

Modeliranje i optimalno punjenje flote električnih dostavnih vozila

Škugor, Branimir

Doctoral thesis / Disertacija

2016

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

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:848548>

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

Download date / Datum preuzimanja: **2025-01-03**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)





Sveučilište u Zagrebu

Fakultet strojarstva i brodogradnje

Branimir Škugor

**MODELIRANJE I OPTIMALNO
PUNJENJE FLOTE ELEKTRIČNIH
DOSTAVNIH VOZILA**

DOKTORSKI RAD

Zagreb, 2016.



Sveučilište u Zagrebu

Fakultet strojarstva i brodogradnje

Branimir Škugor

**MODELIRANJE I OPTIMALNO
PUNJENJE FLOTE ELEKTRIČNIH
DOSTAVNIH VOZILA**

DOKTORSKI RAD

Mentor: prof. dr. sc. Joško Deur

Zagreb, 2016.



Sveučilište u Zagrebu

Faculty of Mechanical Engineering and Naval Architecture

Branimir Škugor

MODELLING AND OPTIMAL CHARGING OF AN ELECTRIC DELIVERY VEHICLE FLEET

DOCTORAL THESIS

Supervisor: Joško Deur, PhD, Full Professor

Zagreb, 2016

Podaci za bibliografsku karticu

UDK:	629.33:62-83
Ključne riječi:	Električna vozila, upravljanje, flota, modeliranje, vozni ciklusi, optimiranje punjenja, dinamičko programiranje.
Znanstveno područje:	Tehničke znanosti
Znanstveno polje:	Strojarstvo
Institucija:	Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje
Mentor:	prof. dr. sc. Joško Deur
Broj stranica:	203
Broj slika:	101
Broj tablica:	29
Broj korištenih bibliografskih jedinica:	99
Datum obrane:	4.10.2016.
Povjerenstvo:	dr. sc. Joško Petrić, red. prof., predsjednik (Fakultet strojarstva i brodogradnje, Zagreb) dr. sc. Joško Deur, red. prof., mentor (Fakultet strojarstva i brodogradnje, Zagreb) dr. sc. Josip Kasać, izv. prof., član (Fakultet strojarstva i brodogradnje, Zagreb) dr. sc. Goran Krajačić, doc., član (Fakultet strojarstva i brodogradnje, Zagreb) dr. sc. Stjepan Bogdan, red. prof., član (Fakultet elektrotehnike i računarstva, Zagreb)
Institucija u kojoj je rad pohranjen:	Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Nacionalna i sveučilišna knjižnica u Zagrebu

Podaci o mentoru

Joško Deur rođen je 1966. godine u Zadru. Diplomirao je 1989. godine na Elektrotehničkom fakultetu Sveučilišta u Zagrebu, smjer Automatika. Na istom je Fakultetu magistrirao 1993. i doktorirao 1999. godine.

Od svibnja 1990. godine uposlen je na Zavodu za robotiku i automatizaciju proizvodnih sustava, Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu. U zvanje redovitog profesora izabran je 2012. godine. Nakon jednogodišnjeg znanstvenog usavršavanja u istraživačkom centru tvrtke Ford Motor Company u Dearbornu, SAD (2000), uspostavio je široku suradnju s tvrtkama Ford Motor i Jaguar Cars kroz više od deset znanstveno-istraživačkih projekata na području modeliranja i regulacije automobilskih sustava. Bio je voditelj dva znanstvena projekta ugovorena s Ministarstvom znanosti, obrazovanja i športa, i jednog istraživačkog projekta financiranog od strane Hrvatske zaklade za znanost. Autor je jedne znanstvene knjige, 4 poglavlja u knjizi, 29 radova u CC/SCI časopisima, 21 rad u drugim časopisima, 104 rada u zbornicima skupova s međunarodnom recenzijom, tri patenta te brojnih studija i izvještaja.

Prof. Deur je član društava KoREMA, IEEE, SAE i IFAC, te IFAC "Technical Committee 7.1 Automotive Control" i "IEEE Technical Committee on Automotive Control". Član je uređivačkog odbora dvaju časopisa. Dobitnik je Državne nagrade za znanost za značajno znanstveno dostignuće u području tehničkih znanosti 2006. godine, te srebrne plakete "Josip Lončar" za izrazito uspješnu doktorsku disertaciju. Govori engleski i služi se njemačkim jezikom.

Zahvale

Prije svega zahvaljujem se mentoru prof. dr. sc. Jošku Deuru na iznimnom strpljenju i mnogim sugestijama tijekom vođenja ovog rada, te na motivaciji koja mi je pomogla da taj put prođem s najvećim entuzijazmom.

Zahvaljujem se članovima povjerenstva, prof. dr. sc. Jošku Petriću, izv. prof. dr. sc. Josipu Kasaću, doc. dr. sc. Goranu Krajačiću, te prof. dr. sc. Stjepanu Bogdanu na korisnim komentarima i sugestijama na ovaj rad. Profesoru Bogdanu dugujem zahvalnost i na strpljivom mentorstvu tijekom izrade diplomskog rada, kojim me je potakao na istraživački način razmišljanja.

Zahvaljujem se kolegama izv. prof. dr. sc. Danijelu Pavkoviću, mag. ing. Mirku Čoriću, mag. ing. Vanji Ranogajecu, te dr. sc. Mihaelu Cipeku na suradnji i izvrsnim diskusijama tijekom izrade ovog rada.

Zahvaljujem se Hrvatskoj zakladi za znanost koja je financijski podržala projekt "ICT-podržana integracija električnih vozila u energetske sustave s visokim udjelom obnovljivih izvora energije", u okviru kojeg je nastao ovaj rad.

Zahvaljujem se tvrtki Konzum te posebice njenim inženjerima Dinku Crkvencu i Ivici Pivaru za omogućenje snimanja i prikupljanja podataka na Konzumovoj floti dostavnih vozila, a koji su bitno doprinijeli kvaliteti ovog rada.

Posebno se zahvaljujem svojim roditeljima, bratu i sestri na bezuvjetnoj ljubavi i podršci tijekom cjelokupnog školovanja. Zahvaljujem se također ostaloj široj obitelji i prijateljima, te posebno stričevima koji su mi dali prve poticaje i ohrabrenje da zakoračim u tehničku struku.

Na kraju bih se zahvalio najdražoj djevojci Josipi koja je bila cilj ovog, te ujedno i početak novog puta.

Zagreb, rujan 2016.

Branimir Škugor

*„... a što bih jedino potomcima htio namrijeti u baštinu
bila bi: VEDRINA. Kristalna kocka vedrine...“*

Tin Ujević

Sažetak

Sa stanovišta elektroenergetske mreže, električna vozila (EV) predstavljaju prostorno-distribuirano baterijsko skladište električne energije, koje se u okviru naprednog punjenja EV može iskoristiti za razne primjene poput poravnjanja opterećenja mreže. Kako bi se ispitala isplativost elektrifikacije ciljane flote vozila i njen utjecaj na električnu mrežu, potrebno je provesti optimiranje punjenja odgovarajuće flote EV primjenom prikladnih optimizacijskih postupaka temeljenih na preciznim i računalno-učinkovitim modelima flote EV, a što predstavlja glavni cilj ovog rada.

U radu je predložen novi agregatni model flote EV koji je validiran u odnosu na precizniji, ali i računalno neučinkovitiji, distribuirani model. Pritom je optimiranje punjenja, za svaki od modela, provedeno korištenjem algoritma dinamičkog programiranja (DP), koji za opći nelinearni optimizacijski problem garantira globalno optimalne rezultate. Cilj optimiranja je minimizacija cijene električne energije koja se koristi za punjenje flote EV uz zadovoljenje ograničenja vezanih uz stanje napunjenosti (SoC) baterije te snagu punjenja. Osim jednorazinskog DP optimiranja punjenja, predloženo je i dvorazinsko optimiranje gdje se jednorazinsko DP optimiranje proširuje nadređenom razinom, na kojoj se korištenjem genetskog algoritma dodatno optimira maksimalna snaga punjača, te vrijednost SoC-a na početku svakog voznog ciklusa s ciljem minimizacije operativnih troškova flote EV.

U svrhu parametriranja i validiranja predloženog agregatnog modela flote EV, postavljen je model električnog vozila s proširenim dometom (EREV) te je predložena pripadna upravljačka strategija pogona. Upravljačka strategija EREV pogona temelji se na regulatoru zasnovanom na bazi pravila (RB), koji se kombinira sa strategijom minimizacije ekvivalentne potrošnje goriva (ECMS). Pritom se održivost SoC-a baterije postiže SoC regulatorom koji je sadržan u RB regulatoru, dok se ECMS-om postiže optimalnost radnih točaka motora s unutarnjim izgaranjem. Predložena upravljačka strategija ispitana je simulacijski, te usporedbom rezultata simulacija s globalno optimalnim rezultatima dobivenima DP optimiranjem upravljačkih varijabli pogona za razne vozne cikluse.

Također su pribavljeni i analizirani podaci o voznim ciklusima konkretne flote dostavnih vozila i o energetsom sustavu pripadnog distributivnog centra. Za potrebe parametriranja

modela flote, provedene su simulacije razvijenog EREV modela preko snimljenih voznih ciklusa te preko sintetičkih voznih ciklusa koji statistički vjerno reprezentiraju polazni skup snimljenih voznih ciklusa. Konačno, na temelju razvijenih alata provedena je pilot studija vezana uz ispitivanje mogućnosti elektrifikacije spomenute flote dostavnih vozila za različite scenarije udjela obnovljivih izvora energije i vremenske razdiobe cijene električne energije.

Ključne riječi: električna vozila, upravljanje, flota, modeliranje, vozni ciklusi, optimiranje punjenja, dinamičko programiranje

Extended summary

Electric vehicles (EV) are recognized as a technology which will gradually replace the existing conventional vehicles propelled by internal combustion engines. This is important from the standpoint of reducing the driving-related energy consumption and cutting the emissions of greenhouse gases and other pollutants. Furthermore, EVs containing an ample energy storage (usually electrochemical batteries), represent a spatially-distributed energy storage convenient for providing various ancillary services to electric grid and supporting proliferation of renewable energy sources (RES). In order to thoroughly investigate benefits of replacing the conventional vehicles with the electric ones (including energy planning studies), it is crucial to develop precise transport-energy models and use different optimisation techniques to reveal optimal structure, parameters, and management of a considered transport-energy system.

In order to facilitate optimisations of integrated transport-energy systems including EV fleet charging management strategies, individual EVs are modelled in this thesis by means of a single aggregate battery, which is validated against a more realistic, although more complex, distributed EV fleet model. The aggregate battery model is parameterised based on several EV fleet-related input time distributions, such as average state-of-charge (SoC) time distributions of EVs connecting to and disconnecting from the electric grid, which are obtained by means of simulations of a developed individual EV model including its control strategy. The EV fleet battery charging can generally be managed based on the use of various optimisation algorithms, such as dynamic programming (DP) algorithm, linear or nonlinear programming, mixed integer linear programming, stochastic dynamic programming and heuristic optimisation algorithms. The DP-based charging management optimisation is proposed herein due to its inherent feature of resulting in globally optimal results for the general problem of nonlinear system model with nonlinear constraints. Finally, the developed EV fleet models and related charging management techniques are used to conduct a case study of electrification of a particular delivery vehicle fleet for different levels of local RES penetration.

The main aim of the thesis is to establish a systematic approach to modelling and optimal

control of transport-energy system with EVs and RES, which includes development of models and optimal control strategies for individual EVs of different types, as well as models and charging management strategies for EV fleets.

The thesis is organised in seven chapters, whose content is summarised in what follows.

Chapter 1 “Introduction” outlines the motivation for the conducted research, presents the literature overview, and provides the main hypothesis and an overview of the thesis.

Chapter 2 “Modelling and control of an extended range electric vehicle” (EREV) describes the quasi-static modelling of a complex series-parallel EREV configuration and proposes a practical and nearly-optimal control strategy for its powertrain. The control strategy relies on a rule-based (RB) controller which is smoothly combined with an optimal equivalent consumption minimisation strategy (ECMS), where the RB controller ensures sustainable battery charge, while the ECMS ensures optimal selection of the powertrain operating point. In addition, DP-based control variable optimisation is conducted for several characteristic driving cycles in order to gain an insight into the powertrain optimal behaviour and facilitate the feedback control strategy design. The DP optimisation results also serve as a benchmark for the control strategy verification.

Chapter 3 “Analysis and synthesis of driving cycles” deals with experimental characterisation and analysis of delivery vehicle fleet system of a regional retail company. The vehicle data have been collected for a fleet of ten delivery vehicles running continuously over a three month period. Next, a detailed statistical analysis of the collected data is presented, in order to provide a basis for future investigation of possible benefits of replacing the conventional vehicle fleet with a hypothetical one based on electric vehicles. Finally, the recorded large set of driving cycles is used for the purpose of Markov chain-based synthesis and validation of a small number of representative driving cycles. Such naturalistic driving cycles are used in Chapter 5 for transport energy demand modelling as a part of optimal EV fleet charging management strategy.

Chapter 4 “Electric vehicle fleet modelling” proposes an aggregate battery modelling approach for an electric vehicle (EV) fleet, which is aimed for energy planning studies of EV-grid integration, as well as for the design of a EV fleet charging management strategy. The

proposed approach improves on the existing, basic aggregate battery modelling approach by accounting for a variable structure of the aggregate battery system (due to vehicle connection/disconnection), including variable state of charge (SoC) constraints and specific time-varying input time-distributions such as those related to average vehicle SoC when arriving to the distribution centre and number of arriving and departing vehicles. The model input distributions are reconstructed from a large set of data related to delivery vehicle fleet driving missions, as well as from results of simulation of individual EVs over the full set of recorded driving cycles. The aggregate charging power input is obtained by using a DP-based optimisation algorithm aimed at finding a global optimum in terms of minimal charging electricity cost. For the purpose of proposed model validation and its comparison with the basic model, a distributed fleet vehicle model is developed and accompanied with a computationally efficient, heuristic algorithm for distributing the optimised aggregate charging power input to charging inputs of individual EVs.

