se uzimaju prosječne vrijednosti zauzeća iz tablice *parking lot model occupation data* dobivene izračunom prosječne iskoristivosti svakog parkirališta za određeni period dobiven modelom iskoristivosti uličnih i vanuličnih parkirališta. Ako nije odabran niti jedan parametar, onda se ne definira nikakvo zauzeće parkirališta i sva su parkirališna mjesta slobodna. Pristupom bez zauzeća parkirališta definira se maksimalni broj potrebnih vozila u floti za čišćenje parkirališnih površina. Primjer izvođenja simulacije u modu optimizacije veličine flote prikazan je na slici 5.17. Slika prikazuje nekoliko tipova iteracija simulacije za optimizaciju veličine flote, pri čemu je za broj vozila 1 korišten pristup bez zauzeća parkirališnih mjesta. Za broj vozila 13 korišten je pristup zauzeća parkirališnih mjesta na temelju prosječne vrijednosti zauzeća parkirališta dobivene modelom iskoristivosti, dok je za broj vozila 58 korišteno zauzeće parkirališta na temelju prosječne vrijednosti stvarne popunjenosti parkirališta. Na slici 5.17 može se vidjeti da je razlika u popunjenosti između modela i stvarnih vrijednosti vrlo mala, pri čemu je za dani primjer razlika točno u jednome mjestu.

Rezultati simulacije optimizacije veličine flote prikazani su na slici 5.18. Za pristup optimizacije flote bez zauzeća parkirališta potrebno je 25 vozila u floti. Ovaj broj vozila ujedno predstavlja maksimalnu veličinu flote za čišćenje gradskih parkirališnih površina u gradu Splitu. Pristup optimizacije veličine flote s prosječnim zauzećem parkirališta dobivenu nad stvarnim podacima definira 13 vozila jednako kao i pristup koji se koristi prosječnom popunjenošću parkirališta dobivenu prema podacima modela iskoristivosti. No na slici 5.18 može se vidjeti da za razdoblje od 24 sata, pristup s prosječnom zauzetošću parkirališta nad stvarnim podacima definira veličinu flote od 13 vozila, dok pristup s prosječnim zauzećem dobivenu modelom iskoristivosti definira veličinu flote od 12 vozila, čime se dobiva preciznija definicija veličine flote

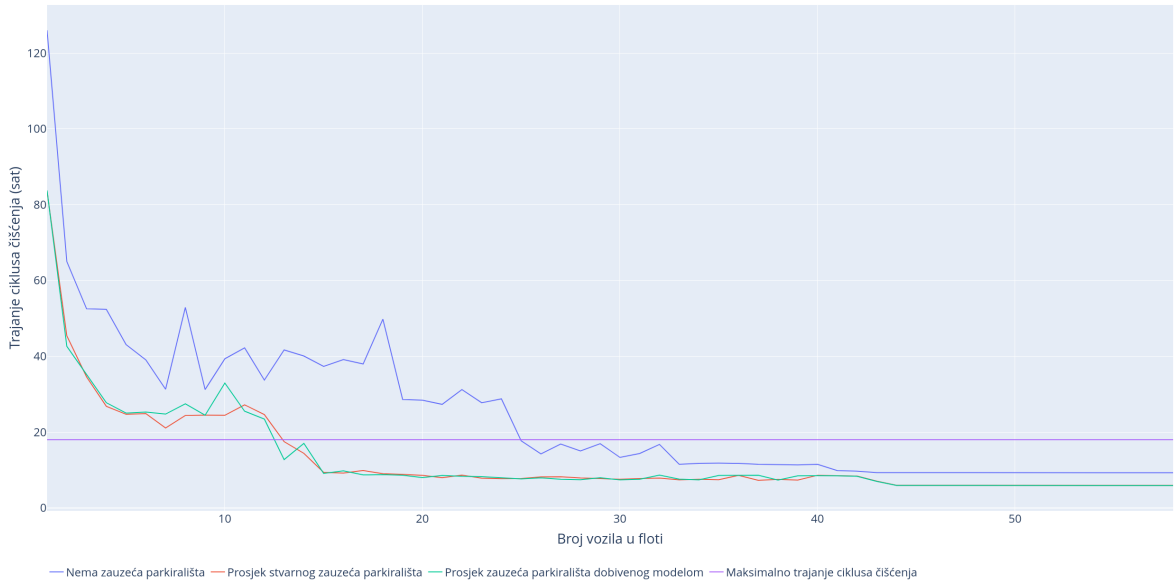

Slika 5.18: Prikaz rezultata optimizacije veličine flote

te ujedno ostvaruje uštedu u resursima potrebnim za provođenje čišćenja gradskih parkirališnih površina.

5.2.2Simulacija osnovnog usmjeravanja elektri čnih vozila

Prva simulacija u platformi za simulaciju transportnog sustava flote električnih vozila provodi se nad modelom VAS-UEV koji se koristi osnovnim algoritmima definiranim u poglavlju 4.2. Pokretanjem simulacije prvi je korak stvaranje zadataka za čišćenje u agentu *Spremište vozila*. Agent *Spremište vozila* prelaskom u stanje *SCHEDULING* stvara zadatke za čišćenje i prosljeđuje ih na ulaz procesa za obradu zadataka. Po završetku stvaranja zadataka za čišćenje, agent *Spremište vozila* prelazi u stanje *SCHEDULING DONE*. Prikaz stanja agenta *Spremište vozila* i procesa za obradu zadataka prikazan je na slici 5.19. Na slici 5.19 može se vidjeti da svaki zadatak za čišćenje ima jednako vrijeme za početak izvršavanja. Razlika je u vremenu početka izvršavanja zadataka nekoliko milisekundi, što je posljedica sekvencijske obrade zadataka u procesu za obradu zadataka, što uzrokuje različiti početak odbrojavanja broja milisekundi do početka izvršavanja. Definiranje broja milisekundi do početka izvršavanja zahtijeva blok korišten za simulaciju čekanja.

Po početku izvršavanja zadataka za čišćenje, agent *Spremište vozila* prelazi u stanje *PROCESSING* i započinje dodjela zadataka za čišćenje agentima *Električna čistilica* u procesu za upravljanje flotom vozila. Nakon što se zadacima za čišćenje dodijele električne čistilice, zadaci se prosljeđuju agentima *Električna čistilica* na izvršavanje. Prikaz stanja procesa za obradu zadataka i procesa za upravljanje flotom nakon dodjele prvih 10 zadataka za čišćenje električnim čistilicama prikazan je na slici 5.20.

Agent *Električna čistilica* kreće s izvršavanjem dodijeljenog zadatka i prelazi u stanje *EXECUTING ASSIGNED TASK*. Izvršavanje zadataka za čišćenje agenata *Električna čistilica* prikazan je na slici 5.21 pod *a*, gdje se može vidjeti da električna čistilica ide od parkirališnog mjesta do parkirališnog mjesta uzimajući u obzir da je parkirališno mjesto slobodno. Slika 5.21 pod *b* prikazuje da kretanje agenta *Električna čistilica* uzrokuje potrošnju baterije na temelju

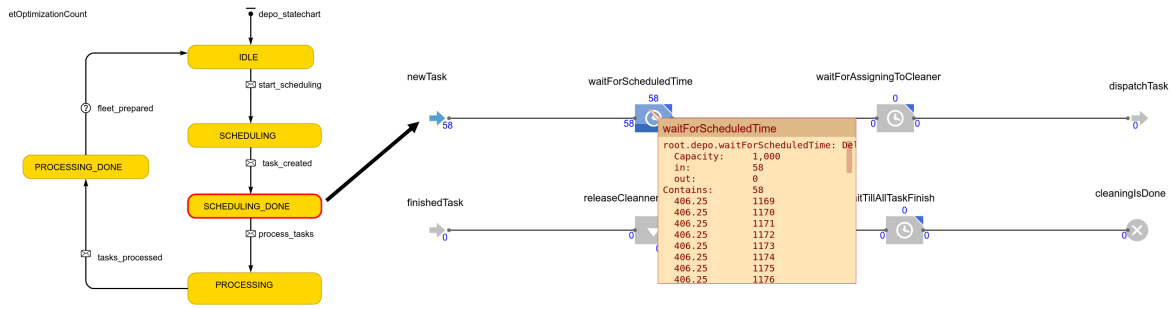

Slika 5.19: Prikaz stanja agenta *spremište vozila* i procesa za obradu zadataka

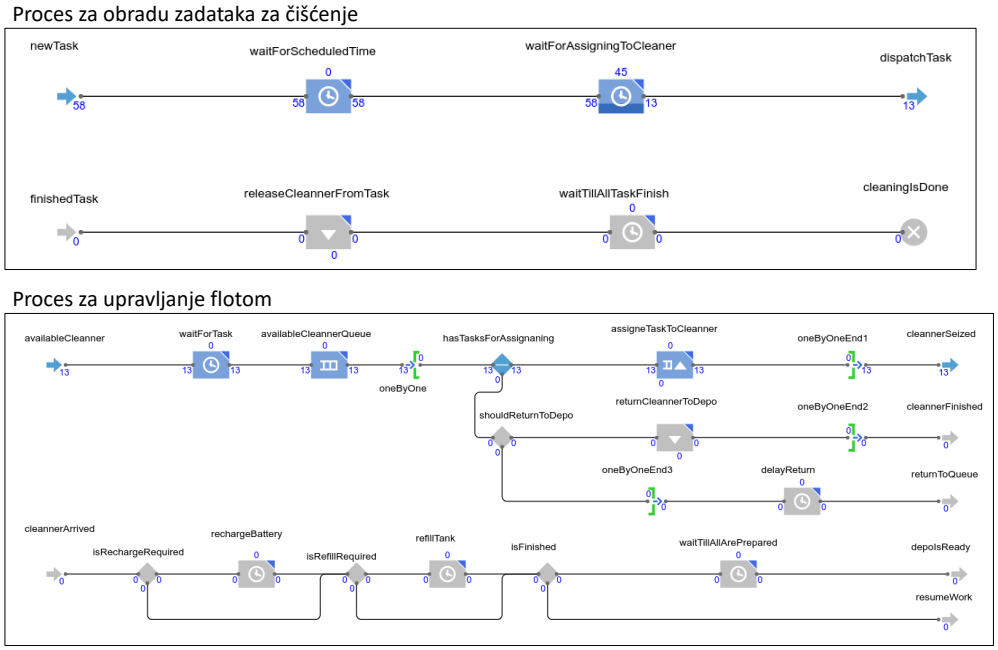

Slika 5.20: Prikaz stanja procesa za obradu zadataka i procesa za upravljanje flotom nakon dodjele prvih 10 zadataka električnim čistilicama

kretanja, dok pod *c* možemo vidjeti da prelaskom agenta *Električna čistilica* u stanje *CLEANING PARKING SPACE* uzrokuje potrošnju baterije i vodenog spremnika na temelju čišćenja parkirališnog mjesta.

Svaki agent *Električna čistilica* sa završetkom zadatka za čišćenje postavlja se u stanje *WAITING FOR NEW TASK*. Na slici 5.22 pod *a* agent *Električna čistilica* šalje izvršeni zadatak

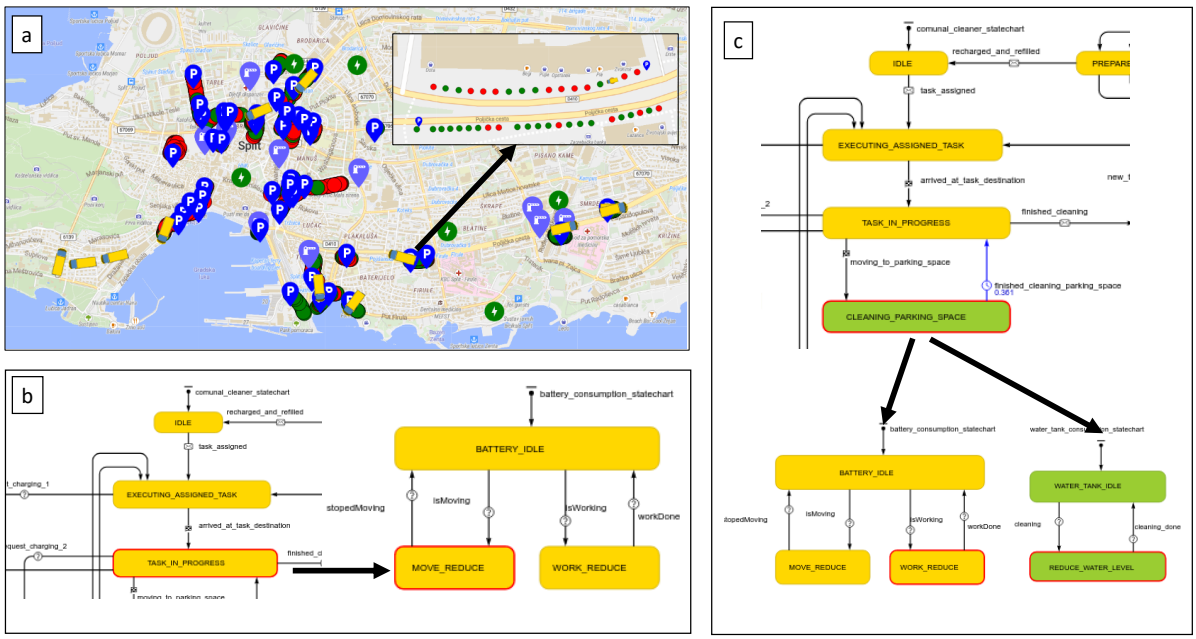

Slika 5.21: Prikaz izvršavanja zadataka za čišćenje agenta *Električna čistilica*: a) vizualni prikaz pomoću karte b) potrošnja baterije zbog kretanja električne čistilice c) potrošnja vodenog spremnika i baterije zbog rada električne čistilice

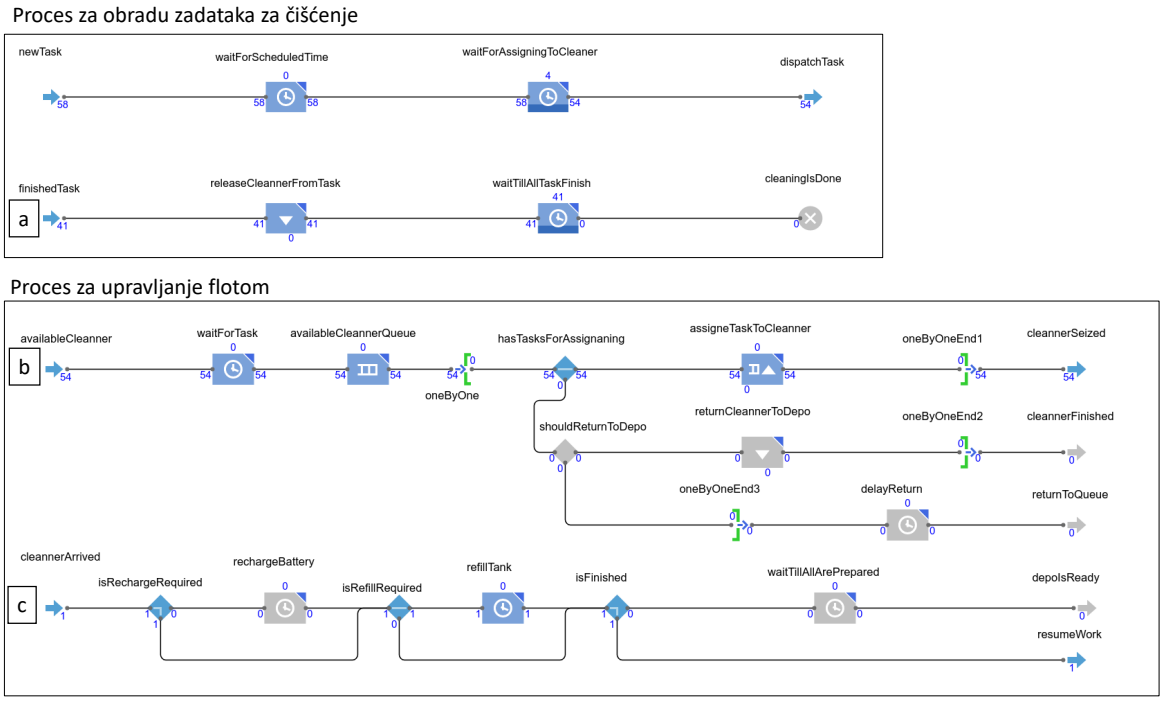

Slika 5.22: Prikaz stanja procesa agenta *Spremište vozila*: a) prikaz stanja izvršenih zadataka za čišćenje b) prikaz stanja dodjele zadataka dostupnim čistilicama c) prikaz stanja korištenja nadopune vodenog spremnika na spremištu vozila

agentu *Spremište vozila* u proces za obradu zadataka signalizirajući time agentu *Spremište vozila* da je zadatak izvršen. Slika 5.22 pod *b* prikazuje statistiku koliko je agenata *Električna čistilica* prošlo kroz proces za upravljanje flotom zbog dodjele novog zadatka za čišćenje. U trenutku dodjele agenta *Električna čistilica* zadatku za čišćenje pomoću osnovnog algoritma za usmjeravanje prema parkiralištu, agent *Električna čistilica* izlazi iz procesa za upravljanje flotom dok zadatak za čišćenje izlazi iz procesa za obradu zadataka i šalje se dodijeljenom agentu *Električna čistilica* na izvršavanje. Dodatno se na slici 5.22 pod *c* vidi da je određeni agent *Električna čistilica* došao na lokaciju spremišta vozila zbog nadopune spremnika za vodu. Po završetku nadopune spremnika s vodom, agent *Električna čistilica* izlazi iz procesa za upravljanje flotom i nastavlja s izvršavanjem zadatka za čišćenje.

Kad razina baterije padne ispod 30%, status baterije promijeni se u *RECHARGE BATTERY* signalizirajući agentu *Električna čistilica* da je potrebno punjenje baterije. Agent *Električna čistilica* stvara zadatak za punjenje i šalje ga agentu *Spremište vozila* koji na temelju algoritma za usmjeravanje prema električnoj punionici dodjeljuje električnu punionicu agentu *Električna čistilica* postavljajući je u zadatak za punjenje. Ovako definirani zadatak za punjenje šalje se agentu *Električna čistilica* koji se usmjerava prema punionici. Dolaskom na električnu punionicu izvršava se proces punjenja na električnoj punionici. Slika 5.23 prikazuje izvršavanje punjenja baterije agenta *Električno vozilo* kod agenta *Električna punionica*, gdje proces punjenja baterije pokazuje da dva agenta *Električna čistilica* čekaju u redu na slobodan priključak

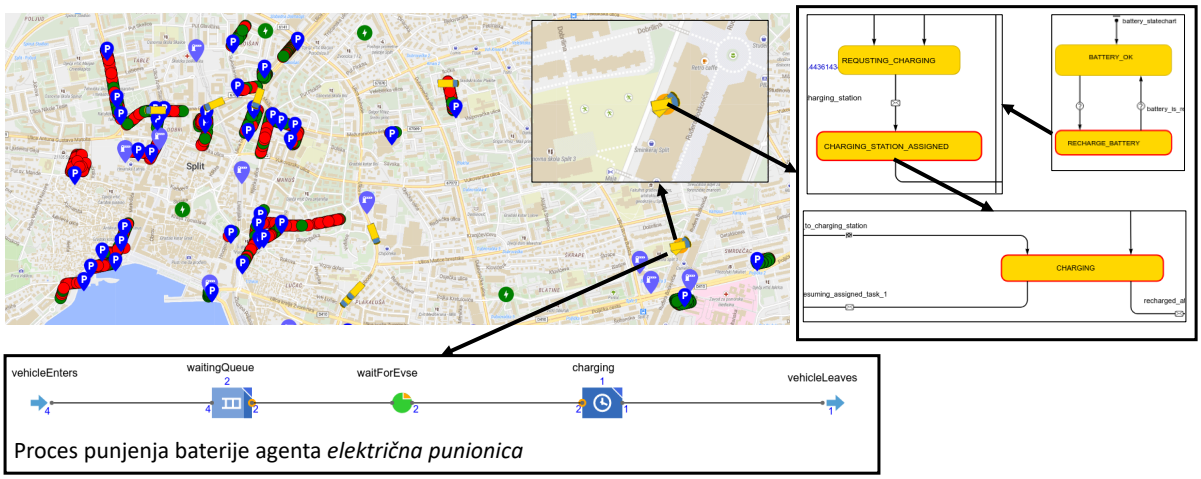

Slika 5.23: Prikaz izvršavanja punjenja baterije agenta *Električno vozilo* na agentu *Električna punionica* tijekom izvođenja simulacije

punionice koja ima samo jedan dostupan priključak za punjenje. Agenti *Električna čistilica* dodijeljeni su ovoj punionici zato što im je bila najbliža u trenutku čišćenja parkirališta, koja su vidljiva na karti slike 5.23.

Nakon što agenti *Električna čistilica* izvrše sve zadatke za čišćenje, svi se agenti usmjeravaju prema spremištu vozila gdje obavljaju pripreme za sljedeći ciklus izvršavanja zadataka za čišćenje. Agent *Spremište vozila* u trenutku završetka s izvršavanjem svih zadataka prelazi u stanje *PROCESSING DONE* u kojem čeka da svi agenti *Električna čistilica* stignu u spremište

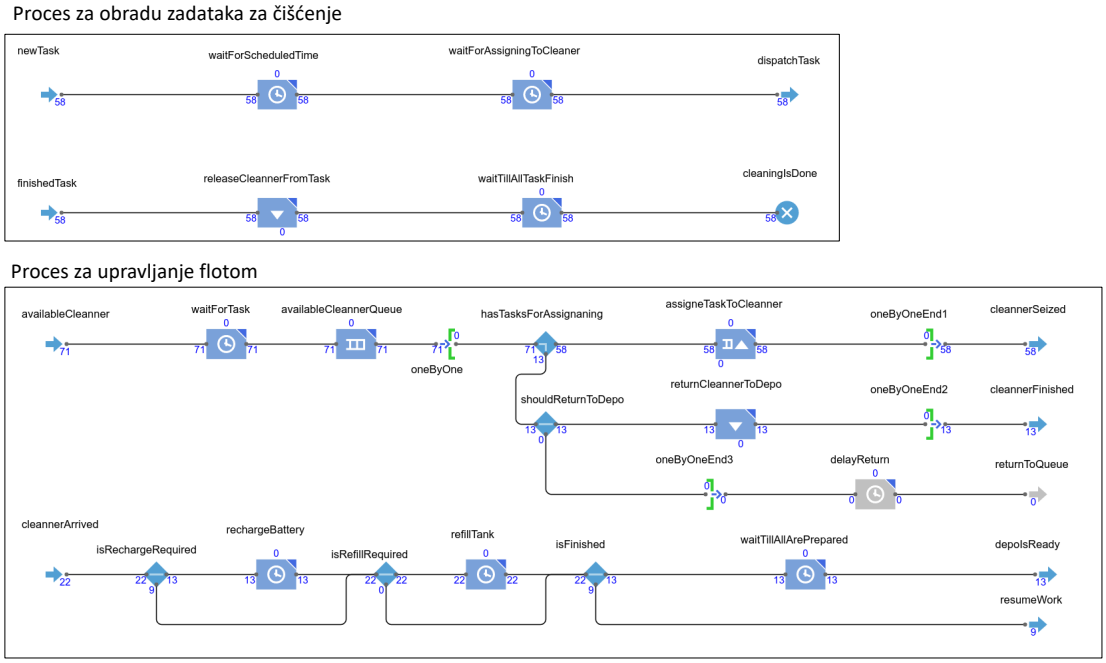

Slika 5.24: Prikaz stanja procesa za obradu zadataka i procesa za upravljanje flotom u trenutku završetka ciklusa čišćenja u simulaciji

Tablica 5.1: Rezultati čišćenja flote električnih čistilica za jedan tjedan ostvarenih simulacijom A

Datum	Početak	Kraj	Broj očišćenih mjesta	Broj neočišćenih mjesta	Uspješnost čišćenja
2021-01-04	06:00:00	20:51:09	1.782	1.138	61,02%
2021-01-05	06:00:00	22:17:02	1.518	1.402	52,00%
2021-01-06	06:00:00	19:35:12	1.491	1.429	51,05%
2021-01-07	06:00:00	22:32:22	1.540	1.380	52,75%
2021-01-08	06:00:00	21:28:02	1.554	1.366	53,22%
2021-01-09	06:00:00	21:07:42	1.671	1.249	57,22%
2021-01-10	06:00:00	22:29:21	1.914	1.006	65,56%

vozila i odrade pripreme koje uključuju punjenje baterije i nadopunu vodenog spremnika. Po završetku pripreme svih agenata, agent *Spremište vozila* prelazi u stanje *IDLE* i završava ciklus čišćenja gradskih parkirališnih površina u gradu Splitu. Stanje procesa za obradu zadataka i procesa za upravljanje flotom u trenutku kad agent *Spremište vozila* ponovno dođe u stanje *IDLE* prikazani su na slici 5.24. Rezultati ciklusa čišćenja električnih čistilica u simulaciji A prikazani su u tablici 5.1, pri čemu sveukupna prosječna vrijednost uspješnosti čišćenja simulacije A iznosi 59,40%. Tablica 5.2 prikazuje rezultate punjenja električnih punionica tijekom izvođenja simulacije A. Sveukupna prosječna vrijednost uspješnosti punjenja na električnim punionicama u simulaciji A iznosi 66,32%.

Tablica 5.2: Rezultati korištenja električnih punionica za ciklus čišćenja odrađen 7. siječnja 2021. godine

Početak	Kraj	Trajanje (min)	Korišteno energije (kWh)	Uspješnost punjenja
10:58:38	14:02:44	184,10	50,88	90,55%
10:35:55	13:58:30	202,58	52,13	85,34%
10:43:36	14:06:40	203,06	52,28	85,53%
10:48:15	14:08:27	200,21	51,42	85,19%
10:58:38	19:06:43	488,07	51,35	34,48%
10:58:38	19:04:29	485,84	51,89	35,38%
10:58:38	22:02:09	663,52	53,67	26,77%

5.2.3Simulacija kontekstnog usmjeravanja elektri čnih vozila

Simulacija B koja se provodi u platformi za simulaciju transportnog sustava flote električnih vozila je simulacija kontekstnog usmjeravanja električnih vozila koristeći algoritme zasnovane na AI-u definirane u poglavlju 4.3. Tijek izvođenja simulacije B jednak je simulaciji A koja je prethodno prikazana kroz funkcijsku analizu analizi. Razlika se sastoji u dijelu vezanom uz stvaranje zadataka za čišćenje koji koristi modele iskoristivosti uličnih i vanuličnih parkirališta unutar algoritama za usmjeravanje prema parkiralištima, te u dijelu vezanom uz dodjelu električne punionice električnoj čistilici pomoću modela iskoristivosti električnih punionica unutar algoritama za usmjeravanje prema električnim punionicama. Odabrani najbolji modeli iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta koriste se kontekstnim informacijama o mjestima od značaja za predviđanje iskoristivosti i metodu strojnog učenja *CatBoost*.

Agent *Spremište vozila* prelaskom u stanje *SCHEDULING* izvršava stvaranje zadataka za čišćenje koristeći algoritam za usmjeravanje prema parkiralištu zasnovanom na *AI*-modelu iskoristivosti uličnih i vanuličnih parkirališta. Pomoću *AI*-modela iskoristivosti uličnih i vanuličnih parkirališta određuje se vrijeme početka čišćenja za određeno parkiralište. Na slici 5.25 može se vidjeti ispis konzole simulacije koja naznačuje različita vremena početka čišćenja parkirališta koja će biti postavljena u zadatku za čišćenje. Stvoreni zadaci za čišćenje prosljeđuju se u proces za obradu zadataka gdje na slici 5.25 možemo vidjeti da zadaci imaju postavljena različita vremena početka izvođenja. Različita vremena početka izvođenja zadataka za čišćenje posljedično nemaju u određenom trenutku sljedećih zadataka za dodjelu agentima *Električna čistilica* koji sada moraju biti u stanju čekanja do početka izvođenja sljedećeg zadatka. Ako je agent *Električna čistilica* izvršio zadatak za čišćenje i nema drugih zadataka za dodjelu u

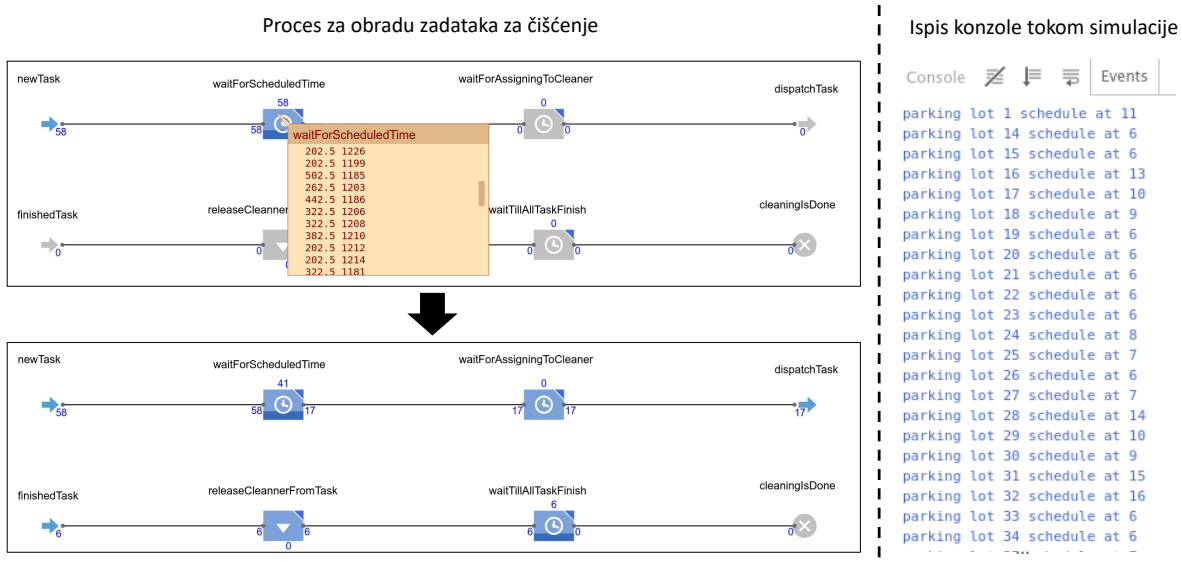

Slika 5.25: Prikaz stanja procesa za obradu zadataka i procesa za upravljanje flotom u trenutku završetka ciklusa čišćenja u simulaciji

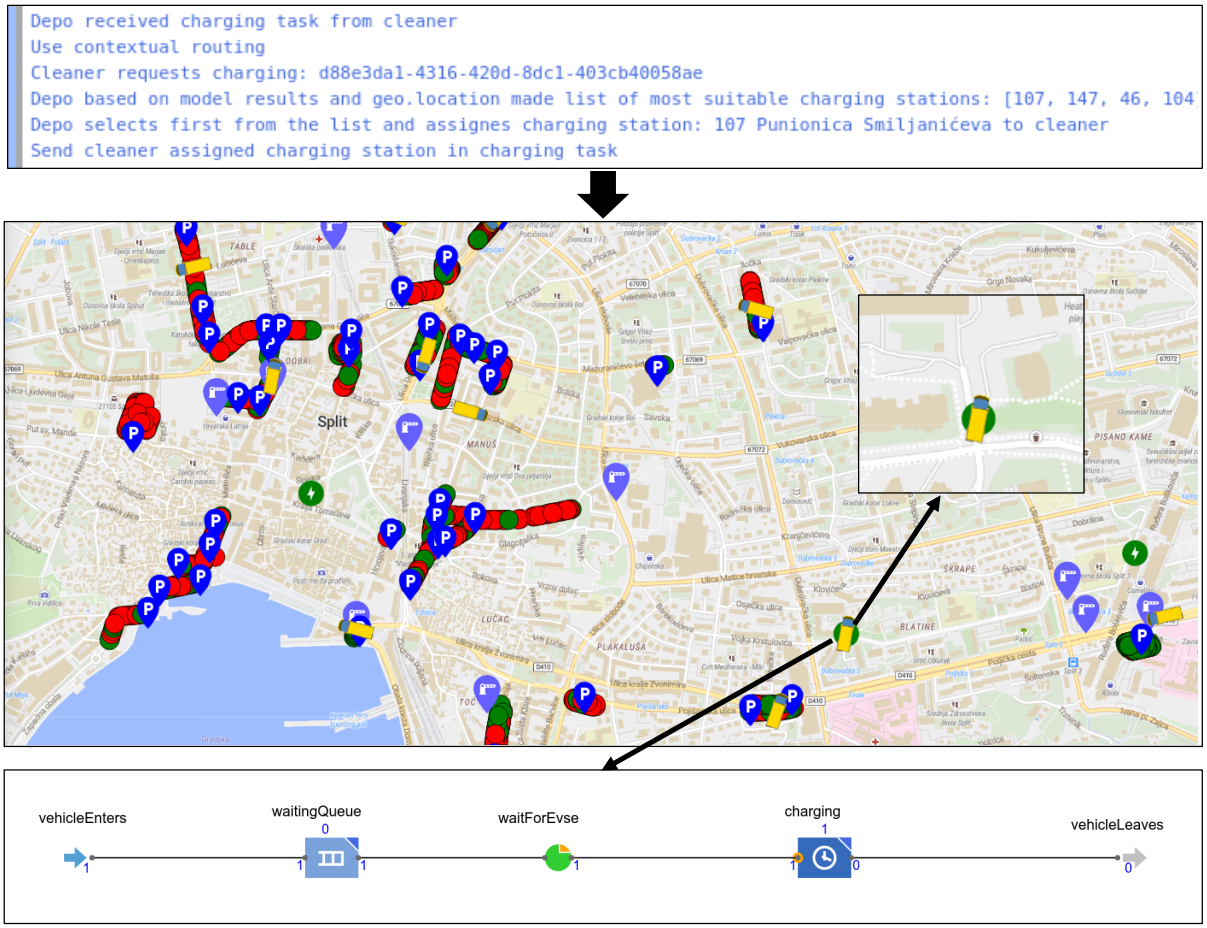

Slika 5.26: Prikaz stanja procesa za obradu zadataka i procesa za upravljanje flotom u trenutku završetka ciklusa čišćenja u simulaciji

tom trenutku, onda agent *Električna čistilica* čeka i u stanju je mirovanja na lokaciji zadnjeg parkirališta koje mu je bilo dodijeljeno.