Chapter 5 “Electric vehicle fleet charging optimisation” proposes a DP-based optimisation method of charging an EV fleet described by the aggregate battery model. The main advantage of the proposed approach is that it provides a globally optimal solution, with a relatively non-excessive computational load owing to a low order of the aggregate battery model. In the case of distributed (agent-based) EV fleet model, DP is conducted separately for each EV in successive manner to provide an acceptable computational load, which results in nearly-optimal results in the general case of charging power constraints. The DP charging optimisation approaches are illustrated through a case study of electrified delivery vehicle transport system charged both from the grid and local RES (solar panels). Two scenarios of energy production from RES (with and without excess in RES production), along with several electricity price models are studied. In the case of distributed fleet model, the DP optimisations are conducted and analysed for different levels of maximum charging power which can be taken from a grid. In the case of aggregate battery model, the DP optimisation results are compared with the results obtained by an existing heuristic charging algorithm used in EnergyPLAN software to illustrate the DP algorithm advantages in minimising the charging energy cost and satisfying the aggregate battery charge sustaining conditions. In addition, the single-level DP optimisation of aggregate battery charging power is extended to a bi-level optimisation, where SoC-at-departure and the maximum charging power of an

individual EV are optimised at the supervisory level by using a genetic algorithm, with the aim to minimise the operational cost for different charger power levels.

Chapter 6 “Analysis of techno-economic aspects of delivery vehicle fleet electrification” integrates the methods and numerical tools developed in the previous chapters through a pilot study of designing and analysing a transport-energy system containing a delivery EV fleet and production from local RES. The considered EV fleet is based on series-configuration EREV trucks of comparable speed and torque characteristics as the existing conventional trucks. The overall transport-energy system model also includes prediction of hourly consumption of electricity within the distribution centre and RES production. The analysis compares the electrified delivery vehicle fleet with the conventional one in terms of the total energy cost and the CO₂ emissions for different scenarios of grid energy production sources and local RES penetration levels.

Chapter 7 “Conclusion” outlines the main results and the following major contributions of the doctoral thesis: 1) HEV/EREV control strategy based on combining a rule-based controller with an equivalent consumption minimisation strategy; 2) EV fleet aggregate model that faithfully describes the dynamics of EV connection to the grid, and which is parameterised based on the main features of collected driving cycles; 3) dynamic programming-based charging optimisation algorithm based on the aggregate EV fleet model, and a heuristic algorithm of distributing the optimised aggregate charging power over individual EVs.

Keywords: electric vehicles, control, fleet, modelling, driving cycles, charging optimisation, dynamic programming

Sadržaj

Popis slika	V
Popis tablica	XII
Popis oznaka i kratica.....	XIV
Popis oznaka.....	XIV
Popis kratica	XXIV
1. Uvod	1
1.1. Motivacija.....	1
1.2. Dosadašnje spoznaje.....	3
1.2.1. Modeliranje i upravljanje pogonima hibridnih električnih vozila.....	3
1.2.2. Sintetički vozni ciklusi	5
1.2.3. Modeliranje i optimalno punjenje flote električnih vozila	6
1.3. Hipoteza.....	8
1.4. Pregled rada	8
2. Modeliranje i upravljanje pogonom električnog vozila proširenog dometa.....	11
2.1. Modeliranje električnog vozila proširenog dometom.....	11
2.1.1. Kinematska shema i načini rada pogona vozila	11
2.1.2. Kvizistatički model pogona vozila	13
2.1.3. Kvizistatički model baterije	16
2.1.4. Modeliranje uzdužne dinamike vozila	17
2.2. Optimiranje upravljačkih varijabli pogona.....	19
2.2.1. Osnovno o dinamičkom programiranju (DP).....	19
2.2.2. Formulacija optimizacijskog problema za CD režim rada	22
2.2.3. Formulacija problema optimiranja za CS i kombinirani režim rada	23
2.3. Upravljačka strategija pogona	24
2.3.1. Struktura sustava upravljanja	24
2.3.2. Određivanje optimalnog načina rada pogona	25
2.3.3. Upravljačka strategija za CD režim rada.....	30
2.3.4. Upravljačka strategija za CS režim rada	31

2.3.5. Upravljačka strategija za kombinirani način rada	36
2.4. Simulacijska provjera sustava upravljanja	41
2.4.1. CD režim rada	41
2.4.2. CS režim rada	44
2.4.3. Kombinirani (BLND) režim rada	47
3. Analiza i sinteza voznih ciklusa	53
3.1. Prikupljanje, obrada i analiza voznih ciklusa flote vozila	53
3.1.1. Opis transportnog sustava.....	53
3.1.2. Prikupljanje i početna obrada podataka.....	53
3.1.3. Statistička obrada podataka	56
3.2. Sinteza voznih ciklusa	63
3.2.1. Klasteriranje voznih ciklusa	64
3.2.2. Određivanje matrice prijelaznih vjerojatnosti	65
3.2.3. Generiranje sintetičkih voznih ciklusa	68
3.2.4. Validacija sintetičkih voznih ciklusa	71
3.2.5. Sinteza voznih ciklusa za potrebe modeliranja zahtjeva transporta za energijom	74
4. Modeliranje flote električnih vozila	79
4.1. Modeli flote električnih vozila	79
4.1.1. Osnovni agregatni model flote vozila	79
4.1.2. Napredni agregatni model flote vozila	81
4.1.3. Distribuirani model flote vozila.....	82
4.2. Parametriranje modela flote vozila.....	83
4.2.1. Razdiobe vezane uz broj parkiranih vozila spremnih za punjenje	83
4.2.2. Razdiobe vezane uz zahtjev transporta za energijom.....	84
4.3. Algoritmi upravljanja punjenjem flote EV	87
4.3.1. Optimiranje punjenja EV flote primjenom dinamičkog programiranja	87
4.3.2. Raspodjela agregatne snage punjenja po pojedinačnim vozilima	90
4.4. Validacija predloženih modela flote vozila	96
4.4.1. Validacija modela temeljena na realističnim ulaznim razdiobama.....	96
4.4.2. Validacija modela temeljena na dodatnim ulaznim razdiobama	100
5. Optimiranje punjenja flote električnih vozila	105

5.1. Dodatne razdiobe potrebne kod optimiranja punjenja flote	105
5.1.1. Razdiobe vezane uz proizvodnju električne energije iz obnovljivih izvora energije (OIE)	105
5.1.2. Razdioba potrošnje električne energije potrošača unutar distributivnog centra..	107
5.2. Optimiranje punjenja temeljem distribuiranog modela flote.....	108
5.2.1. DP optimiranje punjenja pojedinačnog električnog vozila.....	108
5.2.2. DP optimiranje punjenja flote električnih vozila.....	111
5.3. Optimiranje punjenja temeljem agregatnog modela flote EV	113
5.3.1. Heuristički postupak punjenja flote EV	113
5.3.2. DP optimiranje punjenja temeljem agregatnog modela flote EV	113
5.3.3. Dvorazinsko optimiranje punjenja temeljem agregatnog modela flote.....	117
5.4. Rezultati optimiranja punjenja	123
5.4.1. Rezultati optimiranja temeljenog na distribuiranom modelu flote EV	123
5.4.2. Usporedba rezultata heurističkog načina punjenja i DP optimalnog punjenja dobivenih korištenjem agregatnog modela flote	128
5.4.3. Rezultati optimiranja dobiveni korištenjem dvorazinskog optimiranja	135
6. Analiza tehno-ekonomskih aspekata elektrifikacije flote dostavnih vozila	139
6.1. Konvencionalno dostavno vozilo	139
6.1.1. Model konvencionalnog dostavnog vozila.....	139
6.1.2. Validacija modela konvencionalnog dostavnog vozila.....	143
6.2. Dostavno električno vozilo proširenog dometa.....	144
6.2.1. Modeliranje i dimenzioniranje pogona.....	145
6.2.2. Upravljanje pogonom	149
6.3. Rezultati simulacija i optimiranja punjenja flote električnih dostavnih vozila	151
6.3.1. Usporedna analiza rezultata simulacije pojedinačnih modela vozila	152
6.3.2. Usporedna analiza operativnih troškova te emisija štetnih plinova na razini flote vozila	154
7. Zaključak	162
Literatura	169
Prilozi	176
Prilog A – Parametri pogona električnih vozila proširenog dometa (EREV).....	176

Prilog B – Nelinearni agregatni model flote električnih vozila	177
Prilog C – Detalji vezani uz računanje limita energije punjenja pojedinačnih vozila	189
Prilog D – Definicija korelacijskog pokazatelja	190
Prilog E – Generiranje ulaznih razdioba modela flote EV korištenjem Monte Carlo postupka	191
Prilog F – Parametri DP optimiranja punjenja flote EV.....	195
Prilog G – Heuristički pristup punjenju flote EV.....	196
Životopis.....	199
Curriculum vitae.....	203

Popis slika

<i>Slika 2-1: Funkcionalna shema EREV pogona.</i>	12
<i>Slika 2-2: Ilustracija CD-CS i kombiniranog (BLND) režima rada EREV pogona.</i>	13
<i>Slika 2-3: Blokovski dijagram kvazistatičkog modela EREV pogona.</i>	14
<i>Slika 2-4: Statičke karakteristike SUI motora (a), M/G1 stroja (b) i M/G2 stroja (c).</i>	15
<i>Slika 2-5: Mehanički gubici transmisije u praznom hodu (a) i uslijed opterećenja vezano uz faktor korisnosti (b).</i>	16
<i>Slika 2-6: Nadomjesni električni krug baterije (a) i karakteristika napona otvorenog kruga za pretpostavljenu Li-Ion bateriju (b).</i>	17
<i>Slika 2-7: Certifikacijski vozni ciklusi korišteni u optimiranju upravljačkih varijabli i simulaciji EREV pogona.</i>	18
<i>Slika 2-8: Opća blokovska shema sustava upravljanja EREV pogonom.</i>	25
<i>Slika 2-9: Kombinirana izlazna mapa korisnosti za TMEV način rada (a), i razlika korisnosti u TMEV i EV načinu rada (b).</i>	26
<i>Slika 2-10: Zahtjev vozača za momentom (a), standardna devijacija zahtjeva vozača za momentom (b) i širina histereze EV-TMEV granične krivulje (c) za slučaj NEDC voznog ciklusa.</i>	28
<i>Slika 2-11: Optimalna područja hibridnih načina rada određenih minimiziranjem ECMS ciljne funkcije (a), i optimalni načini rada u izlaznoj mapi za US06 vozni ciklus dobiveni DP optimiranjem.</i>	30
<i>Slika 2-12: Načini rada i pripadna 2D područja u izlaznoj mapi za CD (a) i CS režim rada (b).</i>	30
<i>Slika 2-13: Blokovski dijagram kombiniranog RB i 1D-ECMS regulatora.</i>	32
<i>Slika 2-14: Ilustracija 1D i 2D područja ECMS optimiranja.</i>	35
<i>Slika 2-15: Blokovski dijagram RB+1D-ECMS regulatora kombiniranog s 2D-ECMS optimiranjem (a), i grafički prikaz funkcije dane s (2-32).</i>	36
<i>Slika 2-16: Optimalne SoC trajektorije u CD/CS i BLND režimu rada za slučaj NEDC, HWFET, UDDS i US06 ponavljajućih voznih ciklusa dobivene DP optimiranjem.</i>	37
<i>Slika 2-17: Razdioba pragova isključivanja (a) i pragova uključivanja (b) SUI motora, dobivenih iz DP optimizacija za slučaj BLND režima rada i kombiniranog i ponavljajućeg NEDC, HWFET, UDDS i US06 voznog ciklusa (vidi legendu tablice 2-3).</i>	38

<i>Slika 2-18: Referentne i ostvarene SoC trajektorije (a), i razdioba radnih točaka u mapi SUI motora za slučaj inicijalne upravljačke strategije (RB+ECMS1) i 17xNEDC voznog ciklusa.</i>	<i>40</i>
<i>Slika 2-19: Simulacijski rezultati za CD režim rada za slučaj samo EV načina rada i kombiniranog EV i TMEV načina rada sa različitim graničnim krivuljama između EV i TMEV načina rada (b-d) u slučaju NEDC voznog ciklusa.</i>	<i>42</i>
<i>Slika 2-20: Grafička ilustracija različitih rezultata realističnih upravljačkih strategija ostvarenih u CS režimu rada u odnosu na globalno optimalne DP rezultate za slučaj različitih voznih ciklusa.</i>	<i>45</i>
<i>Slika 2-21: Usporedba potrošnje goriva različitih realističnih upravljačkih strategija ostvarenih u CS režimu rada u odnosu na DP-optimalnu potrošnju goriva za slučaj različitih voznih ciklusa.</i>	<i>46</i>
<i>Slika 2-22: SoC trajektorije za 10 NEDC, HWFET, UDDS i US06 ponavljajućih voznih ciklusa (RB+ECMS, CS režim rada).</i>	<i>47</i>
<i>Slika 2-23: Radne točke SUI motora za slučaj 10 NEDC, 10 HWFET, 10 UDDS te 10 US06 ponavljajućih voznih ciklusa (RB+ECMS, CS režim rada).</i>	<i>48</i>
<i>Slika 2-24: Referentne i ostvarene SoC trajektorije za slučaj NEDC (a), HWFET (b), UDDS (c) i US06 (d) ponavljajućih voznih ciklusa (RB+ECMS čiji su pragovi optimirani za svaki ciklus zasebno – RB+ECMS2, BLND režim rada).</i>	<i>50</i>
<i>Slika 3-1: Trajektorija vozila snimljena na međugradskoj ruti (a) i primjeri raznih snimljenih voznih ciklusa (b)-(f).</i>	<i>56</i>
<i>Slika 3-2: Vremenske razdiobe dolazaka u i odlazaka vozila iz distributivnog centra.</i>	<i>57</i>
<i>Slika 3-3: Vremenske razdiobe dolazaka u i odlazaka vozila iz jednog prodajnog centra. ...</i>	<i>58</i>
<i>Slika 3-4: Razdiobe trajanja mirovanja/parkiranosti vozila u distributivnom centru (a) i u jednom prodajnom centru (b).</i>	<i>59</i>
<i>Slika 3-5: Tjedna razdioba prosječnog broja parkiranih vozila u distributivnom centru (podaci snimljeni tijekom 91 dana usrednjeni na tjednoj vremenskoj bazi).</i>	<i>60</i>
<i>Slika 3-6: Usporedni prikaz razdioba prosječnog broja vozila parkiranih u distributivnom centru za svaki pojedini dan tjedna (a), te razdiobe usrednjene na radne dane (PON-PET) i puni tjedan (PON-NED) (b).</i>	<i>61</i>
<i>Slika 3-7: Razdioba prijeđenog puta tijekom pojedinačnih voznih ciklusa.</i>	<i>62</i>
<i>Slika 3-8: Razdiobe prosječnog broja parkiranih vozila (a) i normirani prikaz mjerene i estimirane potrošnje goriva (b).</i>	<i>63</i>
<i>Slika 3-9: Klasterirani vozni ciklusi predstavljeni geografskim lokacijama na polovini prijeđenog puta („virtualna“ destinacija) tijekom svakog voznog ciklusa (a) i vremensko trajanje klasteriranih voznih ciklusa (b).</i>	<i>65</i>
<i>Slika 3-10: Matrica prijelaznih vjerojatnosti za treći klaster voznih ciklusa sa slike 3-9b: 3D</i>	