Tablica 5.3: Rezultati čišćenja flote električnih čistilica za jedan tjedan ostvarenih simulacijom B

Datum	Početak	Kraj	Broj očišćenih mjesta	Broj neočišćenih mjesta	Uspješnost čišćenja
2021-01-04	05:00:00	23:06:22	2.390	530	71,59%
2021-01-05	05:00:00	22:59:53	2.061	859	58,31%
2021-01-06	05:00:00	23:36:45	2.229	691	64,81%
2021-01-07	05:00:00	23:11:25	2.285	635	67,12%
2021-01-08	05:00:00	23:33:08	2.287	633	67,19%
2021-01-09	05:00:00	22:20:57	2.285	635	67,12%
2021-01-10	05:00:00	22:40:46	2.242	678	65,36%

Tablica 5.4: Rezultati korištenja električnih punionica za ciklus čišćenja odrađen 7. siječnja 2021. godine

Početak	Kraj	Trajanje (min)	Korišteno energije (kWh)	Uspješnost punjenja
07:13:35	10:04:48	171,21	51,72	100,00%
07:26:58	10:16:53	169,92	51,33	100,00%
08:28:28	11:19:26	170,97	51,65	100,00%
15:12:07	18:13:56	181,81	51,57	93,89%
16:50:42	19:45:17	174,58	52,44	99,43%
16:18:13	19:49:46	211,55	51,38	80,40%

Agent *Električno vozilo* za potrebe punjenja baterije šalje zadatak za punjenje agentu *Spremište vozila* koji mora izvršiti dodjelu električne punionice električnoj čistilici. Prema slici 5.26, agent *Spremište vozila* pomoću modela iskoristivosti električnih punionica dobiva iskoristivosti punionica u narednih sat vremena i odabire punionicu koja ima najmanju mjeru iskoristivosti i najbliža je električnoj čistilici. Slika 5.26 prikazuje agenta *Električna čistilica* na električnoj punionici koja je po dolasku agenta na lokaciju punionice bila slobodna i agent *Električna čistilica* odmah je započeo proces punjenja bez čekanja u redu na slobodan priključak.

Rezultati simulacije B prikazani su u tablici 5.3. Sveukupni prosjek uspješnosti čišćenja parkirališnih površina u gradu Splitu pomoću kontekstnog usmjeravanja električnih čistilica iznosi 65%, što je u odnosu na simulaciju A povećanje uspješnosti od 5,6%. Rezultati korištenja električnih punionica tijekom simulacije B prikazani su u tablici 5.4. Sveukupni prosjek vrijednost uspješnosti punjenja na električnim punionicama iznosi 84,79%, što je povećanje od 18,47% u odnosu na simulaciju A.

5.3Tehno-ekonomska analiza ostvarene platforme

Tehno-ekonomska analiza obrađuje rezultate izvođenja simulacija u ostvarenoj platformi za simulaciju. Poglavlje 5.2 definira dvije vrste simulacija:

- **Simulacija A** - simulacija osnovnog usmjeravanja električnih čistilica s osnovnim algoritmima;
- **Simulacija B** - simulacija kontekstnog usmjeravanja električnih vozila s algoritmima zasnovanim na AI-u.

Tehno-ekonomska analiza definira mjerljive pokazatelje uspješnosti provođenja simulacija modela VAS-UEV koja se odnose na povećanje održivosti gradskih komunalnih procesa i poboljšanje korisničkog iskustva u korištenju električnih punionica i gradskih parkirališta.

Mjere uspješnosti platforme za simulaciju transportnog sustava flote električnih vozila koje se koriste tijekom izvršavanja simulacije i čije se vrijednosti spremaju u bazu podataka jesu:

- **Uspješnost čišćenja** - predstavlja uspješnost provođenja procesa čišćenja gradskih parkirališnih površina električnim čistilicama iskazanu u postocima;
- **Uspješnost punjenja** - predstavlja uspješnost provođenja što bržeg punjenja električne čistilice na električnim punionicama.

Mjera *uspješnost čišćenja* $\eta_{ciscenje}$ prikazana izrazom 5.1 definira se kao udio broja očišćenih parkirališnih mjesta unutar ukupnog broja mjesta svih parkirališta P, gdje N predstavlja broj uličnih i vanuličnih mjesta u gradu Splitu. Za izvođenje simulacije korišteno je 58 parkirališta koja sadrže sveukupno 2920 parkirališnih mjesta. Mjera *uspješnost čišćenja* iskazana je u postocima, pri čemu 0% označava da niti jedno parkirališno mjesto nije očišćeno tijekom ciklusa čišćenja, dok 100% označava da su sva parkirališna mjesta na svim parkiralištima očišćena.

$$\eta_{ciscenje} = \frac{\sum_1^N P^i_{brojOciscenihMjesta}}{\sum_1^N P^i_{kapacitet}} * 100 \tag{5.1}$$

Mjera *uspješnost punjenja* $\eta_{punjenje}$ za *električno vozilo (EV)* prikazana je izrazom 5.4 i definira se kao omjer efektivne brzine punjenja EBP za električno vozilo EV u kW i brzine punjenja BP za električno vozilo EV u kW. Korišteno električno vozilo EV u provođenju simulacija je električna čistilica RASCO LYNX Charge koja definira kapacitet baterije od 72,5 kWh i vrijeme punjenja baterije od 0% do 100% od 4 sata. Brzina punjenja BP izračunava se prema izrazu 5.2 i za vrijednosti specificirane za električnu čistilicu RASCO LYNX Charge dobiva se brzina punjenja BP u iznosu od 18,125 kW. Efektivna brzina punjenja vozila EV izračunava se prema izrazu 5.3 kao omjer utrošene energije E u kWh za punjenje baterije i ukupnog vremena provedenog na punionici uključujući pri tome vrijeme čekanja na slobodan priključak i vrijeme punjenja. Manji iznos mjere *uspješnost punjenja* označava da je električno vozilo duže obavljalo punjenje baterije, uključujući pritom i vrijeme čekanja na dostupan priključak, dok veća vrijednost označava kraće trajanje procesa punjenja baterije na električnoj punionici.

$$BP(EV) = \frac{kapacitetBaterije^{\{EV\}}}{trajanjePunjenjaBaterije^{\{EV\}}} \tag{5.2}$$

$$EBP(EV) = \frac{E^{\{EV\}}}{t^{\{EV\}}_{cekanje} + t^{\{EV\}}_{punjenje}}; \tag{5.3}$$

$$\eta_{punjenje}(EV) = \frac{EBP(EV)}{BP(EV)}; \tag{5.4}$$

5.3.1Pove ćanje održivosti u gradskim komunalnim procesima

Gradovi s povećanjem urbanizacije bilježe sve veće povećanje broja korisnika koji posjeduju privatno vozilo kojim se koriste za dnevni prijevoz [129]. Povećanjem broja vozila u gradovima ima posljedično sve manje dostupnog parkirališnog prostora. Gradovi odgovaraju na izazov prenamjenom gradske površine u parkirališta. Povećanjem broja parkirališta predstavlja izazov u planiranju čišćenja parkirališnih površina i planiranju potrebnih resursa za čišćenje. Pomoću ostvarene platforme prikazane funkcijskom analizom može se simulirati čišćenje gradskih parkirališnih površina bez prethodnih promjena u gradskim procesima i resursima. Platforma za simulaciju transportnog sustava flote električnih vozila pruža na financijski vrlo isplativ način provođenje različitih simulacija radi optimizacije gradskih procesa i planiranja resursa.

Poglavlje 5.2.1 prikazuje optimizaciju veličine flote koja ukazuje na to da veličina flote od 13 gradskih električnih čistilica ostvaruje čišćenje unutar vremenskog okvira od 18 sati. Povećanjem vremenskog okvira na 24 sata, funkcijska analiza pokazala je da broj električnih čistilica dobiven pristupom zauzeća parkirališta na temelju modela jest 12, dok je sa stvarnim podacima i dalje bio 13. Ovime se ostvarila ušteda gradskog proračuna u iznosu jedne električne čistilice. Gradovi s povećanjem ili smanjivanjem broja parkirališta tijekom vremena mogu uvijek pomoću ostvarene platforme izvršiti ponovnu optimizaciju električnih čistilica ostvarujući pritom održivost u planiranju gradskih resursa.

Poglavlje 5.2 prikazuje izvođenje simulacija A i B vezane uz gradski proces čišćenja parkirališnih površina. Rezultati simulacija prikazani su na slici 5.27. Može se vidjeti da simula-

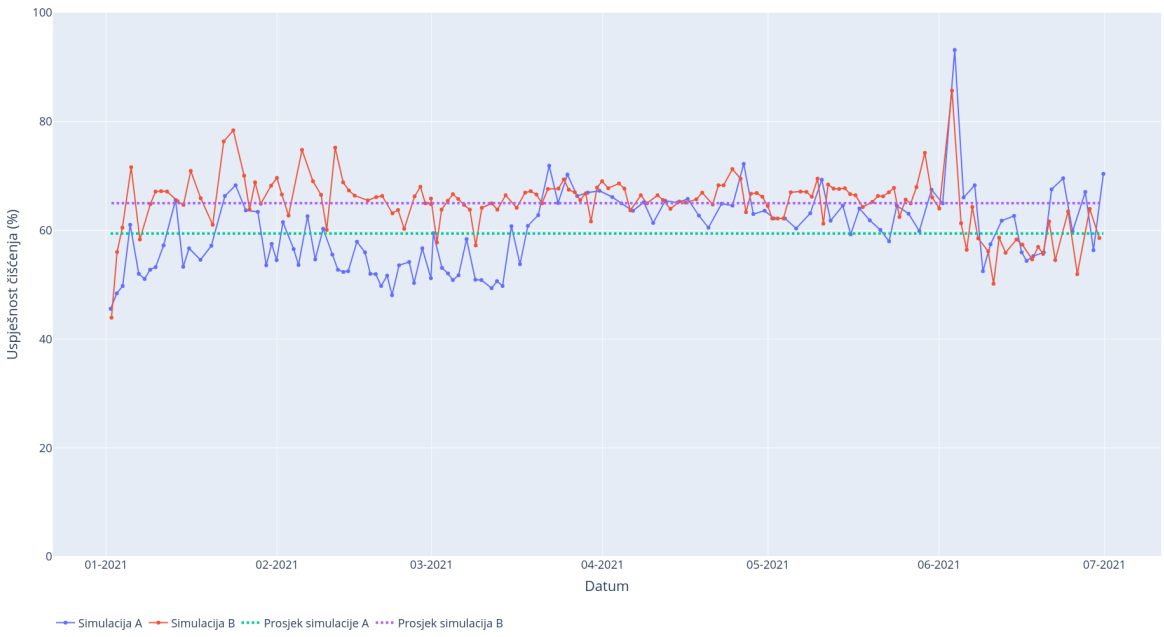

Slika 5.27: Prikaz uspješnosti čišćenja simulacije A i B

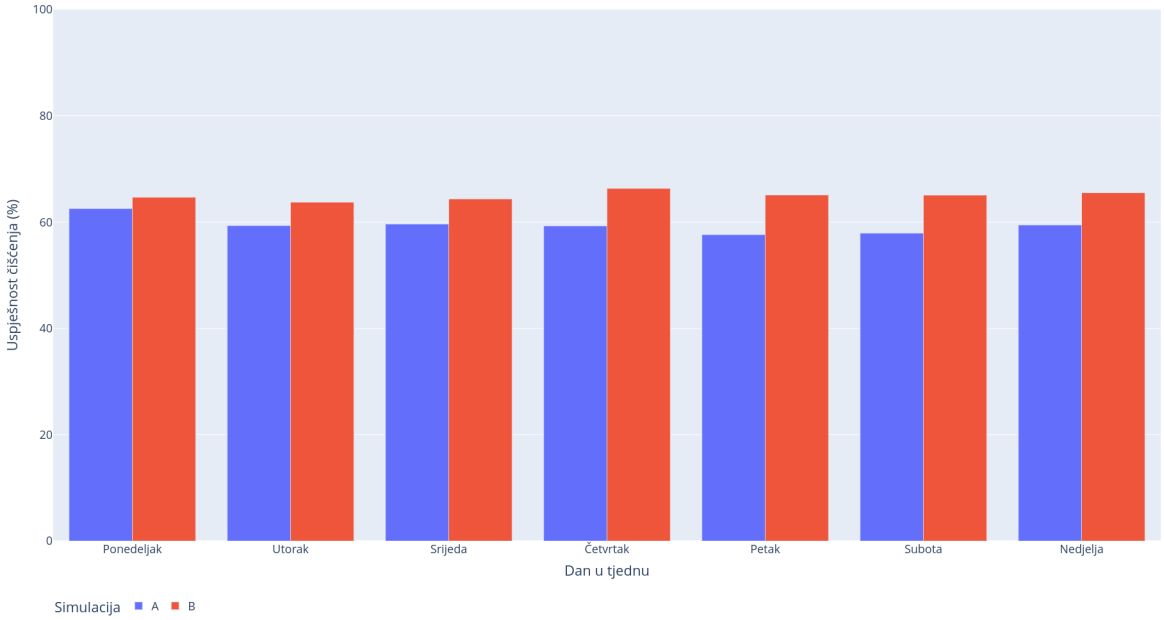

Slika 5.28: Prikaz uspješnosti čišćenja simulacije A i B za prosječan tjedan

cija B bilježi bolju mjeru *uspješnost čišćenja* od simulacije A, pri čemu ukupan prosjek mjere *uspješnost čišćenja* iznosi 65%, što je za 5,6% bolje od simulacije A koja bilježi prosjek od 59,40%. Električne čistilice u simulaciji B u prosjeku su očistile 163 parkirališnih mjesta više od električnih čistilica u simulaciji A, što je poboljšanje gradskog procesa čišćenja parkirališnih površina. Na slici 5.28 prikazan je prosječan tjedan za mjeru *uspješnost čišćenja* gdje se može vidjeti da simulacija B ostvaruje bolju mjeru za svaki dan u tjednu, pri čemu je za ponedjeljak najmanja razlika, dok je za petak ostvarena najveća razlika mjere *uspješnost čišćenja* između simulacije A i B. Kontinuiranim učenjem modela iskoristivosti uličnih i vanuličnih parkirališta mogu se lako pratiti promjene u gradskim urbanim područjima vezanim uz povećanje ili smanjivanje parkirališnih površina, ostvarujući time bolju održivost gradskih procesa za čišćenje parkirališnih površina.

5.3.2Pove ćanje održivosti u korištenju gradskih električnih punionica

Povećanje broja privatnih vozila unutar gradova stvara sve veće gužve u prometu, što rezultira povećanjem buke i onečišćenjem zraka, povećanjem potrošnje goriva cestovnih vozila i narušavanjem kvalitete života u gradovima [130]. Električnim vozilima gužve u prometu otežavaju traženje slobodne električne punionice, pri čemu mogu potrošiti dodatnu energiju baterije na traženje što predstavlja dodatne financijske troškove vlasnicima električnih vozila [131]. Model iskoristivosti električnih punionica korišten unutar algoritama za usmjeravanje električnih čistilica može ostvariti uštede energije električnih vozila i potencijalno omogućiti korisnicima punjenje električnog vozila bez čekanja na dostupnost priključka.

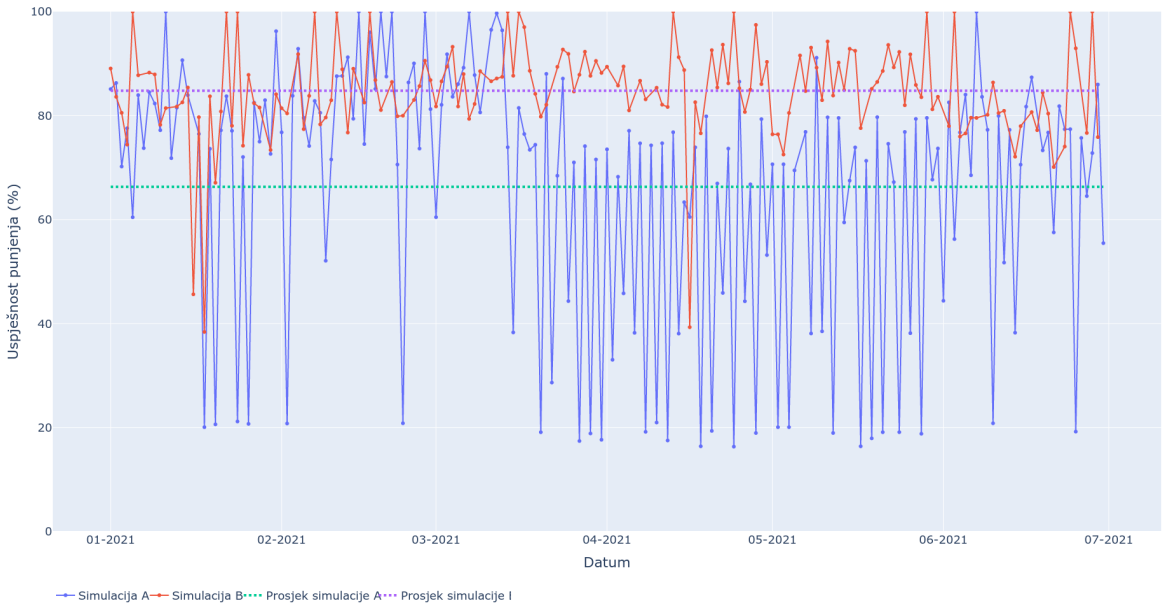

Slika 5.29: Prikaz uspješnosti punjenja simulacije A i B

Poglavlje 5.2 prikazuje izvođenje simulacija A i B gdje se vrši i usmjeravanje električnih čistilica prema električnim punionicama. Uspješnost procesa punjenja električne čistilice definirana je mjerom *uspješnost punjenja* kojom se iskazuje uspješnost korištenja električnih punionica. Što je vrijednost mjere veća, to je vrijeme trajanja punjenja kraće i može označavati proces punjenja bez čekanja na slobodan priključak. Na primjer, ako su dvije električne čistilice ostvarile uspješnost punjenja od 68,96% i 91,95% za 50 kW energije, onda je električna čistilica s 91,95% uspješnosti punjenja ostvarila proces punjenja u trajanju od 4 sata, a druga od 3 sata.

Prikaz rezultata mjera *uspješnost punjenja* simulacije A i B prikazan je na slici 5.29. Može se vidjeti da je simulacija B ostvarila bolje rezultate od simulacije A koristeći pritom model iskoristivosti električnih punionica unutar algoritama za usmjeravanje. Prosjek mjere *uspješnost punjenja* simulacije B iznosi 84,79%, dok za simulaciju A iznosi 66,32%, što je povećanje od 18,47% u simulaciji B. Proces punjenja električne čistilice u simulaciji B u prosjeku je trajao kraće od procesa punjenja električne čistilice u simulaciji A. Slika 5.30 prikazuje prosječni tjedan za mjeru *uspješnost punjenja* gdje se može vidjeti da je za svaki dan u tjednu simulacija B ostvarila bolje rezultate, pri čemu je najveća razlika postignuta za dan utorak u iznosu od 25,53%, a najmanja za petak u iznosu od 13,89%. Iz rezultata se može vidjeti da model iskoristivosti električnih punionica može pospješiti proces punjenja na električnim punionicama, skraćujući pritom vrijeme koje korisnici električnih vozila provedu na punionici. Povećanjem broja električnih vozila u gradovima, gradovi će morati povećati broj električnih punionica koje korisnici moraju uključiti u planiranje aktivnosti punjenja. Model iskoristivosti električnih punionica s kontinuiranim učenjem može se prilagoditi povećanju ili smanjenju broja električnih punionica. Korištenje modela iskoristivosti kao izvor informacija o iskorištenosti električnih

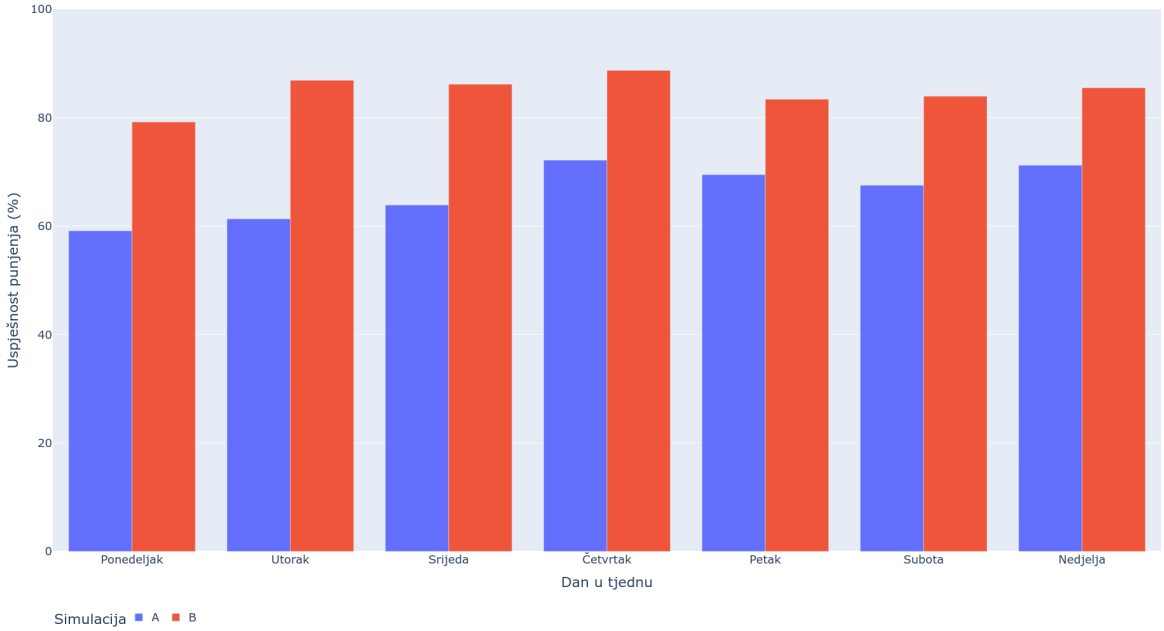

Slika 5.30: Prikaz uspješnosti punjenja simulacije A i B za prosječan tjedan

punionica ili u sklopu algoritama za usmjeravanje prema električnim punionicama, može se postići uravnoteženo korištenje svih električnih punionica u gradu ostvarujući pritom kraće trajanje procesa punjenja, bolje korisničko iskustvo i veću održivost u korištenju gradskih električnih punionica.

5.3.3Korištenje modela iskoristivosti u aplikaciji Bmove

Modeli iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta za predviđanje iskoristivosti mogu se integrirati unutar postojećih aplikacija za pametne uređaje poboljšavajući time korisničko iskustvo pri upotrebi gradskih parkirališta i električnih punionica. Pomoću modela iskoristivosti za ulična i vanulična parkirališta može se dobiti uvid u popunjenost pojedinog parkirališta tijekom dana na temelju čega korisnik može bolje planirati svoje dnevne aktivnosti, kao što je odlazak i dolazak s radnog mjesta. Jedna od aplikacija koja se koristi u Hrvatskoj za plaćanje parkinga jest *Bmove*[§]. Prototip integracije modela iskoristivosti uličnih i vanuličnih parkirališta u aplikaciju *Bmove* prikazan je na slici 5.31. Korak 1 na slici 5.31 prikazuje početni ekran aplikacije gdje korisnik može odabrati grad za koji želi kupiti parkirališne karte. Ako korisnik na početnom ekranu odabere način prikaza u obliku karte, odlazi na ekran s kartom na kojoj su prikazana sva parkirališta koja se nalaze u tome gradu. Odabirom uličnoga parkirališta u koraku 2 prikazuje se predviđena dnevna iskoristivost odabranoga parkirališta. Korisnik u koraku 3 može zumiranjem karte dobiti prikaz uličnoga parkirališta sa senzorima pomoću kojeg se može vidjeti trenutačno zauzeće pojedinih parkirališnih mjesta. Odabirom vanuličnog parkira-

[§]Bmove mobilna i web aplikacija za plaćanje parkinga i korištenja električnih punionica: https://bmove.com/

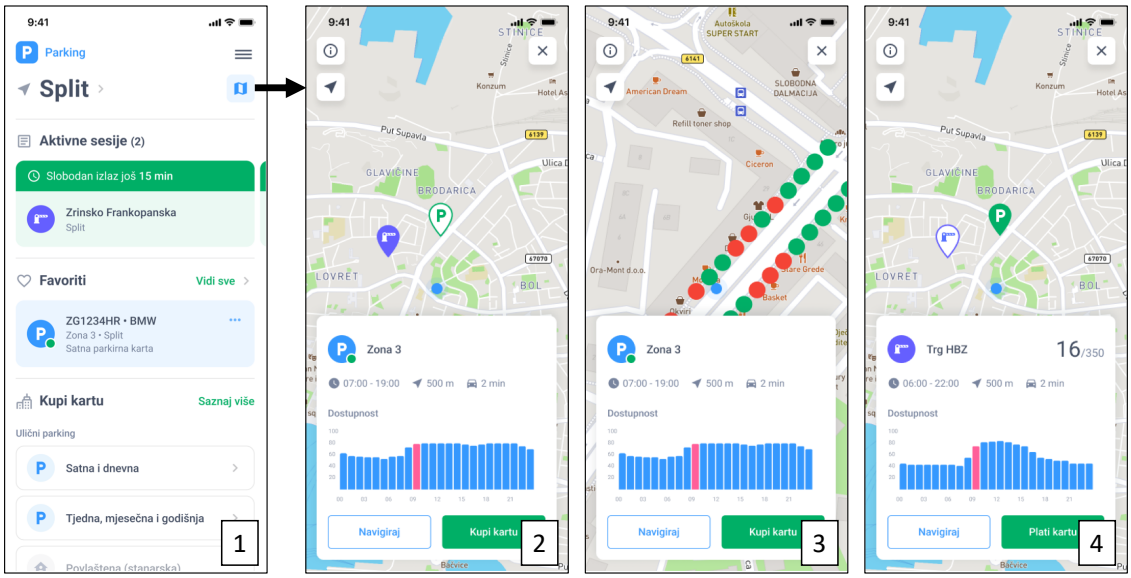

Slika 5.31: Prikaz korištenja modela iskoristivosti uličnih i vanuličnih parkirališta u aplikaciji Bmove

lišta, prikazano u koraku 4 slike 5.31, dobiva se predviđena iskoristivost vanuličnog parkirališta za trenutačni dan. Na temelju prikazanih informacija korisnik aplikacije *Bmove* može ostvariti bolje planiranje svojih dnevnih aktivnosti u vidu odabira parkirališta kojim će se koristiti u gradu za obavljanje svojih aktivnosti.

Aplikacija *Bmove* osim usluge plaćanja parkinga u gradovima nudi i uslugu korištenja električnih punionica. Prototip usluge punjenja na električnim punionicama u aplikaciji *Bmove* prikazan je na slici 5.32. Korisniku se prvo prikazuje početni ekran za uslugu punjenja na električnim punionicama, gdje su prikazane sve električne punionice za odabrani grad. Oda-

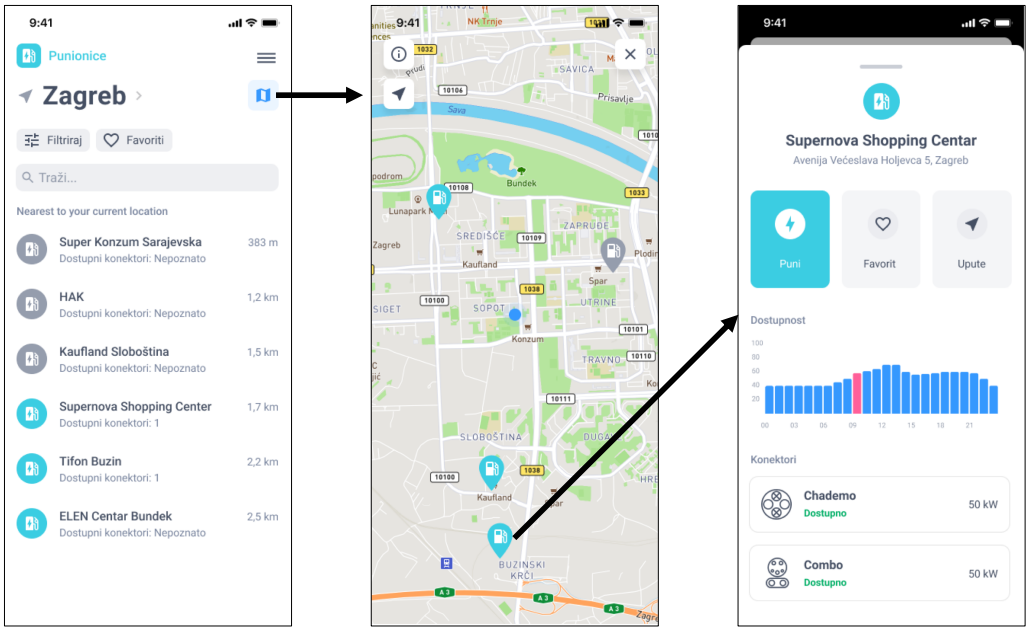

Slika 5.32: Prikaz korištenja modela iskoristivosti električnih punionica u aplikaciji Bmove

birom prikaza početnog ekrana u obliku karte prikazuju se sve električne punionice na karti, pri čemu odabirom određene električne punionice korisnik dobiva detaljne informacije o samoj punionici. Osim detalja vezanih uz električnu punionicu, prikazuje se i predviđena iskoristivost električne punionice za taj dan, dobivene modelom iskoristivosti električne punionice. Korisnik na temelju tih informacija može bolje planirati svoje dnevne aktivnosti i aktivnosti vezane uz punjenje električnog vozila. Kao primjer može biti obavljanje dnevne kupnje namirnica, pri čemu korisnik može odabrati trgovinu u sklopu koje se nalazi električna punionica s najmanjom iskoristivosti, što označava da će biti vrlo vjerojatno slobodna za korištenje po dolasku do trgovine.

5.4Odgovori na istraživa čka pitanja

Ostvareni model višeagentskog sustava za usmjeravanje električnih vozila iz poglavlja 3 uspješno je primijenjen unutar višeagentske platforme što potvrđuje primjenjivost definicije modela višeagentskog sustava i daje odgovor na prvo postavljeno istraživačko pitanje *IP1*. Model višeagentskog sustava zahtijeva korištenje algoritama za usmjeravanje električnih vozila koji su ostvareni u poglavlju 4. Poglavlje 5 prikazuje uspješno korištenje osnovnih algoritama i algoritama zasnovanih na AI-u čime se ostvario scenarij usmjeravanja električnih čistilica prema parkiralištima i prema električnim punionicama. Ovime je ostvaren odgovor na drugo istraživačko pitanje *IP2*. Algoritmi zasnovani na AI-u koriste se modelima AI-a za predviđanje iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta uzimajući u obzir kontekstne podatke *mjesta od značaja* i *vremenske prognoze*. Modeli iskoristivosti koji uzimaju u obzir kontekst *mjesta od značaja* daju najbolje rezultate u predviđanju iskoristivosti i ovime je dan odgovor na treće istraživačko pitanje *IP3*. Pomoću alata *AnyLogic* ostvarena je platforma za simulaciju transportnog sustava flote električnih vozila te je prikazana u poglavlju 5. Ovime je ostvaren odgovor na četvrto istraživačko pitanje *IP4* te je pomoću funkcijske i tehno-ekonomske analize ostvarene platforme u poglavlju 5 definiran i odgovor na peto istraživačko pitanje *IP5*. Odgovorima na sva istraživačka pitanja ostvaren je krajnji cilj doktorskoga rada u obliku višeagentskog sustava za kontekstno usmjeravanje flote električnih vozila čijom se primjenom postižu bolji indikatori uspješnosti u usmjeravanju električnih čistilica prikazanih u tablici 5.5.

Tablica 5.5: Izvršavanje višeagentskog sustava za kontekstno usmjeravanje flote električnih vozila

	Kontekst	**Uspješnost čišćenja**	**Uspješnost punjenja**
Simulacija A	NE	59,50%	66,32%
Simulacija B	DA	65,00%	84,79%

Poglavlje 6

Zaključak i budući rad

Jedan od problema s kojima se gradovi susreću jest održivo provođenje komunalnih procesa i planiranje potrebnih resursa. Prvi izazov predstavlja definiranje veličine i sastava flote električnih čistilica za provođenje što boljeg čišćenja gradskih parkirališnih površina koja tijekom dana mogu biti okupirana vozilima. Drugi izazov je nedostatak slobodnih električnih punionica predstavlja izazov gradovima tijekom obavljanja čišćenja parkirališnih površina električnim čistilicama koji može rezultirati dužim izvršavanjem radnje čišćenja ili u najgorem slučaju odustajanje od daljnjeg provođenja čišćenja. Danas trenutačno ne postoji rješenje koje može definirane izazove riješiti na financijski isplativi način, bez prethodne stvarne primjene, pri čemu se ne jamči uspješnost rješenja. Izazovi provođenja čišćenja gradskih parkirališnih površina pomoću flote električnih čistilica svrstava se u domenu problema usmjeravanja električnih vozila. Višeagentski pristup u rješavanju problema usmjeravanja električnih vozila dobar je način za obuhvaćanje složenih ograničenja i širokog spektra informacija sadržanih unutar profila agenata, pružajući time mogućnost provođenja simulacija višeagentkog sustava za usmjeravanje električnih vozila radi dobivanja najboljeg modela za usmjeravanje flote električnih vozila, bez prethodne implementacije modela u stvarni svijet.

Ključna komponenta doktorskoga rada jest *višeagentski sustav za kontekstno usmjeravanje flote električnih vozila* koji se sastoji od modela višeagentskog sustava, postupaka za usmjeravanje vozila i višeagentske platforme. *Model višeagentskog sustava za usmjeravanje električnih vozila* sastoji se od triju osnovnih agenata: i) agent *električno vozilo*; ii) agent *električna punionica*; iii) agent *spremište vozila*. Za definiranje modela višeagentskog sustava korišteno je višemetodno modeliranje koje se sastoji od višeagentskog modeliranja i modeliranja diskretnih događaja. Svaki agent definiran je skupom statičkih i dinamičkih varijabli koje opisuju sustav agenta. Ponašanje agenta opisano je pomoću dijagrama stanja i definicija procesa koji reprezentiraju obradu diskretnih događaja sustava. Agent *električno vozilo* predstavlja generički tip entiteta koji omogućuje specifikaciju bilo kojeg drugog električnog vozila jednostavnim proširenjem agenta *električno vozilo*. U radu je proširenjem agenta *električno vozilo* ostvaren agent

električna čistilica. Ovime je model višeagentskog sustava dovoljno generičan za primjenu nad većim skupom različitih električnih vozila. Isto tako model višeagentskog sustava može se proširiti dodatnim agentima radi ostvarivanja domene za koju se model želi primijeniti. Za potrebe ovog rada ostvaren je agent *parkiralište* koji se koristi agentom *električna čistilica* za provođenje čišćenja parkirališnih površina. Agent *električna punionica* definira proces punjenja baterije električnog vozila i određuje skup priključka koje agent *električno vozilo* može koristiti. Agent *spremište vozila* centralni je agent koji upravlja dodijeljenom flotom električnih čistilica i provodi usmjeravanje agenata *električna čistilica* prema električnim punionicama i parkiralištima pomoću algoritama za usmjeravanje.