prikaz (a) i konturni prikaz (b).	67
Slika 3-11: Normirana razdioba akceleracije svih snimljenih vozničkih ciklusa.	67
Slika 3-12: Matrica prijelaznih vjerojatnosti i pripadne pod-matrice, korištene u pristupu 2 sinteze vozničkih ciklusa.	68
Slika 3-13: Ilustracija vjerojatnosti sadržanih u retku TP matrice i poredanih na jediničnoj dužini.	69
Slika 3-14: Primjer sintetičkih vozničkih ciklusa dobivenih korištenjem pristupa 1 (diskretne vrijednosti brzine vozila su stanja Markovljevog lanca) (a) i pristupa 2 (diskretne vrijednosti brzine i akceleracije vozila su stanja Markovljevog lanca) (b) za svaki klaster snimljenih vozničkih ciklusa sa slike 3-9.	70
Slika 3-15: Normirane razdiobe značajnih statističkih parametara snimljenih vozničkih ciklusa (Rec), sintetičkih vozničkih ciklusa generiranih korištenjem pristupa 1 (Syn1) i pristupa 2 (Syn2), te kombiniranog voznog ciklusa (Comb).	73
Slika 3-16: Ovisnost značajnih statističkih parametara o trajanju snimljenih vozničkih ciklusa.	74
Slika 3-17: Ovisnost snimljene (normirane) potrošnje goriva o prijeđenom putu za sve snimljene vozne cikluse.	75
Slika 3-18: Normirane razdiobe značajnih statističkih parametara za snimljene (Rec) i sintetičke (Syn2) vozne cikluse, kao i za kombinirane (Comb) i odabrane/reprezentativne (Repr) vozne cikluse za Klaster 5.	76
Slika 3-19: Relativno odstupanje značajnih statističkih parametara (ϵ_i , $i = 1, 2, \dots, 6$) odabranih/reprezentativnih sintetičkih vozničkih ciklusa (Repr) u odnosu na odgovarajuće statističke parametre kombiniranog voznog ciklusa (Comb) za svaki klaster vozničkih ciklusa (statistički parametri: 1 – v_{mean} , 2 – v_{std} , 3 – $a_{pos,mean}$, 4 – $a_{pos,std}$, 5 – $a_{neg,mean}$, 6 – $a_{neg,std}$).	77
Slika 3-20: Validirani sintetički vozni ciklusi za osam klastera vozničkih ciklusa.	78
Slika 4-1: Vremenske razdiobe vezane uz broj vozila u distributivnom centru usrednjene na tjednoj vremenskoj bazi.	84
Slika 4-2: Vremenske razdiobe pojedinačnog zahtjeva za snagom jednog vozila (a), agregatnog zahtjeva za snagom (b) i prosječnog SoC-a vozila koja pristižu u distributivni centar prikazane na tjednoj vremenskoj bazi (c).	86
Slika 4-3: Modeli cijena električne energije korišteni u analizama (model „Cijena 1“ preuzet je s http://www.hep.hr/ , dok su ostali preuzeti s http://www.nordpoolspot.com/).	87
Slika 4-4: Detalji rezultata DP optimiranja punjenja temeljem dvaju agregatnih modela flote EV prikazani na tjednoj vremenskoj bazi i detalji istih razdioba na razini jednog radnog dana vezani uz agregatni SoC (a) i agregatnu snagu punjenja (b) (primijenjen je model cijene električne energije „Cijena 1“ sa slike 4-3).	89
Slika 4-5: Dijagram toka algoritma raspodjele agregatne snage punjenja po pojedinačnim	

vozilima.	92
Slika 4-6: <i>Ilustracija karakterističnih intervala punjenja vozila vezanih uz računanje limita energije punjenja za j-to vozilo.</i>	93
Slika 4-7: <i>Generirane i snimljene ulazne razdiobe agregatnih modela flote EV vezane uz broj parkiranih vozila i broj odlazaka i dolazaka u distributivni centar (a) i zahtjev transporta (b) usrednjene na 24-satni period.</i>	101
Slika 4-8: <i>Različiti „umjetno“ generirani modeli cijena električne energije prikazani na dnevnoj vremenskoj bazi.</i>	102
Slika 4-9: <i>Validacija agregatnih modela flote i odgovarajućih distribuiranih modela u odnosu na DP-IND rezultate za slučaj različitih iznosa maksimalne snage punjenja $P_{cmax,ind}$ i osnovni (dvotarifni) model cijene električne energije i ulaznih vremenskih razdioba modela generiranih Monte Carlo metodom (a) i različite „umjetno“ generirane modele cijena el. energije uz $P_{cmax,ind} = 10$ kW i osnovne ulazne vremenske razdiobe modela (b).</i>	103
Slika 5-1: <i>Razdioba globalne horizontalne Sunčeve iradijacije za lokaciju distributivnog centra i period od jednog dana (a), jednog tjedna (b) i tri mjeseca (c).</i>	106
Slika 5-2: <i>Procijenjene vremenske razdiobe potrošnje električne snage u distributivnom centru (P_{EL}, vidi sljedeći odjeljak) i proizvodnje snage iz solarnih panela (P_{OIE}) za dva scenarija: bez (a) i s viškom proizvedene energije iz OIE (b).</i>	106
Slika 5-3: <i>Razdioba vršnih radnih snaga potrošnje električne energije za nisku i visoku tarifu za dva dijela distributivnog centra tijekom 365 dana.</i>	107
Slika 5-4: <i>Razdiobe vršnih snaga potrošnje električne energije za nisku i visoku tarifu za dva dijela distributivnog centra (a,b), te ukupna razdioba usrednjenih vršnih snaga zajedno s korigiranom razdiobom (b).</i>	108
Slika 5-5: <i>Grafička ilustracija oznaka korištenih u modelu zahtjeva transporta temeljenog na odzivnim površinama.</i>	118
Slika 5-6: <i>Model zahtjeva transporta EREV flote temeljen na odzivnim površinama, a vezan uz SoC na dolasku u distributivni centar $SoC_{in,ind}$ (a) i potrošnju goriva V_{fuel} (b).</i>	119
Slika 5-7: <i>Dijagram toka dvorazinskog optimiranja punjenja flote EV ($\Delta SoC_{out,ind,i,j}$ – inkrement SoC-a baterije j-tog EV neposredno prije početka i-tog voznog ciklusa).</i>	123
Slika 5-8: <i>Ovisnost troška punjenja i pokazatelja kršenja ograničenja vezanih uz snagu koja se povlači iz mreže o maksimalnoj snazi koja se može povući iz mreže (koristi se dvotarifni model „Cijena 1“).</i>	124
Slika 5-9: <i>Optimalni troškovi punjenja za različite rasporede punjenja pojedinačnih EV unutar flote (crveni kružići i crveni križići označavaju minimalne/optimalne troškove punjenja; ravne linije označavaju troškove punjenja flote kad gornji limit na snagu iz mreže ne postoji).</i>	125

<i>Slika 5-10: Odzivi kumulativnog gornjeg limita snage punjenja iz mreže za slučaj sukcesivnog DP optimiranja pojedinačnih vozila ($P_{cmax,grid} = 20$ kW).....</i>	<i>127</i>
<i>Slika 5-11: Usporedni odzivi dani na 24-satnoj vremenskoj bazi dobiveni DP optimiranjem i heurističkom metodom punjenja za slučaj kad ne postoji višak proizvedene energije iz OIE (koristi se model cijene električne energije „Cijena 1“).</i>	<i>129</i>
<i>Slika 5-12: Usporedni odzivi dani na 24-satnoj vremenskoj bazi dobiveni DP optimiranjem (a) i heurističkom metodom punjenja (b) za slučaj kad postoji višak proizvedene energije iz OIE (koristi se model cijene električne energije „Cijena 1“).</i>	<i>133</i>
<i>Slika 5-13: Usporedni rezultati dobiveni DP optimiranjem i heurističkom metodom za različite površine instaliranih solarnih panela $A_{eff,PV}$.</i>	<i>134</i>
<i>Slika 5-14: Kvantifikacija kršenja ograničenja vezanog uz agregatnu snagu punjenja u odnosu na normirani trošak potrošenog goriva (a) i normirani ukupni operativni troškovi (ukupni trošak električne energije za punjenje i goriva) u odnosu na normirani trošak punjenja agregatne baterije (b) ($P_{cmax,ind} = 10$ kW).</i>	<i>136</i>
<i>Slika 5-15: Normirani ukupni operativni troškovi (C_{total}) (a) i udio voznih ciklusa odradenih u potpuno električnoj vožnji (b) u ovisnosti o gornjem limitu snage punjenja pojedinačnog EV ($P_{cmax,ind}$).</i>	<i>138</i>
<i>Slika 6-1: Dostavni kamion MAN TGM 15.240.</i>	<i>140</i>
<i>Slika 6-2: Mapa specifične potrošnje goriva SUI motora i krivulja maksimalnog momenta (a), te odgovarajući maksimalni izlazni moment na kotaču u ovisnosti o brzini vozila za različite stupnjeve prijenosa h_i, $i = 1,2,\dots,12$ (dana i karakteristika izlaznog momenta za EREV pogon) (b).</i>	<i>140</i>
<i>Slika 6-3: Razdioba prijenosnih omjera automatske transmisije rekonstruiranih iz snimljenih podataka i nominalnih diskretnih vrijednosti prijenosnih omjera (y os je skraćena radi bolje vidljivosti cjelokupnog grafa) (a), te primjer rekonstruiranog vremenskog profila mase vozila m_v tijekom jednog voznog ciklusa (b).</i>	<i>142</i>
<i>Slika 6-4: Razdioba relativnih odstupanja simulacijom procijenjene potrošnje goriva u odnosu na snimljenu kumulativnu potrošnju goriva za sve snimljene vozne cikluse (osim onih kod kojih je potrošnja bila manja od 10 litara).</i>	<i>144</i>
<i>Slika 6-5: Blokovski dijagram kvazistatičkog modela EREV tipa kamiona (a), mapa korisnosti i krivulja maksimalnog momenta pogonskog elektromotora (b), te mapa specifične potrošnje goriva i krivulja maksimalnog momenta SUI motora (c). ..</i>	<i>145</i>
<i>Slika 6-6: Područja izbora dvaju stupnjeva prijenosa EREV pogona u izlaznoj mapi pogona (a) i granična krivulja između dva stupnja prijenosa u presjeku područja A i B (označenog kao A-B na slici (a)) (b).</i>	<i>147</i>
<i>Slika 6-7: Napon otvorenog kruga (a) i unutarnji otpor punjenja i pražnjenja za jednu ćeliju u ovisnosti o SoC-u (prikazano za jednu ćeliju Li-Ion baterije prema [67]).</i>	<i>148</i>
<i>Slika 6-8: Optimalna radna linija i optimalna radna točka SUI motora.</i>	<i>150</i>

<i>Slika 6-9: Kamionski UDSS vozni ciklus [98] (a) i grafički prikaz rezultata simulacije u CS režimu rada za različite upravljačke strategije u odnosu na globalno optimalne DP rezultate (b).</i>	151
<i>Slika 6-10: Razdioba prijeđenog puta do uključenja CS režima rada (a) i konačni SoC u odnosu na prijeđeni put tijekom voznog ciklusa (b).</i>	152
<i>Slika 6-11: Normirana potrošnja goriva u ovisnosti o prijeđenom putu tijekom voznog ciklusa (a) i interpolacija istih potrošnja goriva pravicima (b).</i>	153
<i>Slika 6-12: Normirane potrošnje goriva dobivene simulacijama razvijenih modela konvencionalnog i EREV kamiona za različite klastere voznih ciklusa.</i>	154
<i>Slika 6-13: Ovisnost (normiranog) troška punjenja flote EV (C_{bat}) o površini instaliranih solarnih panela ($A_{eff,PV}$) za dvije vrijednosti maksimalne snage punjača ($P_{cmax,ind}$).</i>	155
<i>Slika 6-14: Ovisnost udjela energije punjenja flote EV koja dolazi iz OIE ($E_{ch,OIE}$) u ukupnoj energiji punjenja flote ($E_{ch,TOTAL}$) o površini instaliranih solarnih panela ($A_{eff,PV}$) za dvije vrijednosti maksimalne snage punjača ($P_{cmax,ind}$).</i>	156
<i>Slika 6-15: Normirani ukupni troškovi vezani uz flotu EV ($C_{total} = C_{bat} + C_{fuel}$) i flotu konvencionalnih vozila (C_{fuel}) u ovisnosti o površini instaliranih solarnih panela.</i>	156
<i>Slika 6-16: Ovisnost troškova električne energije korištene od strane ostalih potrošača u distributivnom centru ($C_{el,total}$) o površini instaliranih solarnih panela ($A_{eff,PV}$).</i> 157	
<i>Slika 6-17: Ovisnost (normiranog) viška proizvedene električne energije iz OIE (E_{ceep}) o površini instaliranih solarnih panela ($A_{eff,PV}$).</i>	158
<i>Slika 6-18: Ukupni troškovi električne energije vezani uz flotu EV i ostale potrošače ($C_{bat} + C_{el,total}$) u ovisnosti o višku proizvedene energije iz OIE (crni trokuti pokrivaju optimalan raspon površine solarnih panela).</i>	158
<i>Slika 6-19: Emisije CO₂ vezane uz EV flotu (posebno dane za gorivo, te posebno za proizvodnju električne energije) (a) i ukupne emisije CO₂ (gorivo + proizvodnja električne energije) (b) (normirane u odnosu na ukupne emisije CO₂ vezane uz flotu konvencionalnih vozila, KONV) u ovisnosti o površini instaliranih solarnih panela ($A_{eff,PV}$) i za dva iznosa maksimalne snage punjača.</i>	160
<i>Slika 6-20: Analiza osjetljivosti troška punjenja EV flote (a) i operativnih troškova (gorivo + punjenje) EV flote u odnosu na operativne troškove (gorivo) konvencionalne flote (b) u ovisnosti o perturbaciji parametara vezanih uz energetski sustav (referentne vrijednosti parametara su $\eta_{OIE} = 0.15$, $\eta_{ch} = 0.92$, $P_{cmax,ind} = 10$ kW; površina solarnih panela postavljena je na $A_{eff,PV} = 14400$ m²).</i>	161
<i>Slika B-1: Grafička reprezentacija nelinearne jednadžbe stanja individualne baterije (2-3) – potvrda konkavnosti funkcije.</i>	178
<i>Slika B-2: Optimirane vrijednosti κ-faktora za različit broj vozila N_v u floti i različite vrijednosti maksimalne snage punjenja individualnih baterija $P_{cmax,ind}$ ($K -$</i>	