Algoritmi za usmjeravanje električnih vozila ostvareni u doktorskom radu temelje se na problemu usmjeravanja električnih vozila s vremenskim okvirom i kapacitetom, gdje vremenski okvir definira vremenski interval izvođenja zadataka čišćenja, dok kapacitet određuje broj električnih čistilica u floti. Algoritam za usmjeravanje prema parkiralištu definira dvije faze: fazu planiranja i fazu izvršavanja. U fazi planiranja stvaraju se zadaci za čišćenje parkirališta s postavljanjem vremenskog okvira za izvršavanje, dok se u fazi izvršavanja provodi izvršavanje definiranih zadataka usmjeravajući pritom električne čistilice prema parkiralištima. Osnovni algoritam za usmjeravanje prema parkiralištima u fazi planiranja stvara zadatke s jednakim vremenskim okvirima, dok se u fazi izvršavanja zadaci za čišćenje dodjeljuju najbližim električnim čistilicama. Algoritmi zasnovani na umjetnoj inteligenciji koriste se modelima iskoristivosti uličnih i vanuličnih parkirališta u fazi planiranja za određivanje početka vremenskog okvira. Doktorski rad definira *mjeru iskoristivosti* kao novu mjeru za određivanje popunjenosti parkirališta koja se predviđa pomoću modela umjetne inteligencije [15][14]. Modeli iskoristivosti uzimaju u obzir i kontekstne podatke mjesta od značaja i vremenske prognoze, pri čemu najbolji rezultati postižu modeli koji uzimaju u obzir kontekst mjesta od značaja. Model iskoristivosti uličnih parkirališta metodom *CatBoost* ostvario je R^2 od 92,84%, dok za vanulična parkirališta ostvaren je R^2 od 97,04%. Ovime se može zaključiti da na popunjenost parkirališta utječe kontekst. Algoritmi za usmjeravanje prema električnim punionicama za osnovni tip usmjeravaju električnu čistilicu prema najbližoj punionici po lokaciji, dok se algoritmi zasnovani na umjetnoj inteligenciji koriste modelom iskoristivosti električnih punionica prema kojem dodjeljuju punionicu električnoj čistilici s najmanjom mjerom iskoristivosti. Za ostvarivanje modela iskoristivosti električnih punionica korišteni su i kontekstni podaci, pri čemu se kontekst mjesta od značaja pokazao najboljim za predviđanje mjere iskoristivosti električne punionice ostvarujući R^2 od 91,78%. Može se zaključiti da kontekst utječe na korištenje električnih punionica.

Zadnji dio višeagentskog sustava jest *platforma za simulaciju transportnog sustava flote električnih vozila* koja omogućuje evaluaciju i usporednu analizu algoritama usmjeravanja u definiranim kontekstnim uvjetima, te određivanje veličine flote vozila. Ovako definirana platforma omogućuje na financijski prihvatljiv način testiranje različitih modela usmjeravanja, ali

isto tako u slučaju grada optimizaciju procesa i resursa. Ostvarena platforma omogućuje evaluaciju i drugih modela višeagentskih sustava za usmjeravanje električnih vozila i daje usporedne analize pomoću definiranih mjera uspješnosti. Mjere uspješnosti definirane u radu jesu: *mjera uspješnosti punjenja* i *mjera uspješnosti čišćenja*. Mjera uspješnosti punjenja definira efikasnost korištenja električnih punionica prilikom usmjeravanja uz što manje čekanja na početak punjenja baterije, dok mjera uspješnosti čišćenja određuje efikasnost čišćenja gradskih parkirališnih površina uz što veći broj očišćenih mjesta. Usporednom analizom pokazano je da se korištenjem algoritama zasnovanim na umjetnoj inteligenciji uspješnost punjenja povećava za 18,47%, dok se uspješnost čišćenja povećava za 5,60%. Platforma za simulaciju transportnog sustava flote električnih vozila omogućuje postizanje održivosti procesa i resursa u gradovima ostvarujući pritom tri osnovna temelja održivosti: (i) *ljudi* u gradovima ostvaruju bolju kvalitetu života pomoću bolje upotrebe gradskih parkirališta i električnih punionice te uz smanjenje zagađenosti zraka; (ii) *dobit* koji gradovi ostvaruju uz proaktivno planiranje svojih resursa i optimizacije procesa na financijski isplativi način bez prethodne primjene; (iii) *planet* zbog zamjena konvencionalnih vozila s električnim u gradskim flotama ostvaruje smanjivanje emisija stakleničkih plinova u atmosferu.

Zaključno iz ekonomske perspektive, ostvareni modeli iskoristivosti mogu se integrirati u postojeće aplikacije za pametne uređaje, kao što je aplikacija *Bmove*, pomoću kojih korisnici mogu ostvariti uštede na potrošnji energije za pronalazak slobodne električne punionice ili slobodnog parkirališnog mjesta. Gradovi korištenjem višeagentskog sustava za kontekstno usmjeravanje mogu optimizacijom veličine flote ostvariti uštede u gradskom proračunu prilikom nabave električnih čistilica, dok povećanjem učinkovitosti provedbe procesa čišćenja mogu opravdati troškove nabave električnih čistilica i motivirati druge na zamjenu postojećih flota konvencionalnih vozila s električnim. Sve većom uporabom flota električnih vozila u gradskim sustavima smanjuje se onečišćenje zraka i povećava kvaliteta života u gradovima.

Ostvareni višeagentski sustav za kontekstno usmjeravanje električnih vozila potrebno je proširiti s dodatnim kontekstima koji mogu utjecati na usmjeravanje električnih vozila. Nastavak istraživačkog rada treba razmotriti uključivanje konteksta događaji na mjestima od značaja i stanje u prometu. Nedostatak ostvarenog višeagentskog sustava jest nemogućnost primjene sustava na još širi skup područja iz stvarnog svijeta bez prethodne dorade modela višeagentskog sustava u okviru dodavanja entiteta koji predstavljaju odredišta usmjeravanja električnih vozila. Prema tome, potrebno je ostvariti entitet *odredište* koji definira procese stvaranja zahtjeva koje električna vozila izvršavaju omogućujući pritom promjenjivost intenziteta i volumena zahtjeva. Dodatno, potrebno je definirati nove indikatore uspješnosti u višeagentskom sustavu koji se mogu koristiti za provedbu usporedne analize postupaka usmjeravanja. Nastavak istraživanja mora uključiti mjere uspješnosti s fokusom na ekološku i ekonomsku efikasnost ruta usmjeravanja električnih vozila [132].

Prilog

Prilog 1: Prikaz podataka iskoristivosti električnih punionica, uličnih i vanuličnih parkirališta za period od 24 sata

Tablica 6.2 prikazuje prikaz iskoristivosti uličnog parkirališta Domovniski rat 29 u gradu Splitu za period od 24 sata. Može se vidjeti da se iskoristivost mijenja tokom dana. Najmanja iskoristivost zabilježena je tijekom jutarnjih sati, dok je specifično za datum 1. siječnja, koji je vezan uz blagdan Nove godine, iskoristivost nešto veća nego u ranim jutarnjim satima. Tijekom dana u periodu od 7 sati ujutro do 19 sati navečer iskoristivost uličnih parkirališta veća je zbog obavljanja aktivnosti u gradovima. U tablici 6.2 prikazana je iskoristivost vanuličnog parkirališta Trga HBZ-a u gradu Splitu za period od 24 sata. Jednako kao u primjeru uličnih parkirališta datum je vezan uz blagdan Nove godine te se može vidjeti da je iskoristivost vanuličnog parkirališta najveća u ponoć i u 1 sat ujutro, što označava odlazak građana u grad na organizirani doček Nove godine. Nakon tog perioda iskoristivost značajno pada i bilježi sve do 7 sata ujutro najmanje iskoristivosti vanuličnog parkirališta. Od 7 sati ujutro pa nadalje iskoristivost ponovno raste što naznačuje povećanje korištenja parkirališta zbog obavljanja aktivnosti u gradu. No sada se može vidjeti da iskoristivost vanuličnog parkirališta oko ponoći nakon blagdana Nove godine bilježi tek nekih 35%.

Tablica 6.3 prikazuju iskoristivost električne punionice City centra ONE u gradu Splitu za period od 24 sata. Električna punionica smještena je u sklopu trgovačkog centra. Iz podataka o iskoristivosti električne punionice vidljivo je da se koristi tek nakon 15 sati, a to je period koji se veže okvirno uz kraj radnog vremena i potencijalne odlaske u trgovačke centra radi kupnje. Električna je punionica je skoro u potpunosti zauzeta od 16 sati pa sve do 21 sata, do kada je radno vrijeme trgovačkog centra.

Tablica 6.1: Prikaz podataka o iskoristivosti uličnog parkirališta za period od 24 sata

Id parkirališta	Vrijeme	Iskoristivost (%)
1	2018-01-01 00:00:00	74,06
1	2018-01-01 01:00:00	74,30
1	2018-01-01 02:00:00	75,74
1	2018-01-01 03:00:00	73,91
1	2018-01-01 04:00:00	71,84
1	2018-01-01 05:00:00	68,82
1	2018-01-01 06:00:00	69,57
1	2018-01-01 07:00:00	67,27
1	2018-01-01 08:00:00	65,81
1	2018-01-01 09:00:00	69,14
1	2018-01-01 10:00:00	69,63
1	2018-01-01 11:00:00	70,68
1	2018-01-01 12:00:00	75,83
1	2018-01-01 13:00:00	72,39
1	2018-01-01 14:00:00	72,83
1	2018-01-01 15:00:00	81,74
1	2018-01-01 16:00:00	81,74
1	2018-01-01 17:00:00	78,46
1	2018-01-01 18:00:00	77,36
1	2018-01-01 19:00:00	74,92
1	2018-01-01 20:00:00	67,93
1	2018-01-01 21:00:00	65,04
1	2018-01-01 22:00:00	63,56
1	2018-01-01 23:00:00	58,33

Tablica 6.2: Prikaz podataka o iskoristivosti vanuličnog parkirališta za period od 24 sata

Id parkirališta	Vrijeme	Iskoristivost (%)
6	2019-01-01 00:00:00	99,35
6	2019-01-01 01:00:00	80,36
6	2019-01-01 02:00:00	54,89
6	2019-01-01 03:00:00	40,15
6	2019-01-01 04:00:00	28,06
6	2019-01-01 05:00:00	20,16
6	2019-01-01 06:00:00	19,16
6	2019-01-01 07:00:00	18,59
6	2019-01-01 08:00:00	19,48
6	2019-01-01 09:00:00	22,79
6	2019-01-01 10:00:00	23,70
6	2019-01-01 11:00:00	37,56
6	2019-01-01 12:00:00	80,64
6	2019-01-01 13:00:00	98,99
6	2019-01-01 14:00:00	95,73
6	2019-01-01 15:00:00	96,64
6	2019-01-01 16:00:00	95,11
6	2019-01-01 17:00:00	73,16
6	2019-01-01 18:00:00	60,63
6	2019-01-01 19:00:00	52,06
6	2019-01-01 20:00:00	45,21
6	2019-01-01 21:00:00	38,78
6	2019-01-01 22:00:00	36,31
6	2019-01-01 23:00:00	34,99

Tablica 6.3: Prikaz podataka o iskoristivosti električne punionice za period od 24 sata

Id punionice	Vrijeme	Iskoristivost (%)
46	2020-06-01 00:00:00	0,00
46	2020-06-01 01:00:00	0,00
46	2020-06-01 02:00:00	0,00
46	2020-06-01 03:00:00	0,00
46	2020-06-01 04:00:00	0,00
46	2020-06-01 05:00:00	0,00
46	2020-06-01 06:00:00	0,00
46	2020-06-01 07:00:00	0,00
46	2020-06-01 08:00:00	0,00
46	2020-06-01 09:00:00	0,00
46	2020-06-01 10:00:00	0,00
46	2020-06-01 11:00:00	0,00
46	2020-06-01 12:00:00	0,00
46	2020-06-01 13:00:00	0,00
46	2020-06-01 14:00:00	0,00
46	2020-06-01 15:00:00	0,00
46	2020-06-01 16:00:00	96,39
46	2020-06-01 17:00:00	100,00
46	2020-06-01 18:00:00	100,00
46	2020-06-01 19:00:00	100,00
46	2020-06-01 20:00:00	92,31
46	2020-06-01 21:00:00	0,00
46	2020-06-01 22:00:00	0,00
46	2020-06-01 23:00:00	0,00

Prilog 2: Prikaz važnosti ulaznih varijabli modela iskoristivosti

Slika 6.1 prikazuje važnosti ulaznih varijabli modela iskoristivosti za vanulična parkirališta, a slika 6.2 za ulična parkirališta. Slika 6.3 prikazuje važnost ulaznih varijabli modela iskoristivosti električnih punionica. Skup ulaznih varijabli ne mora odgovarati skupu svih ulaznih varijabli definiranih u fazi stvaranja modela iskoristivosti, jer prilikom treniranja modela vrši se rekurzivna eliminacija ulaznih varijabli radi dobivanja što boljeg modela iskoristivosti.

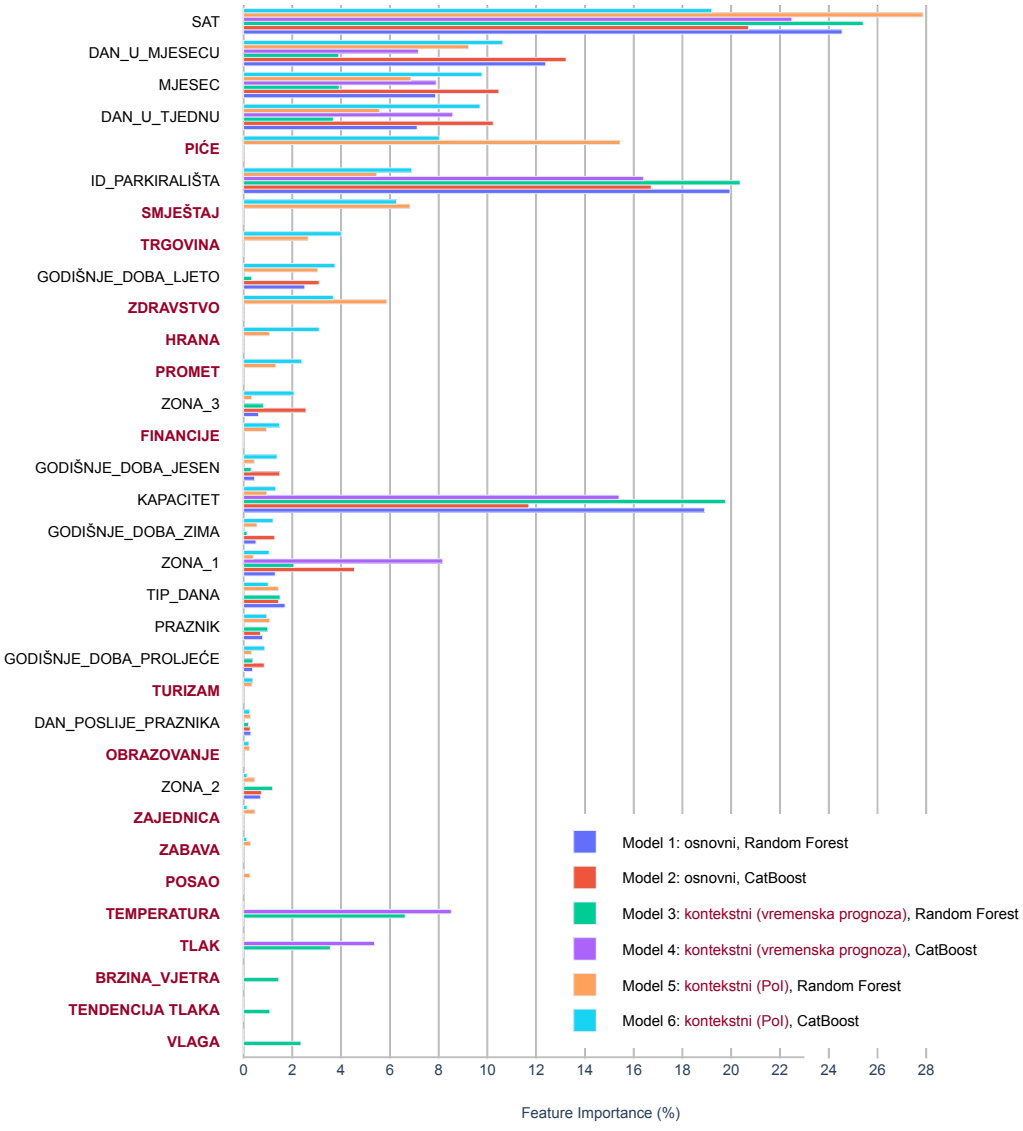

Slika 6.1: Prikaz važnosti ulaznih varijabli modela iskoristivosti vanuličnih parkirališta