korelacijski indeksi).....	180
Slika B-3: Optimirane vrijednosti κ -faktora parametara za različite početne vrijednosti SoC-a (SoC_{init}) i maksimalne snage punjenja $P_{cmax,ind}$ (K – korelacijski indeks).	181
Slika B-4: Ovisnost κ -faktora o srednjim vrijednostima i standardnim devijacijama individualnih snaga punjenja.	182
Slika B-5: Usporedba agregatnih SoC trajektorija više-agentskog i nelinearnog modela baterije za neoptimirane (a) i optimirane κ vrijednosti (b), za slučaj uniformno distribuiranih individualnih snaga punjenja (c).	183
Slika B-6: Usporedba SoC trajektorija za neoptimirane (a) i optimirane κ vrijednosti (b) za slučaj slučajno odabiranih fiksnih diskretnih razina snaga punjenja/praznjenja baterija (c).	184
Slika B-7: Usporedba SoC trajektorija za neoptimirane (a) i optimirane κ vrijednosti (b) u slučaju normalno distribuiranih vrijednosti snaga punjenja/praznjenja (c).	185
Slika B-8: Usporedni prikaz individualnih i agregatnih korisnosti punjenja i pražnjenja baterije u funkciji snage punjenja individualnih baterija ($\eta_{ch,ind,mean} = 0.98$, $\eta_{dch,ind,mean} = 0.95$).	186
Slika B-9: Usporedba SoC trajektorija za slučaj linearnih i nelinearnih modela agregatne baterije za uniformno generirane (a), slučajno odabrane diskretne (b) i normalno distribuirane (c) individualne snage punjenja.	188
Slika B-10: Usporedba odstupanja konačnih vrijednosti SoC-a agregatnog linearnog i nelinearnog modela u odnosu na konačne vrijednosti agregatnog SoC-a realnog više-agentskog modela baterija flote EV.	188
Slika E-1: Ilustracija dolazaka i odlazaka iz distributivnog centra (DC) (i indeks označava i-ti vozni ciklus).	191
Slika E-2: Razdiobe prebrojanih parova dolazaka i odlazaka iz distributivnog centra ($t_{in,DC,i-1}$, $t_{out,DC,i}$) (a), te parova odlazaka i dolazaka u distributivni centar ($t_{out,DC,i}$, $t_{in,DC,i}$) (b) preračunatih s tromjesečnog perioda (91 dan) na 24-satni period uz 15-minutnu vremensku bazu.	192
Slika E-3: Razdioba broja snimljenih odlazaka iz distributivnog centra (a), te funkcija distribucije vjerojatnosti (F) odlaska iz distributivnog centra (b), za slučaj $t_{in,DC,24h} = 50$	193

Popis tablica

<i>Tablica 2-1: Karakteristični načini rada EREV pogona.....</i>	<i>12</i>
<i>Tablica 2-2: Jednadžbe kvazistatičkog modela EREV pogona [38, 74]......</i>	<i>14</i>
<i>Tablica 2-3: Pragovi uključivanja i isključivanja SUI motora rekonstruirani iz rezultata DP optimiranja i dobiveni primjenom DIRECT optimizacijskog algoritma kod realne upravljačke strategije.</i>	<i>38</i>
<i>Tablica 2-4: Krajnji iznos SoC-a (SoC_f) te broj prebacivanja načina rada (N_{mode}) za različite upravljačke strategije u CD režimu rada.</i>	<i>43</i>
<i>Tablica 2-5: RB+ECMS (varijabilna histereza) rezultati u odnosu na globalno optimalne DP rezultate za CD režim rada.....</i>	<i>44</i>
<i>Tablica 2-6: RB+ECMS rezultati u odnosu na globalno optimalne DP rezultate za CS režim rada.....</i>	<i>46</i>
<i>Tablica 2-7: Usporedni rezultati DP optimiranja i simulacija različitih realističnih upravljačkih strategija za slučaj NEDC, HWFET, UDDS, i US06 ponavljajućih voznih ciklusa.....</i>	<i>49</i>
<i>Tablica 2-8: Usporedni rezultati RB+ECMS (CD/CS) strategije i različitih tipova RB+ECMS (BLND) strategije za slučaj NEDC, HWFET, UDDS, i US06 ponavljajućih voznih ciklusa.....</i>	<i>51</i>
<i>Tablica 2-9: Specifična potrošnja goriva, te postotci vremena aktivnosti 1D-ECMS i 2D-ECMS upravljanja (vidi sliku 2-15a) za slučaj NEDC, HWFET, UDDS, US06 ponavljajućih voznih ciklusa (RB+ECMS, BLND režim rada).</i>	<i>52</i>
<i>Tablica 2-10: Zbirni usporedni rezultati iz tablica 2-7 i 2-8.....</i>	<i>52</i>
<i>Tablica 3-1: Srednje vrijednosti i standardne devijacije razdioba značajnih statističkih parametara za snimljene pojedinačne vozne cikluse, generirane sintetičke vozne cikluse te za kombinirani snimljeni vozni ciklus.....</i>	<i>73</i>
<i>Tablica 3-2: Karakteristike snimljenih voznih ciklusa po pojedinim klasterima.</i>	<i>75</i>
<i>Tablica 4-1: Usporedba zahtijevane energije i energije punjenja za različite modele flote EV i pripadne metode punjenja.</i>	<i>97</i>
<i>Tablica 4-2: Pokazatelji sličnosti vremenskih odziva agregatnih modela flote EV u odnosu na odgovarajuće odzive distribuiranih modela flote EV za različite modele cijene električne energije.</i>	<i>99</i>
<i>Tablica 4-3: Ukupni troškovi punjenja dobiveni korištenjem različitih modela flote EV i metoda punjenja te raznih modela cijene električne energije.</i>	<i>99</i>
<i>Tablica 4-4: Usporedba troškova energije punjenja temeljem agregatnih modela flote s troškovima odgovarajućih distribuiranih modela za različite modele cijene</i>	

	<i>električne energije.....</i>	<i>100</i>
<i>Tablica 4-5:</i>	<i>Pokazatelji sličnosti vremenskih odziva različitih modela flote EV uz primjenu različitih metoda punjenja, sve u odnosu na DP-IND metodu.</i>	<i>100</i>
<i>Tablica 5-1:</i>	<i>Minimalni i maksimalni troškovi punjenja flote EV i pripadne standardne devijacije (izražene u EUR) za 10 različitih rasporeda punjenja EV unutar flote i dva modela cijene električne energije („Cijena 1“ i „Cijena 4“ sa slike 4-3).</i>	<i>125</i>
<i>Tablica 5-2:</i>	<i>Usporedba troškova punjenja distribuiranih modela flote EV za slučaj različitih ograničenja postavljenih u sklopu optimiranja.....</i>	<i>126</i>
<i>Tablica 5-3:</i>	<i>Kvantifikacija kršenja ograničenja vezanog uz maksimalnu snagu mreže (postavljenu na iznos 20 kW) koja se može povući iz mreže i usporedba različitih pristupa modeliranju i optimiranju flote EV (koristi se model „Cijena 1“).</i>	<i>128</i>
<i>Tablica 5-4:</i>	<i>Usporedni troškovi punjenja uz primjenu osnovnog agregatnog modela baterije za slučaj DP optimiranja i heurističke metode punjenja i za slučaj kad ne postoji višak proizvedene energije iz OIE ($A_{\text{eff,PV}} = 6600 \text{ m}^2$) i 4 modela cijena električne energije (Slika 4-3).....</i>	<i>130</i>
<i>Tablica 5-5:</i>	<i>Usporedba stvarnih tjednih troškova punjenja i stvarnih tromjesečnih troškova punjenja dobivenih DP optimiranjem sa procijenjenim troškovima punjenja temeljenima na dnevnim i tjednim troškovima punjenja (postotne vrijednosti označavaju odnose troškova iz retka u odnosu na troškove iz stupca).</i>	<i>131</i>
<i>Tablica 5-6:</i>	<i>Usporedni rezultati vezani uz udio energije punjenja iz OIE u ukupnoj energiji punjenja agregatne baterije i troškove punjenja agregatne baterije za slučaj kad postoji višak proizvedene energije iz OIE (koristi se model cijene električne energije „Cijena 1“ i $A_{\text{eff,PV}} = 20100 \text{ m}^2$).</i>	<i>133</i>
<i>Tablica 6-1:</i>	<i>Parametri transmisije [80, 91, 93].</i>	<i>141</i>
<i>Tablica 6-2:</i>	<i>Snimljena kumulativna potrošnja goriva dana usporedno s potrošnjom goriva procijenjenom na temelju simulacije razvijenog modela vozila za deset snimljenih voznih ciklusa (po dva iz svakog klastera ciklusa prikazanih na slici 3-9).</i>	<i>143</i>
<i>Tablica 6-3:</i>	<i>Udjeli punjenja flote EV tijekom perioda jeftine električne energije (LT) i tijekom perioda skupe električne energije (HT) za slučaj kad ne postoji višak proizvedene energije iz OIE.....</i>	<i>155</i>
<i>Tablica A-1:</i>	<i>Parametri EREV pogona tipa Chevrolet Volt.</i>	<i>176</i>
<i>Tablica A-2:</i>	<i>Parametri varijabilne histereze (2-25) za različite vozne cikluse.</i>	<i>176</i>
<i>Tablica A-3:</i>	<i>Parametri EREV pogona dostavnog vozila.</i>	<i>176</i>

Popis oznaka i kratica

Popis oznaka

Oznaka	Jedinica	Opis
$A_{eff,PV}$	m^2	Površina instaliranih solarnih panela
A_{ek}	g/Wh	Specifična potrošnja goriva
\bar{A}_{ek}	g/Wh	Ekvivalentna specifična potrošnja goriva
$A_{ek,mean}$	g/Wh	Srednja specifična potrošnja goriva tijekom voznog ciklusa
A_f	m^2	Čeona površina vozila
a_k	m/s^2	Akceleracija vozila u k -tom koraku
$a_{neg,mean}$	m/s^2	Srednja vrijednost negativne akceleracije vozila
$a_{neg,std}$	m/s^2	Standardna devijacija negativne akceleracije vozila
$a_{pos,mean}$	m/s^2	Srednja vrijednost pozitivne akceleracije vozila
$a_{pos,std}$	m/s^2	Standardna devijacija pozitivne akceleracije vozila
C_{bat}	EUR	Trošak punjenja flote EV
$C_{bat,ind,j}$	EUR	Trošak punjenja baterije j -tog vozila
C_d	-	Koeficijent aerodinamičkog otpora
C_{el}	EUR/kWh	Jedinična cijena električne energije
$C_{el,total}$	EUR	Trošak potrošene električne energije (bez punjenja EV flote)
C_{fuel}	EUR	Trošak potrošenog goriva cijele flote
$C_{fuel,unit}$	EUR	Jedinična cijena goriva

C_{grid}	EUR	Trošak električne energije koja se povlači iz mreže
C_{total}	EUR	Operativni troškovi EV flote (gorivo + električna enegija)
$d_{i,j}$	m	Prijeđeni put j -tog vozila tijekom i -tog voznog ciklusa
d_{lower}	m	Donja margina prijeđenog puta unutar nekog klastera voznih ciklusa
d_{mean}	m	Polovina prijeđenog puta (između donje i gornje margine) unutar nekog klastera voznih ciklusa
d_{upper}	m	Gornja margina prijeđenog puta unutar nekog klastera voznih ciklusa
E_{agg}	Ws	Trenutna razina energije u agregatnoj bateriji
e_{ceep}	Ws	Višak energije iz OIE koja nije iskorištena za opskrbu ostalih potrošača (bez EV)
E_{cell}	kWh	Energetski kapacitet jedne ćelije Li-Ion baterije
$E_{c,f}$	Ws	Ostvarivi agregatni iznos energije raspodijeljen po pojedinačnim EV
E_{ch}	Ws	Agregatna energija punjenja flote EV
$E_{ch,OIE}$	kWh	Energija iz OIE korištena za punjenje agregatne baterije
$E_{ch,total}$	kWh	Ukupna agregatna energija punjenja flote EV
$E_{c,j}$	Ws	Energija punjenja j -tog EV-a u trenutnom koraku
$E_{cmax,j}$	Ws	Gornje ograničenje na energiju koja se može pohraniti u j -to EV u trenutnom koraku
$E_{cmin,j}$	Ws	Donje ograničenje na energiju koja se može pohraniti u j -to EV u trenutnom koraku
$E_{c,ref}$	Ws	Referentna agregatna snaga punjenja flote