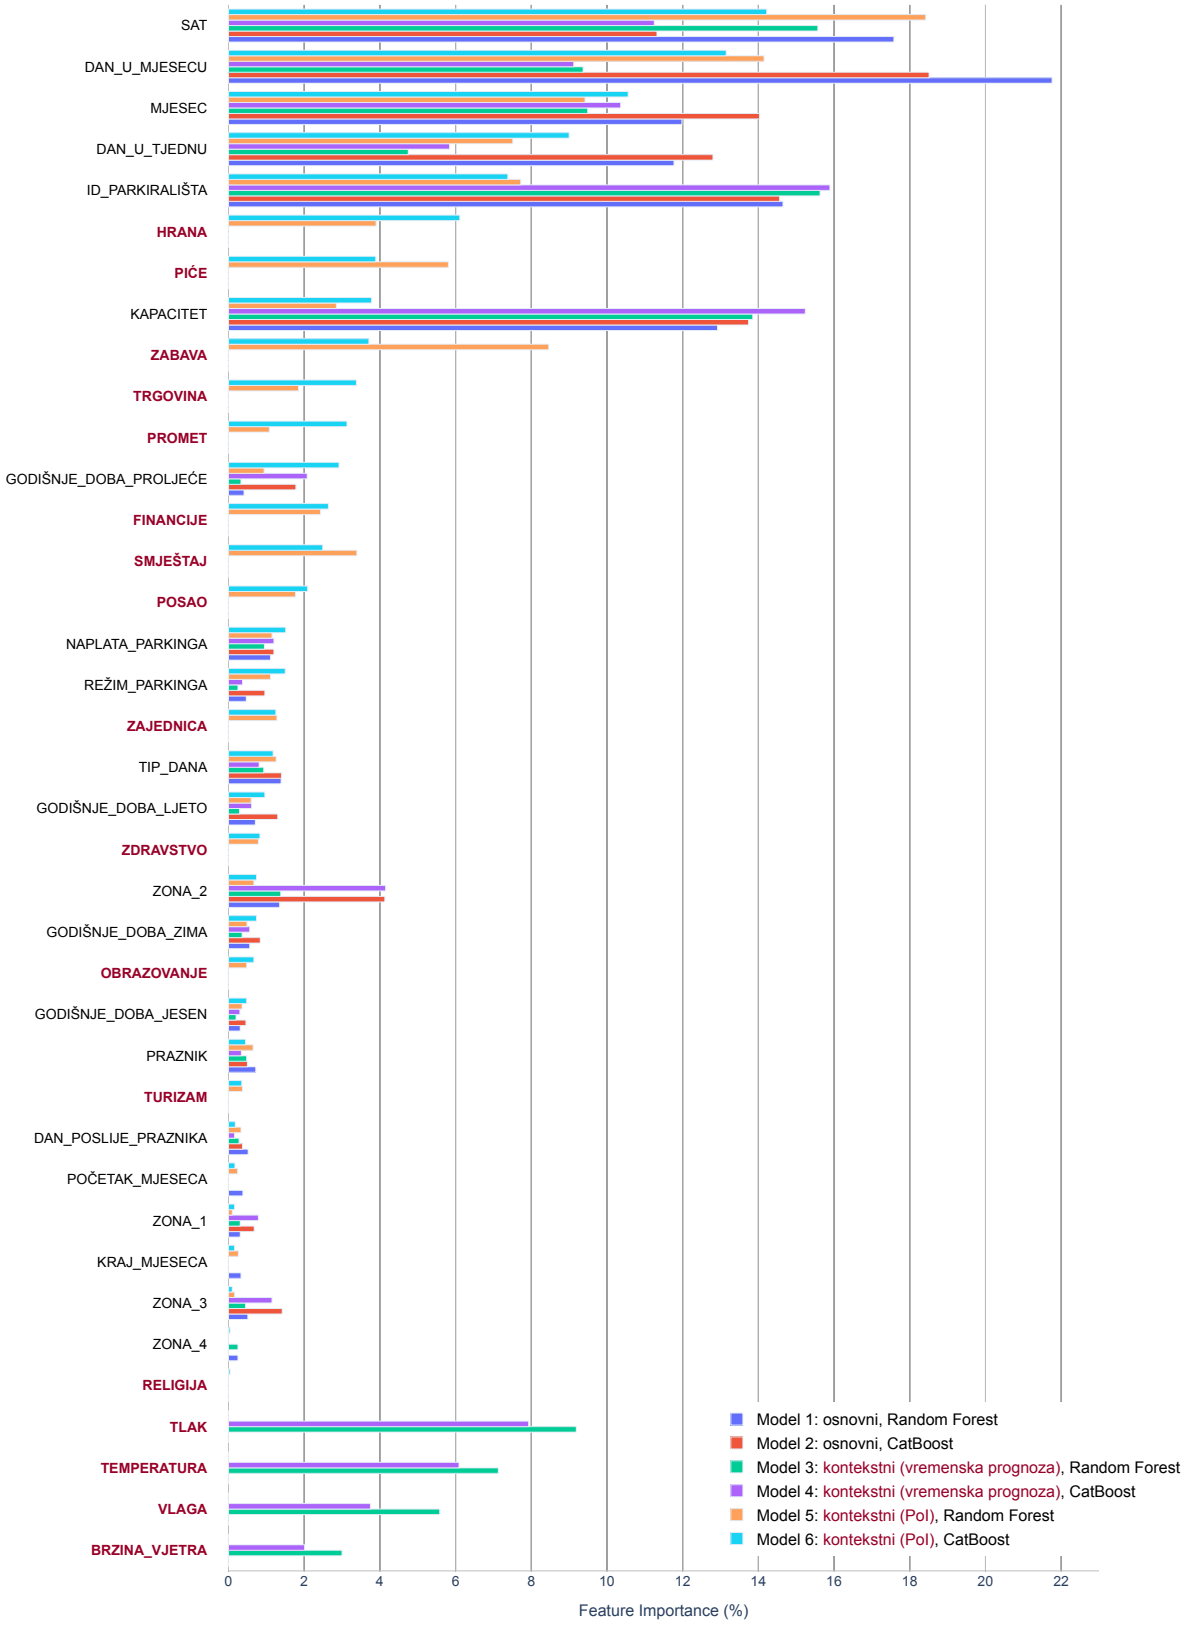

Slika 6.2: Prikaz važnosti ulaznih varijabli modela iskoristivosti uličnih parkirališta

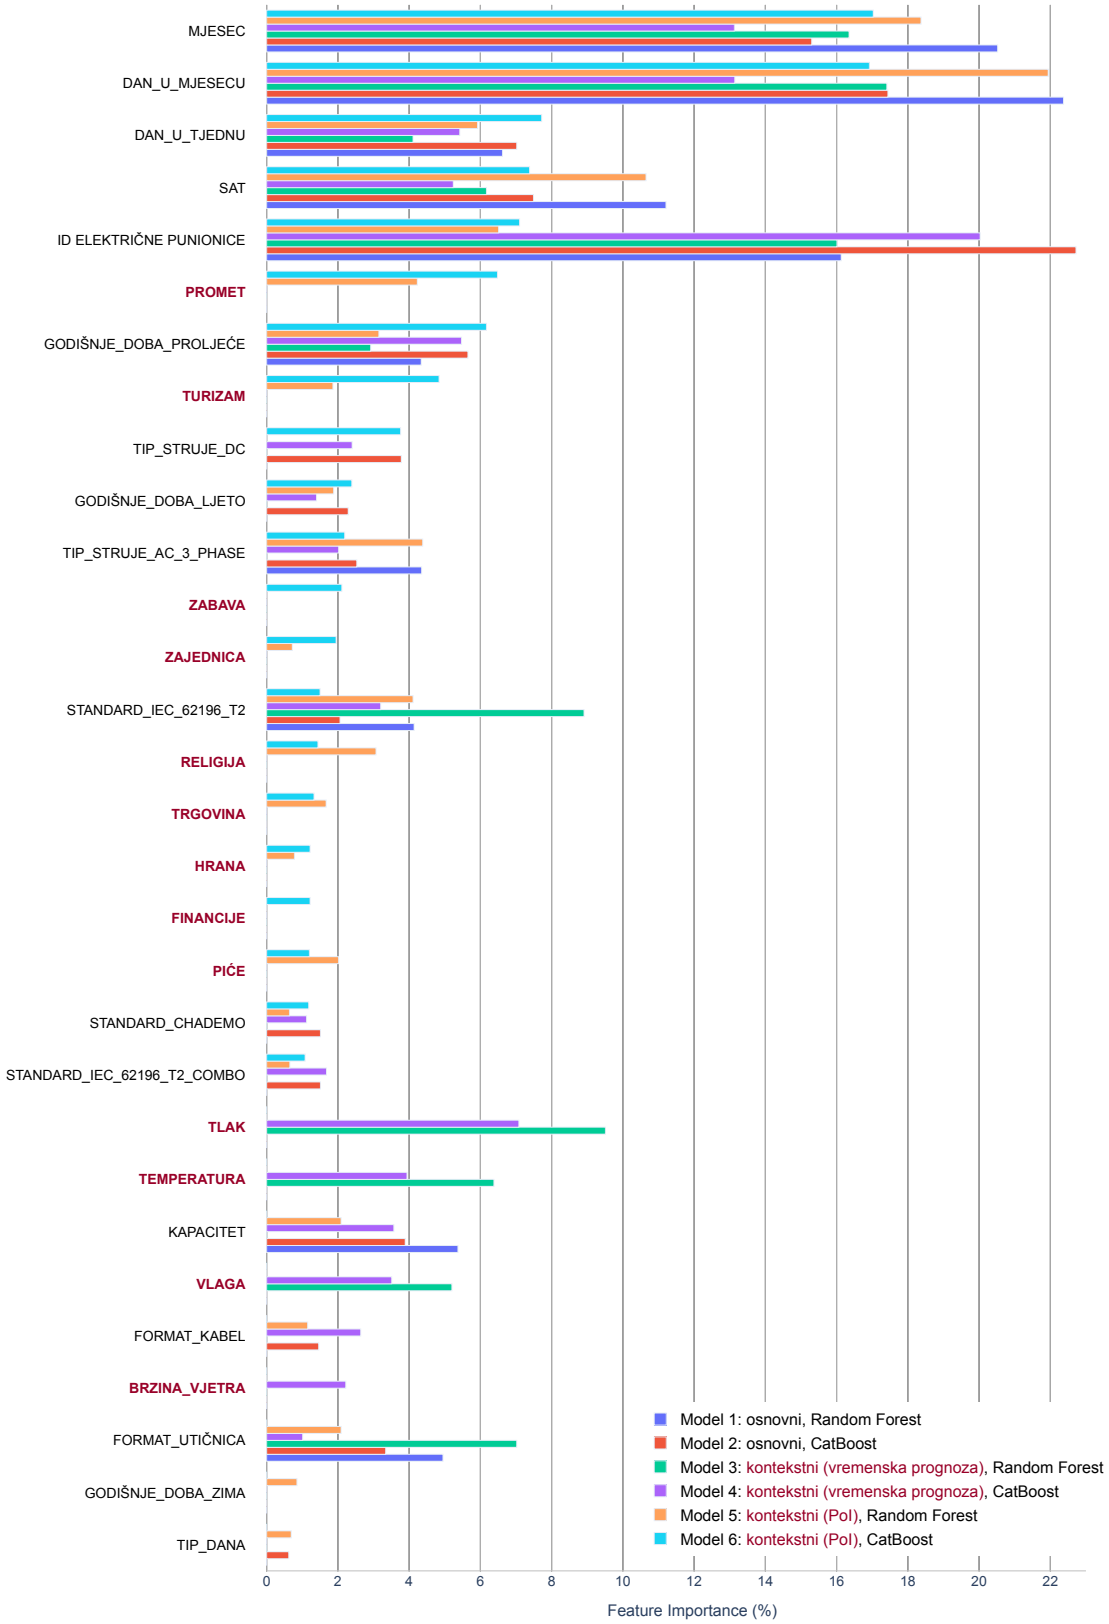

Slika 6.3: Prikaz važnosti ulaznih varijabli modela iskoristivosti električnih punionica

Prilog 3: Sustavske specifikacije alata AnyLogic

Okruženje za razvoj modela

Okruženje za razvoj modela u alatu AnyLogic temelji se na programskom jeziku Java i razvojnog okruženja Eclipse. Okruženje za razvoj modela podržano je i testirano na sljedećim okruženjima:

- •Microsoft Windows 10, x64, Internet Explorer 11;
- •Apple Mac OS X 10.15 (Catalina), x64, Universal, Safari 9+;
- •Ubuntu Linux 18 and 20, x64 (with installed GTK+, libwebkitgtk-1.0-0, libudev, libssl), Firefox 24+;
- •Linux Mint 17, x64 (with installed GTK+, libwebkitgtk-1.0-0, libudev, libssl), Firefox 24+.

AnyLogic može se instalirati i na drugim platformama koje nisu navedene u prethodnoj listi (druge distribucije platforme Linux), ali ne može se garantirati potpuna kompatibilnost između alata AnyLogic i odabrane platforme.

Sustavske preporuke

Za rad s alatom AnyLogic potrebno je sljedeće:

- •Instalacija AnyLogica zahtijeva 1,5 GB slobodne memorije;
- •Preporu čuje se 4-8 GB radne memorije i procesor s najmanje dvjema jezgrama za postizanje optimalne performanse alata AnyLogic (povećanjem broja jezgri preporučljivo je za izvršavanje simulacija koje su vrlo zahtjeve kao na primjer modeliranje pješaka i više paralelnih simulacija u isto vrijeme);
- •Ra čunalni miš koji je u obliku *touchpad-a* za grafičko uređivanje.

AnyLogic aplikacija za pokretanje simulacije

AnyLogic je samostalna Javina aplikacija koja se pokreće na platformama koje podržavaju Java-okruženje *Java Runtime Enviroment (JRE)* verzije 9.0 i više (najnoviju verziju skinite sa stranica Oraclea).

AnyLogic okruženje za simulaciju u potpunosti je izvedena kao aplikacija programskog jezika Java čije je korištenje testirano za rad na sljedećim platformama:

- •Microsoft Windows 10, x64;
- •Apple Mac OS X 10.15 (Catalina), Universal;
- •Ubuntu Linux 18 and 20, x64;
- •Linux Mint 17, x64.

Prilog 4: Specifikacija električne čistilice RASCO LYNX Charge

LYNX Charge prva je električna čistilica tvrtke RASCO. Izgrađena na istoj platformi kao dizelska verzija LYNX-a, Charge zadržava izvanredne karakteristike čišćenja i lakoće. Novi, posebno dizajnirani baterijski paket kapaciteta 72,5 kWh u kombinaciji sa sustavima koji pametno koriste raspoloživu energiju jamče radnu autonomiju za potrebe profesionalnih korisnika.

BATTERY	
Battery type	Lithium ion
Battery capacity	72,5 kWh
Nominal voltage	345 V
Operating time	Up to 8 hours
SWEEPING UNIT	
Disc brush diameter / speed approx.	850 mm
Disc brush speed	0-125 rpm
Sweeping width (2 brush system)	2860 mm
Sweeping width (3 brush system)	3100 mm
Suction nozzle width	820 mm
Fan speed	3500 rpm
Air flow rate	9000 m³/h
WEIGHT	
Total permissible weight (GVW)	5000 kg

POWER SYSTEM	
Electric drive motor	55 kW
LS pump electric motor	18,5 kW
Suction fan electric motor	11,5 kW
DRIVE	
Transport speed max.	50 km/h
Operating speed max.	12 km/h
Gradeability	25%
WATER SYSTEM	
Clean water tank	230 L
Recirculation system	170 L
Total water systems	400 L

STEERING	
Steering angle front axle	48°
Steering angle rear axle	24°
Wheel diameter	15"
HOPPER	
Total volume	2.0 m³
Tipping angle	44°
Tipping height	1550 mm
CHARGER	
Onboard charger	22 kW
Charging time	4 h
Charger inlet	Type 2

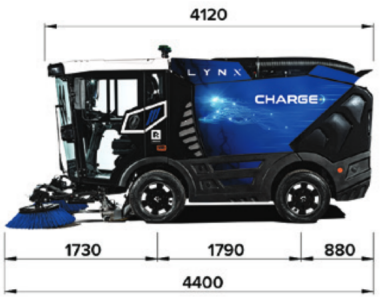

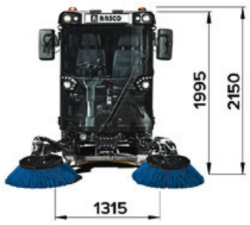

RASCO reserves the right to change the characteristics and specifications of products listed in this brochure without notice. The content is for informational purposes only and cannot be used for other purposes. REV 1_2022

Slika 6.4: Prikaz specifikacije električne čistilice RASCO Lynx korištene u platformi za simulaciju transportnog sustava električnih vozila [133]

Literatura

[1]Abbatecola, L., Fanti, M. P., Ukovich, W., “A review of new approaches for dynamic vehicle routing problem”, in 2016 IEEE International Conference on Automation Science and Engineering (CASE). IEEE, 2016, str. 361–366.

[2]Lin, C., Choy, K. L., Ho, G. T., Chung, S. H., Lam, H., “Survey of green vehicle routing problem: past and future trends”, Expert systems with applications, Vol. 41, No. 4, 2014, str. 1118–1138.

[3]United Nations, “World population prospects 2019: highlights”, Department of Economic and Social Affairs, Population Division, 2019.

[4]Shoup, D. C., “Cruising for parking”, Transport Policy, Vol. 13, No. 6, 2006, str. 479–486.

[5]Kazi, S., Nuzhat, S., Nashrah, A., Rameeza, Q., “Smart parking system to reduce traffic congestion”, in 2018 International Conference on Smart City and Emerging Technology (ICSCET), 2018, str. 1-4.

[6]Jelen, G., Podobnik, V., Babi ć, J., “Parking lot profiling analysis: the city of split use case”, in 2020 5th International Conference on Smart and Sustainable Technologies (SpliTech). IEEE, 2020, str. 1–7.

[7]Mihet-Popa, L., Saponara, S., “Toward green vehicles digitalization for the next generation of connected and electrified transport systems”, Energies, Vol. 11, No. 11, 2018, str. 3124.

[8]European Commission, A Roadmap for Moving to a Competitive Low Carbon Economy in 2050: Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions. Publications Office of the European Union, 2011.

[9]European Commission, White Paper on Transport: Roadmap to a Single European Transport Area: Towards a Competitive and Resource-Efficient Transport System. Publications Office of the European Union, 2011.

[10]Noura, N., Boulon, L., Jemeï, S., "A review of battery state of health estimation methods: Hybrid electric vehicle challenges", World Electric Vehicle Journal, Vol. 11, No. 4, 2020, str. 66.

[11]Pevec, D., Babic, J., Carvalho, A., Ghiassi-Farrokhfal, Y., Ketter, W., Podobnik, V., "A survey-based assessment of how existing and potential electric vehicle owners perceive range anxiety", Journal of Cleaner Production, Vol. 276, 2020, str. 122779.

[12]Xiao, Y., Zhang, Y., Kaku, I., Kang, R., Pan, X., "Electric vehicle routing problem: A systematic review and a new comprehensive model with nonlinear energy recharging and consumption", Renewable and Sustainable Energy Reviews, Vol. 151, 2021, str. 111567.

[13]Bazzan, A. L., Klügl, F., "A review on agent-based technology for traffic and transportation", The Knowledge Engineering Review, Vol. 29, No. 3, 2014, str. 375–403.

[14]Jelen, G., Babic, J., Podobnik, V., "Contextual prediction of on-street and off-street parking lot utilisation: An opening gate towards sustainable parking", in 2021 6th International Conference on Smart and Sustainable Technologies (SpliTech). IEEE, 2021, str. 1–6.

[15]Jelen, G., Podobnik, V., Babic, J., "Contextual prediction of parking spot availability: A step towards sustainable parking", Journal of cleaner production, Vol. 312, 2021, str. 127684.

[16]González-Briones, A., De La Prieta, F., Mohamad, M. S., Omatu, S., Corchado, J. M., "Multi-agent systems applications in energy optimization problems: A state-of-the-art review", Energies, Vol. 11, No. 8, 2018, str. 1928.

[17]Stennikov, V., Mayorov, G., "Research of a multiagent model of an integrated energy supply system developed in the anylogic software environment", in E3S Web of Conferences, Vol. 209. EDP Sciences, 2020, str. 03024.

[18]Schiffer, M., Walther, G., "The electric location routing problem with time windows and partial recharging", European journal of operational research, Vol. 260, No. 3, 2017, str. 995–1013.

[19]Afroditi, A., Boile, M., Theofanis, S., Sdoukopoulos, E., Margaritis, D., "Electric vehicle routing problem with industry constraints: trends and insights for future research", Transportation Research Procedia, Vol. 3, 2014, str. 452–459.

[20]Pelletier, S., Jabali, O., Laporte, G., "50th anniversary invited article—goods distribution with electric vehicles: review and research perspectives", Transportation science, Vol. 50, No. 1, 2016, str. 3–22.

[21]Quak, H., Nesterova, N., van Rooijen, T., "Possibilities and barriers for using electric-powered vehicles in city logistics practice", Transportation Research Procedia, Vol. 12, 2016, str. 157–169.

[22]Erdo ğan, S., Miller-Hooks, E., "A green vehicle routing problem", Transportation research part E: logistics and transportation review, Vol. 48, No. 1, 2012, str. 100–114.

[23]Cortés-Murcia, D. L., Prodhon, C., Afsar, H. M., "The electric vehicle routing problem with time windows, partial recharges and satellite customers", Transportation Research Part E: Logistics and Transportation Review, Vol. 130, 2019, str. 184–206.

[24]Abbasi, M., Rafiee, M., Khosravi, M. R., Jolfaei, A., Menon, V. G., Koushyar, J. M., "An efficient parallel genetic algorithm solution for vehicle routing problem in cloud implementation of the intelligent transportation systems", Journal of cloud Computing, Vol. 9, No. 1, 2020, str. 1–14.

[25]Li, Z., Khajepour, A., Song, J., "A comprehensive review of the key technologies for pure electric vehicles", Energy, Vol. 182, 2019, str. 824–839.

[26]Sanguesa, J. A., Torres-Sanz, V., Garrido, P., Martinez, F. J., Marquez-Barja, J. M., "A review on electric vehicles: Technologies and challenges", Smart Cities, Vol. 4, No. 1, 2021, str. 372–404.

[27]Teoh, T., "Electric vehicle charging strategies for urban freight transport: concept and typology", Transport Reviews, 2021, str. 1–24.

[28]Hannan, M. A., Hoque, M. M., Hussain, A., Yusof, Y., Ker, P. J., "State-of-the-art and energy management system of lithium-ion batteries in electric vehicle applications: Issues and recommendations", Ieee Access, Vol. 6, 2018, str. 19 362–19 378.

[29]Huang, Y., Wang, H., Khajepour, A., Li, B., Ji, J., Zhao, K., Hu, C., "A review of power management strategies and component sizing methods for hybrid vehicles", Renewable and Sustainable Energy Reviews, Vol. 96, 2018, str. 132–144.

[30]Šarkan, B., Gnap, J., Kiktová, M., "The importance of hybrid vehicles in urban traffic in terms of environmental impact", Archiwum Motoryzacji, Vol. 85, No. 3, 2019.

[31]Suarez-Bertoa, R., Pavlovic, J., Trentadue, G., Otura-Garcia, M., Tansini, A., Ciuffo, B., Astorga, C., "Effect of low ambient temperature on emissions and electric range of plug-in hybrid electric vehicles", ACS omega, Vol. 4, No. 2, 2019, str. 3159–3168.

[32]Cano, Z. P., Banham, D., Ye, S., Hintennach, A., Lu, J., Fowler, M., Chen, Z., “Batteries and fuel cells for emerging electric vehicle markets”, Nature Energy, Vol. 3, No. 4, 2018, str. 279–289.

[33]Pollet, B. G., Kocha, S. S., Staffell, I., “Current status of automotive fuel cells for sustainable transport”, Current opinion in Electrochemistry, Vol. 16, 2019, str. 90–95.

[34]Tanç, B., Arat, H. T., Baltacıo ğlu, E., Aydın, K., “Overview of the next quarter century vision of hydrogen fuel cell electric vehicles”, International Journal of Hydrogen Energy, Vol. 44, No. 20, 2019, str. 10 120–10 128.

[35]Erdeli ć, T., Carić, T., “A survey on the electric vehicle routing problem: variants and solution approaches”, Journal of Advanced Transportation, Vol. 2019, 2019.

[36]Fukasawa, R., Longo, H., Lysgaard, J., Aragão, M. P. d., Reis, M., Uchoa, E., Werneck, R. F., “Robust branch-and-cut-and-price for the capacitated vehicle routing problem”, Mathematical programming, Vol. 106, No. 3, 2006, str. 491–511.

[37]Jia, Y.-H., Mei, Y., Zhang, M., “A bilevel ant colony optimization algorithm for capacitated electric vehicle routing problem”, IEEE Transactions on Cybernetics, 2021.

[38]Toth, P., Vigo, D., “Models, relaxations and exact approaches for the capacitated vehicle routing problem”, Discrete Applied Mathematics, Vol. 123, No. 1-3, 2002, str. 487–512.

[39]Ham, A., Park, M.-J., “Electric vehicle route optimization under time-of-use electricity pricing”, IEEE Access, Vol. 9, 2021, str. 37 220–37 228.

[40]Schiffer, M., Schneider, M., Walther, G., Laporte, G., “Vehicle routing and location routing with intermediate stops: A review”, Transportation Science, Vol. 53, No. 2, 2019, str. 319–343.

[41]Liao, W., Liu, L., Fu, J., “A comparative study on the routing problem of electric and fuel vehicles considering carbon trading”, International Journal of Environmental Research and Public Health, Vol. 16, No. 17, 2019, str. 3120.

[42]Erdeli ć, T., Carić, T., Erdelić, M., Tišljarić, L., “Electric vehicle routing problem with single or multiple recharges”, Transportation Research Procedia, Vol. 40, 2019, str. 217–224.

[43]Kancharla, S. R., Ramadurai, G., “Electric vehicle routing problem with non-linear charging and load-dependent discharging”, Expert Systems with Applications, Vol. 160, 2020, str. 113714.

[44]Masmoudi, M. A., Hosny, M., Demir, E., Genikomsakis, K. N., Cheikhrouhou, N., "The dial-a-ride problem with electric vehicles and battery swapping stations", Transportation research part E: logistics and transportation review, Vol. 118, 2018, str. 392–420.

[45]Pelletier, S., Jabali, O., Laporte, G., "The electric vehicle routing problem with energy consumption uncertainty", Transportation Research Part B: Methodological, Vol. 126, 2019, str. 225–255.

[46]Kim, G., Ong, Y.-S., Heng, C. K., Tan, P. S., Zhang, N. A., "City vehicle routing problem (city vrp): A review", IEEE Transactions on Intelligent Transportation Systems, Vol. 16, No. 4, 2015, str. 1654–1666.

[47]Fanti, M. P., Laraspata, R., Iacobellis, G., Mangini, A. M., Ukovich, W., Abbatecola, L., "A decision support system approach for the postal delivery operations", in 2014 IEEE International Conference on Automation Science and Engineering (CASE). IEEE, 2014, str. 588–593.

[48]Fanti, M. P., Mangini, A. M., Abbatecola, L., Ukovich, W., "Decision support for a waste collection service with time and shift constraints", in 2016 American Control Conference (ACC). IEEE, 2016, str. 2599–2604.

[49]Binart, S., Dejax, P., Gendreau, M., Semet, F., "A 2-stage method for a field service routing problem with stochastic travel and service times", Computers & Operations Research, Vol. 65, 2016, str. 64-75, dostupno na: https://www.sciencedirect.com/science/article/pii/S0305054815001689

[50]Ewert, R., Grahle, A., Martins-Turner, K., Syré, A. M., Nagel, K., Göhlich, D., "Electrification of urban waste collection: Introducing a simulation-based methodology for technical feasibility, impact and cost analysis", World Electric Vehicle Journal, Vol. 12, No. 3, 2021, str. 122.

[51]Perboli, G., Rosano, M., "Parcel delivery in urban areas: Opportunities and threats for the mix of traditional and green business models", Transportation Research Part C: Emerging Technologies, Vol. 99, 2019, str. 19–36.

[52]Shen, Z.-J. M., Feng, B., Mao, C., Ran, L., "Optimization models for electric vehicle service operations: A literature review", Transportation Research Part B: Methodological, Vol. 128, 2019, str. 462–477.

[53]Muñoz-Carpintero, D., Sáez, D., Cortés, C. E., Núñez, A., "A methodology based on evolutionary algorithms to solve a dynamic pickup and delivery problem under a hybrid predictive control approach", Transportation Science, Vol. 49, No. 2, 2015, str. 239–253.

[54]Rong, A., Chen, S., Shi, D., Zhang, M., Wang, C., “A review on electric bus charging scheduling from viewpoints of vehicle scheduling”, in 2021 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM), 2021, str. 1-5.

[55]Wang, L., Ma, W., Wang, L., Ren, Y., Yu, C., “Enabling in-depot automated routing and recharging scheduling for automated electric bus transit systems”, Journal of Advanced Transportation, Vol. 2021, Oct 2021, str. 5531063, dostupno na: https://doi.org/10.1155/2021/5531063

[56]Bauer, G. S., Greenblatt, J. B., Gerke, B. F., “Cost, energy, and environmental impact of automated electric taxi fleets in manhattan”, Environmental Science & Technology, Vol. 52, No. 8, 2018, str. 4920-4928, pMID: 29589439, dostupno na: https://doi.org/10.1021/acs.est.7b04732

[57]Gansterer, M., Hartl, R. F., “Collaborative vehicle routing: A survey”, European Journal of Operational Research, Vol. 268, No. 1, 2018, str. 1-12, dostupno na: https://www.sciencedirect.com/science/article/pii/S0377221717309360

[58]Xin, H., “Introduction of centralized and distributed routing protocols”, in 2011 International Conference on Electronics, Communications and Control (ICECC), 2011, str. 2698-2701.

[59]Kullman, N. D., Goodson, J. C., Mendoza, J. E., “Electric vehicle routing with public charging stations”, Transportation Science, Vol. 55, No. 3, 2021, str. 637–659.

[60]Pillac, V., Gendreau, M., Guéret, C., Medaglia, A. L., “A review of dynamic vehicle routing problems”, European Journal of Operational Research, Vol. 225, No. 1, 2013, str. 1–11.

[61]Warden, T., Wojtusiak, J., “Learnable evolutionary optimization in autonomous pickup & delivery planning: a scenario, system architecture and initial results”, TZI-Bericht Nr, Vol. 55, 2010.

[62]Mes, M., van der Heijden, M., Schuur, P., “Interaction between intelligent agent strategies for real-time transportation planning”, Central European journal of operations research, Vol. 21, No. 2, 2013, str. 337–358.

[63]Novaes, A. G. N., Bez, E. T., Burin, P. J., “Fault detection in dynamic vehicle routing operations”, in Dynamics in Logistics, Kreowski, H.-J., Scholz-Reiter, B., Thoben, K.-D., (ur.). Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, str. 13–32.

[64]Artmeier, A., Haselmayr, J., Leucker, M., Sachenbacher, M., “The optimal routing problem in the context of battery-powered electric vehicles”, in CPAIOR Workshop on Constraint Reasoning and Optimization for Computational Sustainability (CROCS), 2010.

[65]Conrad, R. G., Figliozzi, M. A., “The recharging vehicle routing problem”, in Proceedings of the 2011 industrial engineering research conference, Vol. 8. IISE Norcross, GA, 2011.

[66]Schneider, M., Stenger, A., Goeke, D., “The electric vehicle-routing problem with time windows and recharging stations”, Transportation science, Vol. 48, No. 4, 2014, str. 500–520.

[67]Felipe, Á., Ortuño, M. T., Righini, G., Tirado, G., “A heuristic approach for the green vehicle routing problem with multiple technologies and partial recharges”, Transportation Research Part E: Logistics and Transportation Review, Vol. 71, 2014, str. 111–128.

[68]Desaulniers, G., Errico, F., Irnich, S., Schneider, M., “Exact algorithms for electric vehicle-routing problems with time windows”, Operations Research, Vol. 64, No. 6, 2016, str. 1388–1405.

[69]Goeke, D., Schneider, M., “Routing a mixed fleet of electric and conventional vehicles”, European Journal of Operational Research, Vol. 245, No. 1, 2015, str. 81–99.

[70]Zhenfeng, G., Yang, L., Xiaodan, J., Sheng, G., “The electric vehicle routing problem with time windows using genetic algorithm”, in 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 2017, str. 635-639.

[71]Zhang, S., Gajpal, Y., Appadoo, S., Abdulkader, M., “Electric vehicle routing problem with recharging stations for minimizing energy consumption”, International Journal of Production Economics, Vol. 203, 2018, str. 404–413.

[72]Zhang, S., Chen, M., Zhang, W., Zhuang, X., “Fuzzy optimization model for electric vehicle routing problem with time windows and recharging stations”, Expert systems with applications, Vol. 145, 2020, str. 113123.

[73]Basso, R., Kulcsár, B., Sanchez-Diaz, I., “Electric vehicle routing problem with machine learning for energy prediction”, Transportation Research Part B: Methodological, Vol. 145, 2021, str. 24–55.

[74]Bi, X., Tang, W. K. S., “Logistical planning for electric vehicles under time-dependent stochastic traffic”, IEEE Transactions on Intelligent Transportation Systems, Vol. 20, No. 10, 2019, str. 3771-3781.

[75]Chen, H., Zhang, Y., “Dynamic path optimization in sharing mode to relieve urban traffic congestion”, Discrete Dynamics in Nature and Society, Vol. 2021, 2021.

[76]Poonthalir, G., Nadarajan, R., “A fuel efficient green vehicle routing problem with varying speed constraint (f-gvrp)”, Expert Systems with Applications, Vol. 100, 2018, str. 131–144.

[77]Masri, N., Yetkin, M., Hillman, E., Fay, D., Kishore, S., “Optimal public electric bus fleet charging schedule with solar and energy storage considering static and dynamic route assignment”, in 2021 IEEE Symposium Series on Computational Intelligence (SSCI). IEEE, 2021, str. 01–10.

[78]Saleu, M., Raissa, G., “Optimization of urban deliveries with drones and vehicles in parallel”, Doktorski rad, Université Clermont Auvergne (2021-...), 2021.