E_{dem}	Ws	Agregatni zahtjev transporta za energijom na kotačima
E_{HT}	EUR/kWh	Jedinična cijena električne energije u periode visoke tarife
E_{LT}	EUR/kWh	Jedinična cijena električne energije u periode niske tarife
$E_{max,agg}$	Wh	Energetski kapacitet agregatne baterije
$E_{max,ind}$	Wh	Energetski kapacitet pojedinačne baterije
EN_{ST}	-	Zastavica koja određuje uključivanje ili isključivanje SUI motora u EREV pogonu
e_{SoC}	-	Odstupanje stvarnog SoC-a od referentnog
F	-	Podintegralna funkcija u ciljnoj funkciji kod DP optimiranja
\mathbf{f}	-	Opća funkcija stanja sustava
f_{fuel}	-	Funkcija koja povezuje potrošnju goriva s prijeđenim putem i SoC-om na početku voznog ciklusa
f_{SoC}	-	Funkcija koja povezuje potrošnju goriva s prijeđenim putem i SoC-om na početku voznog ciklusa
F1, F2, F3	-	Oznake spojki
g	m/s ²	Akceleracija slobodnog pada
h	-	Prijenosni omjer transmisije
i_o	-	Prijenosni omjer izlazne redukcije pogona
J	-	Ciljna funkcija
J_f	-	Krajnja vrijednost ciljne funkcije
k	-	Vremenski diskretni korak
K_E	-	Koeficijent korelacije referentne i ostvarive krivulje

		agregatne energije punjenja
K_f	-	Težinski faktor kažnjavanja pogreške završnog stanja
K_g	-	Težinski faktor kažnjavanja prekoračenja ograničenja
K_{SoC}	-	Pojačanje SoC regulatora
K_{soc}	-	Koeficijent korelacije krivulja agregatnog referentnog i ostvarivog SoC-a
\dot{m}_{batt}	g/s	Nadomjesni maseni protok goriva
m_{cell}	kg	Masa jedne ćelije baterije
\dot{m}_{eq}	g/s	Ekvivalentni maseni protok goriva
m_f	g	Masa potrošenog goriva
\bar{m}_f	g/kWh	Specifična potrošnja goriva
$\dot{m}_{fuel}, \dot{m}_f$	g/s	Maseni protok goriva
$m_{f,c}$	g	Korigirana potrošnja goriva
m_v	kg	Masa vozila
N_{buffer}	-	Veličina kružnog spremnika u koji se spremaju vrijednosti τ_R momenta
$N_{control}$	-	Broj diskretnih vrijednosti upravljačke varijable $P_{c,agg}$ kod DP optimiranja
N_{dc}	-	Ukupan broj voznih ciklusa tijekom perioda
$n_{dc,agg}$	-	Broj EV spojenih na mrežu
$N_{dc,j}$	-	Broj voznih ciklusa odrađen j -tim vozilom iz flote
$n_{dc,j}$	-	Udio vremena parkiranosti j -tog vozila unutar nekog diskretnog vremenskog trenutka
$n_{dc,o}$	-	Vremenski trenutci unutar kojih EV napušta

		distributivni centar
N_{mode}	-	Broj prebacivanja načina rada kod EREV-a
N_{soc}	-	Broj diskretnih vrijednosti varijable stanja <i>SoC</i> kod DP optimiranja
N_t	-	Broj diskretnih vremenskih trenutaka
N_v	-	Broj vozila u floti
P_{batt}	W	Snaga baterije kod EREV pogona
$P_{c,agg}$	W	Agregatna snaga punjenja flote EV
$P_{c,agg,OIE}$	W	Snaga iz OIE koja se koristi za punjenje agregatne baterije
$P_{c,agg,ref}$	W	Referentni profil agregatne snage punjenja flote EV
$P_{c,j}$	W	Snaga punjenja <i>j</i> -tog EV
$P_{cmax,grid}$	W	Maksimalna snaga koja se može povući iz mreže
$P_{cmax,ind}$	W	Maksimalna snaga punjača
$P_{cum,lim,j}$	W	Gornji limit snage koja se može povući iz mreže za <i>j</i> -to vozilo
$P_{c,viol,total}$	W	Kumulativno kvantificirano kršenje ograničenja na maksimalnu snagu punjenja pojedinačnog vozila
P_d	W	Zahtjev vozača za snagom
$P_{dem,agg}$	W	Zahtijevana agregatna snaga na kotačima flote EV
$P_{dem,j}$	W	Zahtijevana snaga na kotaču <i>j</i> -tog vozila
P_e	W	Snaga SUI motora
P_{EL}	W	Potrošnja električne snage u distributivnom centru
P_{grid}	W	Snaga koja se povlači iz mreže
p_{ij}	-	Vjerojatnost prijelaza iz stanja <i>i</i> u stanje <i>j</i> kod

Markovljevih lanaca

P_{mg1}	W	Snaga električnog stroja MG1
P_{mg2}	W	Snaga električnog stroja MG2
P_{off}	W	Prag snage isključivanja SUI motora
P_{on}	W	Prag snage uključivanja SUI motora
P_{OIE}	W	Snaga iz obnovljivih izvora energije
$P_{reg,agg}$	W	Agregatna snaga regenerativnog kočenja flote EV
$P_{reg,j}$	W	Snaga regenerativnog kočenja na kotaču j -tog vozila
q	As	Naboj baterije
Q_{cell}	As	Nabojski kapacitet jedne ćelije baterije
Q_{max}	As	Nabojski kapacitet jedne ćelije baterije
r	m	Efektivni polumjer auto gume
R_{ic}	Ω	Unutarnji otpor baterije tokom punjenja
R_{idc}	Ω	Unutarnji otpor baterije tokom pražnjenja
R_o	-	Faktor otpora kotrljanja
R_z	m	Srednji radijus Zemlje
SoC_{agg}	-	SoC agregatne baterije
$SoC_{agg,min}, SoC_{agg,max}$	-	Donji i gornji limit na SoC agregatne baterije
$SoC_{agg,f}$	-	Ostvarivi SoC agregatne baterije
$SoC_{agg,ref}$	-	Referentni SoC agregatne baterije
SoC_f, SoC_{end}	-	Konačna vrijednost SoC-a
$SoC_{f,c}$	-	Korigirana vrijednost krajnjeg iznosa SoC-a
$SoC_{in,avg}$	-	Prosječan SoC EV-a koja pristižu u distributivni centar
$SoC_{in,ind,i,j}$	-	SoC j -tog EV-a na kraju i -tog voznog ciklusa

SoC_i, SoC_{init}	-	Početna vrijednost SoC-a
SoC_j	-	SoC baterije j -tog vozila
SoC_{min}, SoC_{max}	-	Donji i gornji limiti na SoC baterije
S_{mode}	-	Varijabla načina rada pogona
$SoC_{out,avg}$	-	Prosječan SoC EV-a koja odlaze iz distributivnog centra
$SoC_{out,ind,i,j}$	-	SoC j -tog EV-a na početku i -tog voznog ciklusa
SoC_R	-	Referentni SoC kod EREV upravljačke strategije
t	s	Vrijeme
t_{dc}, t_f	s	Vrijeme trajanja voznog ciklusa
$t_{c1,j}$	s	Trajanje spojenosti j -tog EV-a na mrežu u trenutnom koraku
$t_{c2,j}$	s	Preostalo vrijeme spojenosti j -tog EV-a na mrežu
$T_{optim,ind}$	s	Trajanje DP optimiranja punjenja jednog EV-a
\mathbf{u}_k	-	Vektor upravljačkih varijabli u k -tom vremenskom koraku
$\mathbf{u}_{min}, \mathbf{u}_{max}$	-	Vektori donjih i gornjih limita upravljačkih varijabli
U_{oc}	V	Napon otvorenog kruga baterije
$V_{fuel,i,j}$	l	Volumen potrošenog goriva j -tog EV-a tijekom i -tog voznog ciklusa
$V_{f,sim}$	l	Volumen potrošenog goriva dobiven simulacijom
$V_{f,real}$	l	Zabilježeni volumen potrošenog goriva
v_k	m/s	Brzina vozila u k -tom vremenskom koraku
v_{mean}	m/s	Srednja vrijednost brzine vozila tijekom voznog ciklusa

v_{std}	m/s	Standardna devijacija brzine vozila tijekom voznog ciklusa
v_v	m/s	Brzina vozila
X_{centre}	m	Koordinata distributivnog/prodajnog centra dobivena iz geografske dužine
$\mathbf{x}_{N_t}, \mathbf{x}_f$	-	Vektor stanja u konačnom trenutku N_t
X_{GPS}	o	Geografska dužina dobivena iz GPS uređaja
$\mathbf{x}_0, \mathbf{x}_i$	-	Vektor stanja u početnom trenutku
\mathbf{x}_k	-	Vektor varijabli stanja u k -tom vremenskom koraku
Y_{centre}	m	Koordinata distributivnog/prodajnog centra dobivena iz geografske širine
Y_{GPS}	o	Geografska širina dobivena iz GPS uređaja
α	o	Nagib ceste
α_{max}	o	Nagib ceste koje vozilo treba zadovoljiti
ΔE	Ws	Preostala agregatna energija namijenjena raspodjeli po pojedinačnim vozilima
$\Delta E_{c,j}$	Ws	Dio agregatne energije u jednoj iteraciji namijenjen za punjenje j -tog vozila
$\Delta n_{in,dc}$	-	Broj vozila pristiglih u distributivni centar
$\Delta n_{out,dc}$	-	Broj vozila koja napuštaju distributivni centar
ΔSoC	-	Širina mrtve zone SoC regulatora
ΔSoC_j	-	Potrošnja SoC j -tog vozila unutar diskretnog vremenskog koraka
$\Delta SoC_{out,ind,i,j}$	-	Povećanje SoC-a j -tog vozila u razdoblju prije i -tog voznog ciklusa

ΔT	h	Trajanje diskretnog vremenskog koraka
$\Delta X, \Delta Y$	m	Pomaci vozila po x- i y-osi unutar jednog koraka (rekonstruirani iz snimljene geografske dužine i širine)
ε_i	-	Odstupanje i -tog statističkog parametra sintetičkog voznog ciklusa u odnosu na statistički parametar kombiniranog voznog ciklusa
ε_{total}	-	Kriterij koji u obzir uzima sva odstupanja $\varepsilon_i, i = 1, 2, \dots, 6$
η_{batt}	-	Korisnost baterije
η_c	-	Korisnost pojedinačne baterije pri punjenju kod EREV-a
η_{ch}	-	Korisnost agregatne baterije pri punjenju
η_d	-	Korisnost pojedinačne baterije pri pražnjenju kod EREV-a
η_{dch}	-	Korisnost agregatne baterije pri punjenju
η_{mg1}	-	Korisnost MG1 stroja
η_{mg2}	-	Korisnost MG2 stroja
η_{OIE}	-	Korisnost solarnih panela
η_t	-	Korisnost transmisije
η_{TMEV}	-	Kombinirana korisnost u TMEV načinu rada kod EREV-a
λ	-	Širina histereze granice između EV i TMEV rada kod upravljanja EREV pogona
λ_L, λ_U	-	Donji i gornji limit širine histereze λ
Π	-	Matrica prijelaznih vjerojatnosti

ρ_{air}	kg/m ³	Gustoća zraka
τ_{cd}	Nm	Okretni moment pogonskog vratila
τ_e	Nm	Okretni moment SUI motora
τ_{eopt}	Nm	Referentni okretni moment SUI motora postavljen od strane ECMS algoritma
τ_{eR}	Nm	Referentni okretni moment SUI motora postavljen od strane RB regulatora
τ_{eRmod}	Nm	Okretni moment SUI motora dobiven kombiniranjem zahtjeva ECMS-a i RB-a
$\tau_{EV,max}$	Nm	Maksimalni okretni moment na izlaznom vratilu koji se može postići u EV načinu rada
τ_{mg1}, τ_{mg2}	Nm	Okretni momenti MG1 i MG2 električnih strojeva
$\tau_{mg1,min}, \tau_{mg1,max}$	Nm	Donji i gornji limiti okretnog momenta MG1 stroja
$\tau_{mg2,min}, \tau_{mg2,max}$	Nm	Donji i gornji limiti okretnog momenta MG2 stroja
τ_{mg2R}	Nm	Referentna vrijednost okretnog momenta MG2 stroja
τ_R	Nm	Ekvivalentni okretni moment opterećenja
$\tau_{SPHEV,max}$	Nm	Maksimalni okretni moment na izlaznom vratilu koji se može postići u EV načinu rada
τ_{uhR}	Nm	Vektor referentnih stanja spojki F1, F2, i F3
τ_{uR}	Nm	Referentni okretni moment koje prenose spojke spojke F1, F2, i F3
ω_e	rad/s	Brzina vrtnje SUI motora
$\omega_{e,min}, \omega_{e,max}$	rad/s	Donji i gornji limiti brzine vrtnje SUI motora
ω_{emgs}	rad/s	Vektor koji sadrži brzine vrtnje SUI motora, te MG1 i MG2 električnih strojeva

ω_{eopt}	rad/s	Referentna brzina vrtnje SUI motora postavljena od strane ECMS algoritma
ω_{eR}	rad/s	Referentna brzina vrtnje SUI motora postavljena od strane RB regulatora
ω_{eRmod}	rad/s	Referentna brzina vrtnje SUI motora dobivena kombiniranjem zahtjeva ECMS-a i RB-a
$\omega_{mg1}, \omega_{mg2}$	rad/s	Brzine vrtnje MG1 i MG2 električnih strojeva
$\omega_{mg1,min}, \omega_{mg1,max}$	rad/s	Donji i gornji limiti brzine vrtnje MG1 stroja
$\omega_{mg2,min}, \omega_{mg2,max}$	rad/s	Donji i gornji limiti brzine vrtnje MG2 stroja

Popis kratica

BEV	Baterijsko električno vozilo (<i>engl. Battery Electric Vehicle</i>)
BLND	Kombinirani režim postupnog pražnjenja baterije (<i>engl. Blended</i>)
CD	Režim pražnjenja naboja baterije (<i>engl. Charge Depleting</i>)
KONV	Konvencionalno vozilo
CS	Režim održavanja naboja baterije (<i>engl. Charge Sustaining</i>)
DISTR1(2)	Primjena algoritma raspodjele agregatne snage punjenja po pojedinačnim vozilima temeljena na referentnoj agregatnoj snazi punjenja dobivenoj korištenjem DP-AGGR1(2) optimiranja
DP	Algoritam dinamičkog programiranja
DP-AGGR1	DP optimiranje punjenja temeljem osnovnog agregatnog modela flote EV
DP-AGGR2	DP optimiranje punjenja temeljem naprednog agregatnog modela flote EV
DP-IND	DP optimiranje punjenja distribuiranog modela flote EV

ECMS	Strategija minimizacije ekvivalentne potrošnje goriva (<i>engl. Equivalent Consumption Minimization Strategy</i>)
EREV	Električno vozilo proširenog dometa (<i>engl. Extended Range Electric Vehicle</i>)
EV	Električno vozilo; ujedno način rada: potpuno električno vozilo
GEN	Razdiobe generirane korištenjem Monte Carlo postupka
HEUR	Heuristički način punjenja flote EV
HEV	Hibridno električno vozilo (<i>engl. Hybrid Electric Vehicle</i>)
HT	Period skupe električne energije (<i>engl. High tariff</i>)
LT	Period jeftine električne energije (<i>engl. Low tariff</i>)
OIE	Obnovljivi izvor energije
PHEV	Utično hibridno električno vozilo (<i>engl. Plug-in Hybrid Electric Vehicle</i>)
RB	Regulator zasnovan na bazi pravila (<i>engl. Rule-based</i>)
REC	Snimljeni podaci (razdiobe)
SHEV	Način rada: serijsko hibridno električno vozilo
SoC	Stanje napunjenosti baterije (<i>engl. State-of-Charge</i>)
SPHEV	Način rada: serijsko-paralelno hibridno električno vozilo
SUI motor	Motor s unutarnjim izgaranjem
TMEV	Način rada: dvo-motorno potpuno električno vozilo
TP	Matrica prijelaznih vjerojatnosti (<i>engl. Transition Probability</i>)
V2G	Vozilo na mreži (<i>engl. Vehicle-to-Grid</i>)

1. Uvod

1.1. Motivacija

Uvođenje električnih vozila (EV) predstavlja ključ razvoja energetske učinkovite, čiste i tihog transportnog sustava, te smanjenja ovisnosti o naftnim rezervama. Međutim, rastuća primjena EV može predstavljati problem sa stanovišta elektroenergetskog sustava, zbog povećanja opterećenja mreže u intervalima punjenja baterija EV [1]. Ovaj se problem može riješiti primjenom naprednog punjenja flote EV, kod kojeg se punjenje provodi u periodu slabijeg opterećenja mreže, zahvaljujući činjenici da su vozila veliku većinu vremena parkirana i raspoloživa za punjenje (96% vremena prema nacionalnom istraživanju provedenom u SAD [2]). Time, EV umjesto potencijalnog problema postaju pogodnost za elektroenergetski sustav, jer omogućuju poravnanje opterećenja mreže, te time i bolju učinkovitost i iskoristivost cjelokupnog sustava [3]. Kako je u periodima poravnanja opterećenja cijena električne energije uobičajeno niža, napredno punjenje rezultira i smanjenjem troškova električne energije. Konačno, EV mogu potaknuti prodor obnovljivih izvora energije (OIE), jer se proizvodnja iz OIE (npr. energija vjetra ili sunca) može naprednim punjenjem pohraniti u EV, umjesto da se odbacuje u intervalima malog opterećenja mreže. Pohranjena energija se dalje pretvara u mehanički rad na ekološki prihvatljiv način, ili se eventualno može vratiti u mrežu u intervalima povećanog opterećenja mreže (koncept vozila na mreži, engl. skrać. V2G) [1, 2, 4-6]. V2G koncept bi omogućio aktivno sudjelovanje flota EV na tržištima električne energije, a naročito potencijal bi EV imala u regulaciji napona i frekvencije lokalnih mreža zbog malog vremena odziva koje karakterizira EV baterije [2].

Kako bi se potaknuo i ubrzao prodor EV i OIE u razne transportno-energetske sustave potrebno je provesti brojna istraživanja vezana uz tehničku izvodljivost te ekonomsku isplativost uvođenja ovakvih rješenja [2, 4-7]. Osim toga, potrebno je kvantificirati povoljan učinak navedenih tehnologija na okoliš, koji se sve više potiče kroz različite regulatorne mehanizme. Kao preduvjet provedbi spomenutih istraživanja (usko vezanih uz područje energetske planiranja [1, 2, 4-6]) potrebno je izraditi precizne i računalno-učinkovite modele transportno-energetskog sustava. Oni kao podmodele sadrže flotu EV uključujući realistične

vozne cikluse, model proizvodnje iz OIE, model zahtjeva za električnom energijom ostalih potrošača unutar energetskog sustava i model vremenske razdiobe cijene električne energije.

Modeli transportno-energetskog sustava koriste se nadalje za optimiranje vremenskih profila snage punjenja EV. Ciljevi optimiranja mogu biti različiti, a najčešće su vezani uz minimizaciju troškova električne energije za punjenje flote EV, viška proizvedene energije iz OIE ili oscilacija u opterećenju mreže, uz zadovoljenje različitih fizikalnih ograničenja sustava te zadovoljenje zahtjeva na održivo stanje napunjenosti EV na kraju perioda punjenja [3, 4, 8-15]. Odabir optimizacijskog algoritma koji će za zadani problem dati globalno optimalno rješenje, a da je pri tome računalno učinkovit, predstavlja izazov. S tog stanovišta, povoljno je da se modeliranje i optimiranje punjenja flote EV provede na razini tzv. agregatne baterije, koja u vidu jedne koncentrirane baterije predstavlja cijelu flotu [4].

Nadalje, da bi model flote EV bio čim vjerniji, on treba uključivati samo ona EV koja su spojena na mrežu te stanje napunjenosti samo njihovih baterija. Iz toga proizlazi problematika modeliranja razdioba početka i kraja punjenja EV unutar flote, te modeliranja zahtjeva za energijom za potrebe vožnje kako bi se ustvrdilo stanje napunjenosti baterija EV prilikom spajanja na mrežu. Potonje bi se u svrhu bolje točnosti trebalo temeljiti na vjernim modelima EV, koji također uključuju realistične upravljačke strategije projektirane s ciljem minimizacije potrošnje energije [16, 17]. EV se mogu podijeliti u nekoliko karakterističnih skupina [16]: hibridna električna vozila (HEV), utična hibridna električnih vozila (PHEV - *engl. Plug-in Hybrid Electric Vehicle*), baterijska električna vozila proširenog dometa (EREV - *engl. Extended Range Electric Vehicle*) i baterijska električna vozila (BEV - *engl. Battery Electric Vehicle*). Sa stanovišta energetskog sustava, zanimljiva su samo utična vozila koja za potrebe vožnje potpuno ili dijelom koriste energiju iz mreže, a to su redom BEV i PHEV/EREV. Pogoni navedenih vozila mogu biti izvedeni u različitim konfiguracijama kao što su serijska, paralelna, te serijsko-paralelna [18-20]. Stoga, sinteza optimalne upravljačke strategije za takve pogone koji sadrže više različitih izvora energije također predstavlja značajan izazov [16, 17].

1.2. Dosadašnje spoznaje

1.2.1. Modeliranje i upravljanje pogonima hibridnih električnih vozila

Kako bi se istražile potencijalne prednosti EV nad konvencionalnim vozilima i ostvarile pretpostavke za modeliranje flote EV, potrebno je izraditi precizne i računalno učinkovite modele pogona EV. Prevladavaju dva osnovna pristupa modeliranja EV pogona u koje spadaju i HEV pogoni, a to su kvazistatički i dinamički pristup [16]. U ovom radu primjenjuju se kvazistatički modeli, jer su računalno vrlo učinkoviti i kao takvi predstavljaju dobru podlogu za upravljanje tokovima snage u EV pogonima. Ulazne varijable kvazistatičkih modela HEV pogona najčešće su brzina vrtnje i moment pogonskih kotača koji su definirani voznim ciklusom, a izlazne varijable su maseni protok goriva i stanje napunjenosti baterije (SoC - *engl. State of Charge*), pri čemu je SoC jedina varijabla stanja modela. Koeficijent korisnosti i kapacitiranost (npr. maksimalni moment) pojedine komponente hibridnog pogona opisuje se statičkim karakteristikama koje su obično dobivene eksperimentalnim mjerenjima. Ovakve mape pohranjuju se u baze podataka [21], a pomoću njih se izrađuju prikladni matematički modeli [16], koji opisuju elektromotore [21], motor s unutarnjim izgaranjem (SUI) [22] te elektrokemijsku bateriju [23, 24].

HEV pogoni, koji sadrže više izvora energije, najčešće su upravljani s regulatorima zasnovanim na bazi pravila (RB - *engl. Rule Based Controller*), koji su empirijski podešeni, a čiji je cilj postaviti radnu točku SUI motora unutar područja najveće korisnosti [22, 25]. Razlog korištenja takvih regulatora je jednostavnost i robusnost, no oni su općenito podoptimalni i ne mogu iskoristiti puni potencijal HEV pogona u smislu ekonomičnosti. Zbog toga se RB regulatori u literaturi često zamjenjuju s optimizacijskim algoritmima temeljenima na minimizaciji ekvivalentne potrošnje goriva (ECMS - *engl. Equivalent Consumption Minimisation Strategy*), gdje se tok snage iz baterije razmatra kao dodatni, ekvivalentni tok goriva te se minimizira u ukupnosti sa stvarnim tokom goriva [25-30]. Budući da lokalno-optimalan ECMS algoritam ne može osigurati održivost SoC-a, odnosno njegovo zadržavanje unutar dopuštenih granica, ekvivalentan tok goriva iz baterije unutar ECMS kriterijske funkcije penalizira se težinskim faktorom. Međutim, takav ECMS algoritam može postati vrlo osjetljiv na odabir težinskog faktora za širok raspon voznih ciklusa, što se može izbjeći

relativno složenom adaptacijom tog faktora u ovisnosti o karakteristikama voznog ciklusa [28]. Stoga se u novije vrijeme predlaže da se adaptacija težinskog faktora ostvari korištenjem PI regulatora SoC-a [31]. Drugačiji, općenito praktičniji pristup bi uključio kombiniranje RB regulatora s ECMS algoritmom, u kojem bi se objedinile prednosti RB regulatora koji osigurava održivost SoC varijable i ECMS algoritma koji osigurava optimalnost rada pogona [29]. Upravljanje HEV pogonom može se osim navedenim metodama ostvariti i korištenjem neizrazitog upravljanja [32], teorije igara [33] ili samoučećih umjetnih neuronskih mreža [34, 35]. Primijenjena upravljačka strategija uobičajeno se provjerava s obzirom na globalno optimalno rješenje upravljanja za karakteristične vozne cikluse, a koje se dobiva primjenom dinamičkog programiranja [16].

PHEV/EREV pogoni, čije se baterije mogu puniti iz mreže, često su složenijih konfiguracija od HEV pogona. Tipičan primjer je EREV pod nazivom Chevrolet Volt, čiji pogon sadržava dva električna stroja, jedan SUI motor, planetarni prijenosnik te tri spojke [36-38]. Raznim kombinacijama uključenosti i isključenosti spojki mogu se ostvariti različite konfiguracije pogona i time različiti načini rada koji se dijele na potpuno električne i hibridne načine rada. Zbog toga je za ovakve pogone, osim spomenutih upravljačkih strategija koje se koriste za postavljanje radnih točaka komponenata pogona, potrebno projektirati i nadređeni dio upravljačke strategije koji na optimalan način postavlja način rada pogona [30, 39, 40]. PHEV/EREV vozila tipično rade u CD/CS režimu, gdje se vozilo prvo vodi u potpuno električnom načinu rada, čime se baterija prazni do neke predefiniране, minimalno dopuštene razine SoC-a (CD mod - *engl. Charge Depleting*), nakon čega se uključuje hibridni način rada kako bi se SoC održao na dostignutoj razini (CS mod - *engl. Charge Sustaining*) [30, 39, 40]. Međutim, ako je unaprijed poznata udaljenost koju vozilo treba prijeći tijekom voznog ciklusa, baterija se može prazniti postupnije uz istovremeno korištenje SUI motora, na način da najnižu dopuštenu razinu SoC-a dosegne tek na kraju vozne misije. U ovom kombiniranom načinu rada (BLND - *engl. Blended mode*) može se postići manja potrošnja goriva zbog veće slobode prilikom optimiranja radnih točki komponenti pogona [31, 41-44]. Sustav upravljanja treba ostvariti točno slijeđenje referentne SoC trajektorije [31, 42-44], što se može realizirati adaptacijom kriterijske funkcije ECMS upravljačke strategije [31, 42], korištenjem SoC regulatora sadržanog unutar RB [40] ili podešavanjem pragova uključivanja/isključivanja ICE

motora [43, 44]. Određivanje optimalne SoC trajektorije za različite uvjete vožnje (uključujući nagib ceste) temelji se na optimizacijskim metodama kao što je PMP pristup (*engl. Pontryagin Minimum Principle*) [41] ili dinamičko programiranje [45].

1.2.2. Sintetički vozni ciklusi

Vozni ciklusi su tipično definirani kao vremenski profili brzine vozila (1D opis) i kao takvi određuju temeljne karakteristike vožnje. Vozni ciklusi imaju široku primjenu iz perspektive konvencionalnih, ali i električnih cestovnih vozila, što uključuje: a) realističnu procjenu potrošnje goriva/energije [46], b) procjenu emisija stakleničkih i štetnih plinova [47], c) izbor optimalne konfiguracije i optimalnih dimenzija komponenti pogona vozila [48, 49], te d) razvoj optimalne upravljačke strategije pogona vozila [50]. Pored toga, vozni ciklusi koriste se od strane regulatornih agencija za određivanje propisane dozvoljene emisije stakleničkih plinova koje vozila moraju zadovoljiti [51]. Kod električnih vozila dodatno se koriste i za određivanje efektivnog dometa vozila i životne dobi baterije. Osim toga, ključni su kod realizacije strategija eko-rutiranja vozila, modeliranja i upravljanja flotama vozila za realistične uvjete vožnji, te naprednih strategija upravljanja punjenjem baterija flote električnih vozila [52].

Međutim, za navedene potrebe većinom se koriste certifikacijski vozni ciklusi (npr. NEDC - *engl. New European Driving Cycle*) koji ne reprezentiraju stvarne vozne uvjete. Kako bi rezultati simulacija pojedinačnih vozila i flota vozila bili čim bliže rezultatima koji se ostvaruju u stvarnoj vožnji, u simulacijama bi se umjesto certifikacijskih trebali koristiti realistični vozni ciklusi [53]. Realistični vozni ciklusi uobičajeno se dobivaju snimanjem voznih podataka korištenjem GPS tehnologije (namjenskim GPS uređajima [53, 54] ili GPS uređajima sadržanima u pametnim telefonima [55]). Međutim, broj takvih snimljenih voznih ciklusa može biti prilično velik što može uzrokovati predugo trajanje simulacija i optimizacija temeljenih na cjelokupnom skupu snimljenih voznih ciklusa. Stoga se široki skup snimljenih voznih ciklusa može nadomjestiti s jednim ili nekoliko sintetičkih voznih ciklusa koji statistički vjerno reprezentiraju polazni skup [53]. Zbog smanjenog broja potrebnih simulacija, sintetički vozni ciklusi se osim za navedene potrebe često koriste i za modeliranje energetskehteva flote električnih vozila u obliku odzivnih površina [56, 57]. Iz voznih

podataka snimljenih GPS-om se osim voznih ciklusa mogu dobiti i druge značajke flote vozila koje su važne kod ispitavanja mogućnosti elektrifikacije postojeće flote konvencionalnih vozila kao što su [54]: i) razdiobe vremena dolazaka vozila na i odlazaka vozila s mjesta na kojem bi se u slučaju elektrifikacije flote hipotetska električna vozila potencijalno punila [58], ii) razdioba prijeđenih udaljenosti tijekom voznog ciklusa, iii) razdioba trajanja parkiranosti itd.

Osim profila brzine vozila, značajan utjecaj na potrošnju energije/goriva ima i nagib ceste [59], te ga je u svrhu poboljšanja točnosti pripadnih procjena i analiza potrebno uključiti u sintezu (2D opis) voznih ciklusa [48]. Pregledom stanja predmetnog područja tehnike utvrđeno je da postoje dva osnovna pristupa u generiranju (1D) sintetičkih voznih ciklusa iz snimljenih podataka: a) kombiniranjem karakterističnih mikro-ciklusa [60] i b) korištenjem stohastičke metode temeljene na Markovljevim lancima [53, 54, 61]. Pritom se potonjem pristupu daje prednost zbog inherentnog svojstva rješavanja problema „rupa“ uzrokovanih gubitcima GPS signala prilikom snimanja podataka, te zbog mogućnosti uključivanja signala nagiba u opis voznog ciklusa na statistički pouzdan način. Sinteza voznih ciklusa temeljena na Markovljevim lancima tipično se odvija u tri koraka [53, 54]: i) klasteriranje odnosno svrstavanje snimljenih voznih ciklusa u karakteristične skupine prema određenim statističkim značajkama, ii) parametriranje Markovljevog lanca i sukcesivno generiranje sintetičkog voznog ciklusa, te iii) validacija generiranih sintetičkih voznih ciklusa. Neovisno o primijenjenom pristupu, u literaturi se, osim u [48], gotovo isključivo razmatra 1D opis voznih ciklusa.