[79]Wagner, S., Götzinger, M., Neumann, D., “Optimal location of charging stations in smart cities: A points of interest based approach”, 2013.

[80]Pagany, R., Marquardt, A., Zink, R., “Electric charging demand location model—a user- and destination-based locating approach for electric vehicle charging stations”, Sustainability, Vol. 11, No. 8, 2019, str. 2301.

[81]Jordán, J., Palanca, J., del Val, E., Julian, V., Botti, V., “Localization of charging stations for electric vehicles using genetic algorithms”, Neurocomputing, Vol. 452, 2021, str. 416–423.

[82]Napoli, G., Polimeni, A., Micari, S., Andaloro, L., Antonucci, V., “Optimal allocation of electric vehicle charging stations in a highway network: Part 1. methodology and test application”, Journal of Energy Storage, Vol. 27, 2020, str. 101102.

[83]Pevec, D., Babic, J., Carvalho, A., Ghiassi-Farrokhfal, Y., Ketter, W., Podobnik, V., “Electric vehicle range anxiety: an obstacle for the personal transportation (r) evolution?”, in 2019 4th international conference on smart and sustainable technologies (splitech). IEEE, 2019, str. 1–8.

[84]Van Duin, J. R., Quak, H., Muñuzuri, J., “New challenges for urban consolidation centres: A case study in the hague”, Procedia-Social and Behavioral Sciences, Vol. 2, No. 3, 2010, str. 6177–6188.

[85]Gonçalves, F., Cardoso, S. R., Relvas, S., Barbosa-Póvoa, A., "Optimization of a distribution network using electric vehicles: A vrp problem", in Proceedings of the IO2011-15 Congresso da associação Portuguesa de Investigação Operacional, Coimbra, Portugal, 2011, str. 18–20.

[86]Bae, S. H., Sarkis, J., Yoo, C. S., "Greening transportation fleets: Insights from a two-stage game theoretic model", Transportation Research Part E: Logistics and Transportation Review, Vol. 47, No. 6, 2011, str. 793–807.

[87]Celebi, D. *et al.*, "Planning a mixed fleet of electric and conventional vehicles for urban freight with routing and replacement considerations", Sustainable Cities and Society, Vol. 73, 2021, str. 103105.

[88]Mouhrim, N., Alaoui, A. E. H., Boukachour, J., "Vehicle routing problem with mixed fleet of electric and conventional vehicles under emissions allowances", in 2018 4th International Conference on Logistics Operations Management (GOL). IEEE, 2018, str. 1–5.

[89]Balaji, P. G., Srinivasan, D., An Introduction to Multi-Agent Systems. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, str. 1–27, dostupno na: https://doi.org/10.1007/978-3-642-14435-6_1

[90]Podobnik, V., Lovrek, I., "An agent-based platform for ad-hoc social networking", in KES International Symposium on Agent and Multi-Agent Systems: Technologies and Applications. Springer, 2011, str. 74–83.

[91]Podobnik, V., Lovrek, I., "Multi-agent system for automation of b2c processes in the future internet", in IEEE INFOCOM Workshops 2008. IEEE, 2008, str. 1–4.

[92]Sujil, A., Verma, J., Kumar, R., "Multi agent system: concepts, platforms and applications in power systems", Artificial Intelligence Review, Vol. 49, No. 2, 2018, str. 153–182.

[93]Bellifemine, F., Bergenti, F., Caire, G., Poggi, A., Jade — A Java Agent Development Framework. Boston, MA: Springer US, 2005, str. 125–147, dostupno na: https://doi.org/10.1007/0-387-26350-0_5

[94]Kuklová, J., "Highway modeling in anylogic for multi-agent approach to smart city management", in 2021 Smart City Symposium Prague (SCSP), 2021, str. 1-6.

[95]Wang, Z., Paranjape, R., "An evaluation of electric vehicle penetration under demand response in a multi-agent based simulation", in 2014 IEEE Electrical Power and Energy Conference, 2014, str. 220-225.

[96]Lin, H., Liu, Y., Sun, Q., Xiong, R., Li, H., Wennersten, R., "The impact of electric vehicle penetration and charging patterns on the management of energy hub – a multi-agent system simulation", Applied Energy, Vol. 230, 2018, str. 189-206, dostupno na: https://www.sciencedirect.com/science/article/pii/S0306261918312327

[97]Ren, L., Fan, X., Cui, J., Shen, Z., Lv, Y., Xiong, G., "A multi-agent reinforcement learning method with route recorders for vehicle routing in supply chain management", IEEE Transactions on Intelligent Transportation Systems, 2022.

[98]Tesfatsion, L., "Agent-based computational economics: modeling economies as complex adaptive systems", Information Sciences, Vol. 149, No. 4, 2003, str. 262–268.

[99]Vidal, T., Laporte, G., Matl, P., "A concise guide to existing and emerging vehicle routing problem variants", European Journal of Operational Research, Vol. 286, No. 2, 2020, str. 401–416.

[100]Marrekchi, E., Besbes, W., Dhouib, D., "An overview of the recent solution approaches in the green vehicle routing problem", Solving Transport Problems: Towards Green Logistics, 2019, str. 115–133.

[101]Bruglieri, M., Mancini, S., Pezzella, F., Pisacane, O., "A path-based solution approach for the green vehicle routing problem", Computers & Operations Research, Vol. 103, 2019, str. 109–122.

[102]Hulagu, S., CELIKOGLU, H. B., "A multiple objective formulation of an electric vehicle routing problem for shuttle bus fleet at a university campus", in 2019 6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS), 2019, str. 1-5.

[103]Bruni, M., Jabali, O., Khodaparasti, S., "The electric vehicle route planning problem with energy consumption uncertainty", in 2020 Forum on Integrated and Sustainable Transportation Systems (FISTS), 2020, str. 224-229.

[104]Sweda, T. M., Dolinskaya, I. S., Klabjan, D., "Adaptive routing and recharging policies for electric vehicles", Transportation Science, Vol. 51, No. 4, 2017, str. 1326–1348.

[105]Jung, J., Chow, J. Y., "Effects of charging infrastructure and non-electric taxi competition on electric taxi adoption incentives in new york city", Transportation Research Record, Vol. 2673, No. 4, 2019, str. 262–274.

[106]Fraile-Ardanuy, J., Castano-Solis, S., Álvaro-Hermana, R., Merino, J., Castillo, Á., "Using mobility information to perform a feasibility study and the evaluation of spatio-

temporal energy demanded by an electric taxi fleet", Energy conversion and management, Vol. 157, 2018, str. 59–70.

[107]Brandstätter, G., Gambella, C., Leitner, M., Malaguti, E., Masini, F., Puchinger, J., Ruthmair, M., Vigo, D., "Overview of optimization problems in electric car-sharing system design and management", in Dynamic perspectives on managerial decision making. Springer, 2016, str. 441–471.

[108]Fanti, M. P., Mangini, A. M., Pedroncelli, G., Ukovich, W., "Fleet sizing for electric car sharing system via closed queueing networks", in 2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC). IEEE, 2014, str. 1324–1329.

[109]Brandstätter, G., Kahr, M., Leitner, M., "Determining optimal locations for charging stations of electric car-sharing systems under stochastic demand", Transportation Research Part B: Methodological, Vol. 104, 2017, str. 17–35.

[110]Baldacci, R., Mingozzi, A., Roberti, R., "Recent exact algorithms for solving the vehicle routing problem under capacity and time window constraints", European Journal of Operational Research, Vol. 218, No. 1, 2012, str. 1–6.

[111]Desrochers, M., Desrosiers, J., Solomon, M., "A new optimization algorithm for the vehicle routing problem with time windows", Operations research, Vol. 40, No. 2, 1992, str. 342–354.

[112]Gallo, G., Pallottino, S., "Shortest path algorithms", Annals of operations research, Vol. 13, No. 1, 1988, str. 1–79.

[113]Belikov, E., Afonichkina, P., "Research of modern routing systems", in 2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus). IEEE, 2021, str. 225–228.

[114]Shafique, U., Qaiser, H., "A comparative study of data mining process models (kdd, crisp-dm and semma)", International Journal of Innovation and Scientific Research, Vol. 12, No. 1, 2014, str. 217–222.

[115]Liaw, A., Wiener, M. *et al.*, "Classification and regression by randomforest", R news, Vol. 2, No. 3, 2002, str. 18–22.

[116]"State of data science and machine learning 2020", dostupno na: https://www.kaggle.com/kaggle-survey-2020 2020.

[117]Hancock, J. T., Khoshgoftaar, T. M., “Catboost for big data: an interdisciplinary review”, Journal of Big Data, Vol. 7, No. 1, Nov 2020, dostupno na: http://dx.doi.org/10.1186/s40537-020-00369-8

[118]Huang, G., Wu, L., Ma, X., Zhang, W., Fan, J., Yu, X., Zeng, W., Zhou, H., “Evaluation of catboost method for prediction of reference evapotranspiration in humid regions”, Journal of Hydrology, Vol. 574, 2019, str. 1029 - 1041, dostupno na: http://www.sciencedirect.com/science/article/pii/S0022169419304251

[119]Pevec, D., Babic, J., Kayser, M. A., Carvalho, A., Ghiassi-Farrokhfal, Y., Podobnik, V., “A data-driven statistical approach for extending electric vehicle charging infrastructure”, International journal of energy research, Vol. 42, No. 9, 2018, str. 3102–3120.

[120]Zhang, W., Gao, F., Sun, S., Yu, Q., Tang, J., Liu, B., “A distribution model for shared parking in residential zones that considers the utilization rate and the walking distance”, Journal of advanced transportation, Vol. 2020, 2020.

[121]Turner, C. R., Fuggetta, A., Lavazza, L., Wolf, A. L., “A conceptual basis for feature engineering”, Journal of Systems and Software, Vol. 49, No. 1, 1999, str. 3–15.

[122]Bishop, C. M., Pattern recognition and machine learning. springer, 2006.

[123]Zheng, A., Casari, A., Feature engineering for machine learning: principles and techniques for data scientists. " O’Reilly Media, Inc.", 2018.

[124]Cerda, P., Varoquaux, G., “Encoding high-cardinality string categorical variables”, IEEE Transactions on Knowledge and Data Engineering, 2020, dostupno na: https://hal.inria.fr/hal-02171256

[125]Barten, A. P., “The coefficient of determination for regression without a constant term”, in The Practice of Econometrics. Springer, 1987, str. 181–189.

[126]Chai, T., Draxler, R. R., “Root mean square error (rmse) or mean absolute error (mae)?–arguments against avoiding rmse in the literature”, Geoscientific model development, Vol. 7, No. 3, 2014, str. 1247–1250.

[127]Babic, J., Podobnik, V., “A review of agent-based modelling of electricity markets in future energy eco-systems”, in 2016 International Multidisciplinary Conference on Computer and Energy Science (SpliTech). IEEE, 2016, str. 1–9.

[128]Kuklová, J., “Highway modeling in anylogic for multi-agent approach to smart city management”, in 2021 Smart City Symposium Prague (SCSP). IEEE, 2021, str. 1–6.

[129]Liang, H., Ren, J., Lin, R., Liu, Y., "Alternative-fuel based vehicles for sustainable transportation: A fuzzy group decision supporting framework for sustainability prioritization", Technological Forecasting and Social Change, Vol. 140, 2019, str. 33–43.

[130]Hamurcu, M., Eren, T., "Strategic planning based on sustainability for urban transportation: An application to decision-making", Sustainability, Vol. 12, No. 9, 2020, str. 3589.

[131]Qian, Z., Yi, Z., Zhong, W., Yue, H., Yaojia, S., "Siting and sizing of electric vehicle fast-charging station based on quasi-dynamic traffic flow", IET Renewable Power Generation, Vol. 14, No. 19, 2021, str. 4204–4214.

[132]Vdovic, H., Babic, J., Podobnik, V., "Eco-efficient driving pattern evaluation for sustainable road transport based on contextually enriched automotive data", Journal of Cleaner Production, Vol. 311, 2021, str. 127564.

[133]"Introducing lynx charge - an electric street sweeper", dostupno na: https://rasco.hr/en/news/electric-street-sweeper/ Oct 2021.

Popis oznaka

CV_{EC} Kapacitet vodenog spremnika električne čistilice

C_P Kapacitet parkirališta

F_{EVSE} Format kojem pripada priključak električne punionice

I_p Indikator za potrebu punjenja baterije električnog vozila

PCU_{EC} Snaga četke usisivača električne čistilice

PV_{EC} Snaga ventilatora električne čistilice

R_v Razina vode u vodenom spremniku električne čistilice

S_{EVSE} Standard kojem pripada priključak električne punionice

TP_{EVSE} Tip snage kojem pripada priključak električne punionice

lat Geografska širina

lng Geografska dužina

C_{BEV} Kapacitet baterije električnog vozila

D_{EV} Domet električnog vozila

P_{EV} Punionica koja je dodijeljena električnom vozilu

PM_{EV} Snaga motora električnog vozila

R_{BEV} Razina baterije električnog vozila

Wh_{BEV} Radni stati baterije električnog vozila

Z_{EV} Zadatak koji je dodijeljen električnom vozilu

Životopis

Goran Jelen rođen je 1990. godine u Varaždinu. Godine 2012. diplomirao je računarstvo na Fakultetu elektrotehnike i računarstva (FER) Sveučilišta u Zagrebu. Obrazovanje je nastavio na diplomskom studiju istog fakulteta te je 2014. godine stekao mag. ing. stupanj iz područja Informacijske i komunikacijske tehnologije (IKT). Godine 2014. upisuje doktorski studij računarstva na istome fakultetu.

Godine 2014. počinje raditi u Ericsson Nikola Tesli kao razvojni programer, gdje je radio na projektima vezanim uz IKT rješenja u zdravstvu i Machine-to-Machine rješenjima za automobilsku industriju. Od 2018. godine karijeru nastavlja u Infoartu. U Infoartu je na početku radio u području rješenja za parkiranje i punjenje električnih vozila kao stariji razvojni konzultant u PayByPhoneu (u vlasništvu Volkswagen Financial Services AG), gdje je isporučivao softverska rješenja na globalnoj razini. Softverska rješenja odnosila su se na plaćanje i pružanje usluga, te analizu podataka parkiranja i punjenja električnih vozila. Zajedno s radom u "Laboratoriju za društveno umrežavanje i društveno računarstvo (socialLAB)" na FER-u kao vanjski suradnik, stekao je potrebnu stručnost za svoj doktorski rad.

Jelen je dobitnik prve (2012.) i treće (2013.) nagrade Ericsson Nikola Tesla za najbolji studentski rad u području IKT-a. Objavio je 2 znanstvena rada u zbornicima konferencija te 1 u časopisima. Jelen je trenutno stariji razvojni programer u Infoartu gdje radi na parkirališnim sustavima i sustavima za punjenje električnih vozila dostupnim u Europi i šire.

Popis objavljenih djela

Rad u časopisima

1.Jelen, G., Podobnik, V., Babi ć, J., "Contextual prediction of parking spot availability: A step towards sustainable parking", Journal of Cleaner Production, 312 (2021), 127684, DOI: 10.1016/j.jclepro.2021.127684

2.Jelen, G., Babi ć, J., Podobnik, V., "A multi-agent system for context-aware electric vehicle fleet routing: A step towards more sustainable urban operations", Journal of Cleaner Production, 374 (2022), 134047, DOI: 10.1016/j.jclepro.2022.134047

Rad u zbornicima konferencija (međunarodno recenzirano i usmeno izlaganje)

1.Jelen, G., Podobnik, V., Babi ć, J., "Parking Lot Profiling Analysis: the City of Split Use Case", 2020 5th International Conference on Smart and Sustainable Technologies (SpliTech), Split, IEEE, 2020, str. 1-7, DOI: 10.23919/SpliTech49282.2020.9243764

2.Jelen, G., Babi ć, J., Podobnik, V., "Contextual Prediction of On-Street and Off-Street Parking Lot Utilisation: An Opening Gate Towards Sustainable Parking", 2021 6th International Conference on Smart and Sustainable Technologies (SpliTech), Split, IEEE, 2021, str. 1-6, DOI: 10.23919/SpliTech52315.2021.9566384

Biography

Goran Jelen was born in 1990 in Varaždin. In 2012, he received his Bachelor's degree in Computing from the Faculty of Electrical Engineering and Computing (FER) at the University of Zagreb. He continued his education through Information and Communication Technology (ICT) programme at FER, where he received his Master's degree in 2014. In 2014, he started his PhD in computer science at FER.

In 2014, he joined Ericsson Nikola Tesla as a software developer, where he worked on projects related to ICT-enabled healthcare solutions and machine-to-machine solutions for the automotive industry. From 2018, he continued his career at Infoart. At Infoart he worked in the field of parking and charging solutions for electric vehicles as a Senior Consultant at PayByPhone (owned by Volkswagen Financial Services AG), where he delivered software solutions globally. The software solutions were related to payment, service delivery and data analysis of parking and electric vehicle charging. Together with his work in the "Social Networking and Computing laboratory (socialLAB)" at FER as a Research Associate, he gained the necessary expertise for his PhD thesis.

Jelen was awarded the first (2012) and third place (2013) of the Ericsson Nikola Tesla Award for the best student paper in ICT. He published 2 conference papers and 1 journal paper. Currently, Jelen is a senior developer in Infoart working on parking and electric vehicle charging solutions provided in Europe and beyond.