1.2.3. Modeliranje i optimalno punjenje flote električnih vozila

Postoje dva osnovna pristupa modeliranju flote EV: a) modeliranje svakog pojedinačnog EV unutar flote [8, 9, 62] i b) agregatni pristup modeliranju [3, 4, 10, 11, 63]. Kod agregatnog modeliranja, baterije svih EV unutar flote predstavljene su nadomjesnom baterijom koja ima jednu varijablu stanja (agregatni SoC) i jednu upravljačku varijablu (agregatna snaga punjenja). Zbog svoje računalne učinkovitosti, ovakav pristup modeliranju flote EV posebno je pogodan za potrebe energetskog planiranja kod kojeg se razmatra velik broj EV [4, 11]. Također je prisutan i kod hijerarhijskog punjenja flote EV, koje se sastoji od dvije razine [3,

64]: 1) optimiranje vremenskog profila snage punjenja na agregatnoj razini, te 2) raspodjela optimirane agregatne snage punjenja na pojedinačna EV. Ovaj pristup je naročito pogodan u slučaju kada se zaseban subjekt, tzv. agregator, koristi kao sučelje između flote EV s jedne strane i energetskog sustava i tržišta električne energije s druge strane [8]. Baterije EV mogu se modelirati kao spremnici naboja ili spremnici energije [4, 9], pri čemu zbog svoje jednostavnosti potonji pristup prevladava u raznim studijama energetskog planiranja. Svaki od navedenih tipova modela flote EV podrazumijeva različite ulazne vremenske razdiobe vezane uz broj vozila spojenih na mrežu te potrošnju energije EV u ovisnosti o voznim ciklusima [4, 65, 66]. Razdiobe vezane uz potrošnju energije EV mogu se temeljiti na različitim pretpostavkama [4] ili puno pouzdanije i točnije na simulacijama modela pojedinačnih EV za dani skup snimljenih voznih ciklusa [65, 66]. Kako bi se olakšala sinteza i analiza modela EV kao i općenito simulacija flote EV, skup snimljenih voznih ciklusa može se pogodno nadomjestiti s nekoliko reprezentativnih sintetičkih voznih ciklusa [53, 67]. Pritom se, kako je već spomenuto u prethodnom odjeljku, generiranje sintetičkih voznih ciklusa najčešće ostvaruje korištenjem statističke metode Markovljevih lanaca [53, 54, 58, 68].

Nakon definiranja modela flote EV, potrebno je riješiti problem optimalnog punjenja iste, a kako bi se minimizirala neka unaprijed zadana ciljna funkcija kao što je primjerice trošak punjenja [3, 8-14] ili višak proizvedene energije iz OIE [4, 13, 15]. Problem optimalnog punjenja može se riješiti korištenjem algoritma dinamičkog programiranja (DP), koji daje globalno optimalne rezultate s obzirom na zadanu ciljnu funkciju i pritom zadovoljavajući zadana ograničenja [8, 9, 12]. Međutim, navedeni algoritam nije upotrebljiv za optimiranje sustava s velikim brojem EV zbog velike računalne složenosti [8, 10, 69], ali bi se mogao koristiti za optimiranje punjenja flote EV predstavljene agregatnim modelom baterije. Potom se optimalni agregatni profili snage punjenja mogu rasporediti po pojedinačnim EV korištenjem nekog jednostavnog heurističkog ili optimizacijskog algoritma [3, 64]. Osim hijerarhijskog pristupa punjenju flote postoji i pristup izravnog punjenja pojedinačnih EV unutar flote [8, 9, 12]. No takav pristup ne može jamčiti optimalnost dobivenih rezultata u općem slučaju nelinearnog modela sustava ili nelinearnih ili spregnutih ograničenja. Isto vrijedi i za ostale algoritme izravnog pojedinačnog punjenja, poput linearnog i nelinearnog programiranja, te stohastičkih ili heurističkih algoritama [3, 4, 11, 13-15].

1.3. Hipoteza

Cilj istraživanja provedenog u okviru ovog rada jest razraditi sustavan pristup modeliranju i optimalnom vođenju transportno-energetskog sustava s EV i OIE koji uključuje razvoj optimalnih upravljačkih strategija pojedinačnih EV te razvoj modela flote EV i optimiranje njenog punjenja.

Temeljna hipoteza rada je da formuliranje novog agregatnog modela flote EV, koji vjerno odražava dinamiku priključivanja EV na mrežu i koji se parametrira temeljem računalnih simulacija pojedinačnih EV preko realističnih voznih ciklusa, omogućuje postizanje veće točnosti matematičkog opisa ponašanja flote EV, a time i energetskog planiranja i globalno-optimalnog punjenja koji se zasnivaju na takvom modelu i algoritmu dinamičkog programiranja.

1.4. Pregled rada

Sinteza upravljačke strategije pogona hibridnih električnih vozila, sinteza voznih ciklusa, modeliranje i optimiranje punjenja flote električnih vozila, te analiza tehno-ekonomskih aspekata flote električnih vozila razrađeni su u sedam poglavlja, uključujući uvod i zaključak. U nastavku je dan opis pojedinih dijelova rada.

Drugo poglavlje: *Modeliranje i upravljanje pogonom električnog vozila s produljenim dometom.* Opisuje matematički model te predlaže upravljačku strategiju EREV pogona temeljenu na kombiniranju RB regulatora i ECMS pristupa. Predložena upravljačka strategija provjerena je simulacijom u usporedbi s globalno-optimalnim rezultatima dobivenim primjenom algoritma dinamičkog programiranja.

Treće poglavlje: *Prikupljanje, analiza i sinteza voznih ciklusa.* Opisuje postupak snimanja voznih ciklusa uz primjenu GPS/GPRS uređaja za slučaj karakteristične flote dostavnih vozila vodećeg regionalnog maloprodajnog lanca. Provedena je i opisana numerička analiza snimljenih podataka s ciljem dobivanja preliminarnih uvida u mogućnosti elektrifikacije postojeće flote vozila. Prikazuje se postupak generiranja i validiranja sintetičkih voznih ciklusa iz snimljenih podataka uz primjenu postupka Markovljevih lanaca. Provodi se

usporedba kvalitete sinteze voznih ciklusa za slučajeve da se kao stanja Markovljevog lanca koriste diskretne vrijednosti samo brzine vozila te diskretne vrijednosti brzine i akceleracije vozila. Provedena je i sinteza voznih ciklusa namijenjenih primjeni u modeliranju zahtjeva transporta za energijom odzivnim površinama, a koje se potom koriste kod dvorazinskog optimiranja punjenja flote EV danog u poglavlju 5.

Četvrto poglavlje: *Modeliranje flote električnih vozila.* Nakon pregleda osnovnog modela agregatne baterije preuzetog iz literature, predlaže se nova formulacija analitičkog agregatnog modela baterije, koja uzima u obzir činjenicu da kapacitet i SoC agregatne baterije ovise o (promjenjivom) broju EV spojenih na mrežu. Opisuje se postupak parametriranja agregatne baterije koji se odnosi na generiranje vremenskih razdioba broja vozila spojenih na mrežu i agregatnog SoC-a na temelju snimljenih podataka flote dostavnih vozila i simulacija modela pojedinačnih EV uključujući prethodno razvijenu upravljačku strategiju. Validacija predloženog modela flote vozila provodi se na temelju rezultata optimiranja punjenja flote vozila primjenom algoritma dinamičkog programiranja na agregatnoj razini i heurističkog algoritma raspodjele agregirane snage punjenja na razini pojedinačnih EV.

Peto poglavlje: *Optimiranje punjenja flote električnih vozila.* Opisuje se optimiranje punjenja agregatnog te distribuiranog modela flote EV uz primjenu algoritma dinamičkog programiranja, kako bi se osiguralo globalno-optimalno rješenje. S ciljem ilustracije poboljšanja rezultata optimiranja korištenjem DP algoritma, opisan je i jedan heuristički algoritam punjenja flote EV preuzet iz literature, čiji su rezultati dani usporedno s DP rezultatima. U ovom je poglavlju također predloženo i dvorazinsko optimiranje punjenja gdje se na nadređenoj razini optimira maksimalna snaga punjača te iznos SoC-a pojedinačnih baterija na početku svakog voznog ciklusa (koja je u temeljnom DP algoritmu postavljena na 100%), dok se na podređenoj razini provodi DP optimiranje agregatne snage punjenja flote vozila, sve s ciljem minimiziranja troškova punjenja i zadovoljenja postavljenih ograničenja.

Šesto poglavlje: *Analiza tehno-ekonomskih aspekata primjene flote električnih dostavnih vozila.* Opisuje pilot studiju vezanu uz konkretnu flotu dostavnih vozila za koju su prikupljeni podaci. Razvijen je model postojećeg konvencionalnog dostavnog vozila kao i model električnog dostavnog vozila sličnih karakteristika. Na temelju simulacija modela EV i snimljenih voznih podataka, parametriran je model EV flote opisan u četvrtom poglavlju.

Pored modela flote EV, modeliran je i energetski sustav distributivnog centra dostavnih vozila na satnoj razini. Optimiranje punjenja flote EV provedeno je za različite razdiobe cijena električne energije, te različite scenarije proizvodnje električne energije iz OIE. Rezultati optimiranja iskorišteni su za analizu prednosti elektrifikacije flote dostavnih vozila i uvođenja lokalnih OIE, a s obzirom na smanjenje troškova energije i emisija CO₂.

2. Modeliranje i upravljanje pogonom električnog vozila proširenog dometa

U ovom poglavlju obrađuje se modeliranje i upravljanje na razini jednog električnog vozila proširenog dometa (EREV), kao temelj za parametrisiranje agregatnih modela flote EV obrađenih u sljedećim poglavljima. U prvom potpoglavlju dani su modeliranje i analiza razmatranog pogona. U drugom potpoglavlju dana je matematička formulacija problema optimiranja upravljačkih varijabli pogona. Treće potpoglavlje opisuje sintezu upravljačke strategije. Četvrto potpoglavlje prikazuje simulacijsku provjeru razvijenog modela i upravljačke strategije kao i verifikaciju upravljačke strategije usporedbom pripadnih rezultata simulacije s globalno optimalnim rezultatima dobivenih numeričkim optimiranjem.


2.1. Modeliranje električnog vozila proširenog dometom

2.1.1. Kinematska shema i načini rada pogona vozila

Slika 2-1 prikazuje funkcionalnu shemu pogona odabranog električnog vozila proširenog dometa [36, 37] (*engl. Extended Range Electric Vehicle, EREV*; primjena u Chevrolet Volt/Opel Ampera vozilima). Razmatrani EREV pogon sadrži motor s unutarnjim izgaranjem (SUI, *engl. Internal Combustion Engine, ICE*), dva električna stroja (M/G1 i M/G2), planetarni prijenosnik koji ima funkciju vanjskog djelitelja snage, tri spojke (F1, F2, i F3) namijenjene za mijenjanje načina rada pogona, i elektrokemijsku bateriju.

Prema tablici 2-1, postoje četiri glavna načina rada [36, 37, 38] i mogu se svrstati u tri karakteristične grupe. U prvoj grupi, u kojoj nema dijeljenja snage, spojka F1 je zatvorena, a spojka F2 je otvorena. Prema tome prsten (*r – engl. ring*) planetarnog prijenosnika je zakočen i planetarni prijenosnik je reduciran na standardni jedno-stupanjski prijenosnik, pa je brzina vrtnje M/G2 stroja izravno proporcionalna s izlaznom brzinom vrtnje pogona ω_{cd} kao što je to slučaj kod električnih vozila (EV) ili serijskih hibridnih električnih vozila (SHEV). Spojka F3 se koristi za prebacivanje između potpuno električnog (F3 otvorena) i serijsko-hibridnog električnog (F3 zatvorena) načina rada, gdje potonji način rada podrazumijeva uključivanje

SUI motora. Druga grupa načina rada uključuje dijeljenje snage (F1 otvorena, F2 zatvorena), gdje spojka F2 spaja M/G1 stroj na planetarni prijenosnik, tako kombinirajući oba električna stroja i postavljajući njihove brzine u međusobnu ovisnost i u ovisnost o brzini izlazne osovine ω_{cd} . Ovo rezultira serijsko-paralelnim hibridnim načinom rada (SPHEV, F3 zatvorena), koji je tipičan za različite HEV transmisije s dijeljenjem snage (vidi [38, 70-74] i reference dane tamo), ili dvo-motornim električnim načinom rada (TMEV, *engl. Two Motor Electric Vehicle*, F3 otvorena). Treća grupa, koja nije navedena u tablici 2-1, vezana je uz režim praznog hoda u kojem su spojke F1 i F2 otvorene dok spojka F3 može biti zatvorena u svrhu punjenja baterije ili pokretanja SUI motora ili otvorena u potpunom režimu praznog hoda. Različiti načini rada u tablici 2-1 označeni su varijablom s_{mode} , koja poprima vrijednosti od 0 do 3.



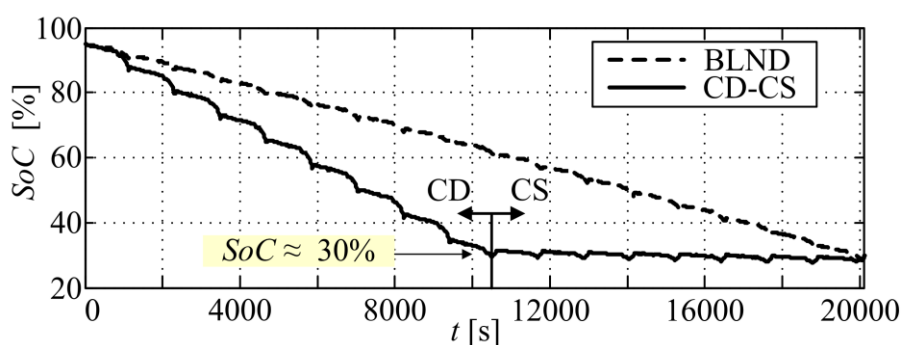
Slika 2-1: Funkcionalna shema EREV pogona.

Tablica 2-1: Karakteristični načini rada EREV pogona.

NAČIN RADA (MOD)	F1	F2	F3	Režim	Dijeljenje snage	s_{mode}
Električna vožnja (EV)	1	0	0	CD	NE	0
Serijska hibridna vožnja (SHEV)	1	0	1	CS	NE	3
Serijsko-paralelna hibridna vožnja (SPHEV)	0	1	1	CS	DA	2
Električna dvo-motorna vožnja (TMEV)	0	1	0	CD	DA	1

EREV pogon tipično radi u potpuno električnom režimu rada u kojem prazni bateriju do neke određene pred-definirane razine SoC-a, koja je u ovom radu postavljena na 30% (*engl. skrać. Charge Depleting, CD*). Ovaj režim rada kombinira EV i TMEV električne načine rada ovisno o brzini vozila i zahtjevu vozača za momentom. Nakon što SoC dosegne spomenutu donju

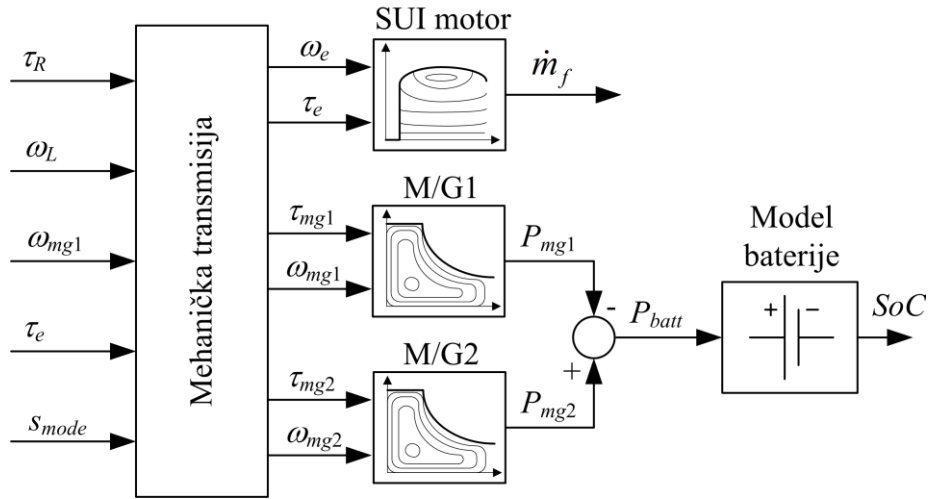
razinu SoC-a, pogon se prebacuje u hibridni režim rada (engl. skrać. *Charge Sustaining*, CS) koji kombinira sva četiri načina rada iz tablice 2-1 kako bi održao SoC baterije na donjoj razini tj. kako bi spriječio preduboko pražnjenje baterije. Kombinacija režima pražnjenja baterije (CD) i režima održavanja SoC-a baterije (CS) označava se s CD-CS [41] i ilustrirana je na slici 2-2. Na istoj slici prikazan je i kombinirani režim rada (engl. skrać. *Blended*, BLND) gdje se baterija postupnije prazni dostižući pred-definirani minimalni SoC tek na kraju voznog ciklusa. U ovom se režimu rada, električni (EV i TMEV) i hibridni načini rada (SHEV, SPHEV) iz tablice 2-1 kombiniraju tijekom cijelog voznog ciklusa.



Slika 2-2: Ilustracija CD-CS i kombiniranog (BLND) režima rada EREV pogona.

2.1.2. Kvazistatički model pogona vozila

U svrhu smanjenja računalne složenosti, za potrebe simulacija pogona vozila ili optimizacija upravljačkih varijabli pogona uobičajeno se koriste kvazistatički modeli pogona vozila [16]. Slika 2-3 prikazuje blokovsku shemu kvazistatičkog modela EREV vozila. Zahtijevani moment τ_R (koji je približno jednak momentu τ_{cd} , vidi izraz (2-2)) i brzina vrtnje $\omega_L = \omega_{cd}$ na izlaznoj osovini dobiveni su korištenjem modela vozača opisanog u odjeljku 2.1.4. Ostali ulazi u model ω_{mg1} , τ_e , s_{mode} , predstavljaju upravljačke varijable koje se postavljaju od strane regulatora ili se optimiraju korištenjem optimizacijskih algoritama. Podmodel transmisije opisan je „invertiranim“ kinematskim jednadžbama danima u tablici 2-2 koje uključuju i mehaničke gubitke u transmisiji [74].



Slika 2-3: Blokovski dijagram kvazistatičkog modela EREV pogona.

Kako se vidi na slici 2-3, izlazi iz podmodela transmisije ω_e i τ_e koriste se za određivanje masenog protoka goriva $\dot{m}_f(\tau_e, \omega_e)$ korištenjem statičke mape specifične potrošnje goriva (g/kWh) prikazane na slici 2-4a [39, 75] i sljedećeg izraza:


$$\dot{m}_f(\tau_e, \omega_e) = \frac{\tau_e \omega_e \bar{m}_f(\tau_e, \omega_e)}{1000 \cdot 3600} \text{ [g/s]}. \quad (2-1)$$

Na isti način su brzine vrtnje i momenti električnih strojeva M/G1 i M/G2 dovedeni na ulaz statičkih mapa korisnosti (slike 2-4bc) u svrhu određivanja korisnosti ovih strojeva [37, 39, 75], a potom i mehaničkih snaga koje se koriste kao ulaz u dinamički model baterije (odjeljak 2.1.3).

Tablica 2-2: Jednadžbe kvazistatičkog modela EREV pogona [38, 74].

NAČIN RADA	s_{mode}	ω_e	τ_{mg1}	ω_{mg2}	τ_{mg2}
EV	0	0	0	$i_o(h+1)\omega_L$	$\frac{1}{i_o(h+1)} \underbrace{\left(\frac{P_0(\omega_L)}{\omega_L} + \frac{\tau_R}{\eta_{mt}(\tau_R)} \right)}_{\tau_{cd}}$
SHEV	3	ω_{mg1}	$-\tau_e$		
SPHEV	2	ω_{mg1}	$h\tau_{mg2} - \tau_e$	$i_o(h+1)\omega_L - h\omega_{mg1}$	
TMEV	1	0	$h \cdot i_o^{-1}(h+1)^{-1} \cdot \tau_{cd}$		

Na slici 2-4 su osim statičkih mapa prikazane i krivulje maksimalnih momenata SUI motora i električnih strojeva. Mape M/G1 i M/G2 strojeva, prikazane na slikama 2-4b i 2-4c samo za prvi kvadrant ($\omega_{mg1,2} \geq 0$, $\tau_{mg1,2} \geq 0$, motorski način rada), vrijede i za ostale kvadrante.




Slika 2-4: Statičke karakteristike SUI motora (a), M/G1 stroja (b) i M/G2 stroja (c).

Koncentrirani model gubitaka snage u transmisiji uključuje gubitke u praznom hodu $P_0(\omega_L)$ i gubitke kod prijenosa snage modelirane mapom korisnosti $\eta_{mt}(\tau_R)$. Prema tome, ukupni moment preračunat na izlaznu osovину kojeg moraju generirati SUI motor, te M/G1 i M/G2 strojevi da bi se zadovoljio izlazni moment na kotačima τ_R opisuje se izrazom

$$\tau_{cd} = \frac{P_0(\omega_L)}{\omega_L} + \frac{\tau_R}{\eta_{mt}(\tau_R)}. \quad (2-2)$$

Mape $P_0(\omega_L)$ i $\eta_{mt}(\tau_R)$ prikazane na slici 2-5 preuzete su iz [76].



Slika 2-5: Mehanički gubitci transmisije u praznom hodu (a) i uslijed opterećenja vezano uz faktor korisnosti (b).

2.1.3. Kvizistatički model baterije

Dinamički model baterije izveden je iz nadomjesnog električnog kruga prikazanog na slici 2-6a te se opisuje sa sljedećom jednačinom stanja [77]:

$$\frac{dSoC}{dt} = \frac{-i(t)}{Q_{max}} = \frac{\sqrt{U_{oc}^2(SoC) - 4R(SoC, i)P_{batt}} - U_{oc}}{2Q_{max}R(SoC, i)}, \quad (2-3)$$

gdje $SoC = q/Q_{max}$ predstavlja stanje napunjenosti baterije (q – naboj u bateriji, $0 \leq SoC \leq 1$), a Q_{max} nabojski kapacitet baterije. U modelu korištenom u ovom radu, napon otvorenog kruga U_{oc} modeliran je u ovisnosti o SoC-u (Slika 2-6b, [24, 78, 79], karakteristika za Li-Ion bateriju preuzeta je iz Autonomie računalnog programa), dok je unutarnji otpor R zbog jednostavnosti postavljen da ovisi samo o predznaku struje $sgn(i)$ iako općenito ovisi i o SoC-u [24] (različite vrijednosti otpora su korištene za pražnjenje (R_{idc}) i za punjenje (R_{ic}), Prilog A). Snaga baterije u jednačini (2-3) računa se na sljedeći način (vidi sliku 2-3):

$$P_{batt} = \eta_{mg2}^{k_2} \omega_{mg2} \tau_{mg2} - \eta_{mg1}^{k_1} \omega_{mg1} \tau_{mg1}, \quad (2-4)$$

gdje su eksponenti k_1 i k_2 jednaki -1 u slučaju da električni strojevi rade u motorskom načinu rada, odnosno $+1$ u slučaju da rade u generatorskom načinu rada.


Korisnost baterije pri punjenju η_c ($P_{batt} < 0$) i pražnjenju baterije η_d ($P_{batt} > 0$) računa se kao

$$\begin{aligned}\eta_c &= 1 + i^2(t)R_{ic} / P_{batt}, \quad \text{za } P_{batt} < 0 \\ \eta_d &= (1 + i^2(t)R_{idc} / P_{batt})^{-1}, \quad \text{za } P_{batt} > 0\end{aligned}\quad (2-5)$$

pri čemu R_{ic} i R_{idc} predstavljaju odgovarajuće unutarnje otpore (vidi Prilog A). Međutim, korisnost baterije korištena u upravljačkoj strategiji osim trenutačnih gubitaka snage u obzir uzima i procijenjene ukupne gubitke snage pri ciklusu punjenja i pražnjenja baterije koji je karakterističan za hibridna vozila (engl. *round-trip losses*, vidi [16]) i računa se prema:

$$\eta_{batt} = \frac{|P_d(t)|}{|P_c(t)|} = \frac{U_{oc}(t) - R_{idc}|i(t)|}{U_{oc}(t) + R_{ic}|i(t)|}. \quad (2-6)$$

Primjerice, pri pražnjenju baterije ova se korisnost može interpretirati kao omjer stvarne snage P_{batt} ($P_d = P_{batt}$) i fiktivne (prethodne) snage punjenja P_c . Pritom se fiktivna snaga punjenja računa tako da se pretpostavi da je struja punjenja imala isti apsolutni iznos (ali suprotni predznak) kao i struja pražnjenja. Ista interpretacija vrijedi i za slučaj punjenja baterija gdje je snaga punjenja P_c stvarna snaga, a snaga pražnjenja P_d fiktivna snaga.



Slika 2-6: Nadomjesni električni krug baterije (a) i karakteristika napona otvorenog kruga za pretpostavljenu Li-Ion bateriju (b).

2.1.4. Modeliranje uzdužne dinamike vozila

Ulazna brzina vrtnje ω_L modela sa slike 2-3 (brzina vrtnje kotača $\omega_L = \omega_{cd}$) dobivena je iz brzine vozila v_v , koja je definirana voznim ciklusom:


$$\omega_L = v_v / r, \quad (2-7)$$

gdje r predstavlja efektivni polumjer auto gume. Moment opterećenja kotača τ_R (zahtjev vozača, Slika 2-3) određuje se na temelju osnovne jednadžbe gibanja vozila [80]:

$$\tau_R = \left(m_v \dot{v}_v + \underbrace{m_v g \sin \alpha + R_o m_v g \cos \alpha + 0.5 \rho_{air} C_d A_f v_v^2}_{\tau_{RL \rightarrow v.s.l.2-8}} \right) r, \quad (2-8)$$

gdje prvi član na desnoj strani odgovara momentu akceleracije vozila, drugi član momentu potrebnom za svladavanje nagiba čiji je kut označen s α , treći član momentu otpora kotrljanja, te četvrti član momentu aerodinamičkog otpora. Parametri modela uključuju masu vozila m_v , konstantu ubrzanja Zemljine sile teže g , koeficijent otpora kotrljanja R_o , gustoću zraka ρ_{air} , površinu frontalnog presjeka vozila A_f , te koeficijent aerodinamičkog otpora C_d . Numeričke vrijednosti ovih parametara dane su u Prilogu A.

Na slici 2-7 prikazani su certifikacijski vozni ciklusi (vremenski profili brzina) koji su korišteni u ovom radu za dobivanje odgovarajućih vremenskih profila brzine ω_L (2-7) i momenta τ_R (2-8) za potrebe optimiranja upravljačkih varijabli (potpoglavlje 2.2) i simulacijske provjere upravljačke strategije (potpoglavlje 2.3).



Slika 2-7: Certifikacijski vozni ciklusi korišteni u optimiranju upravljačkih varijabli i simulaciji EREV pogona.

2.2. Optimiranje upravljačkih varijabli pogona

U ovom potpoglavlju opisati će se algoritam dinamičkog programiranja (DP) [69] te njegova primjena u optimiranju upravljačkih varijabli EREV pogona u CD, CS te kombiniranom (BLND) režimu rada. Rezultati DP optimiranja upotrijebiti će se u poglavljima 2.3 i 2.4 redom za sintezu i verifikaciju upravljačkog sustava vozila. Detalji vezani uz ovo potpoglavlje dani su u [45, 74].

2.2.1. Osnovno o dinamičkom programiranju (DP)

Diskretni optimizacijski problem. Diskretna ciljna funkcija koja se minimizira definira se na sljedeći način:

$$J = \sum_{k=0}^{N_t-1} F(\mathbf{x}_{k+1}, \mathbf{u}_k, k), \quad (2-9)$$

gdje je N_t ukupan broj diskretnih vremenskih intervala, a $\mathbf{x}_k = \mathbf{x}(t_k)$ i $\mathbf{u}_k = \mathbf{u}(t_k)$ su vektori varijabli stanja i upravljačkih varijabli u k -tom diskretnom vremenskom intervalu $t_k = k\Delta T$, $k = 0, 1, \dots, N_t - 1$.

Sustav diferencijalnih jednadžbi koje opisuju dinamički model procesa transformira se u sustav jednadžbi diferencija

$$\mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k, k), \quad k = 0, 1, \dots, N_t - 1. \quad (2-10)$$

Početni i krajnji uvjeti na vektor stanja su

$$\mathbf{x}_0 = \mathbf{x}_i, \quad \mathbf{x}_{N_t} = \mathbf{x}_f. \quad (2-11)$$

Upravljački vektor ograničen je na sljedeće minimalne i maksimalne vrijednosti

$$\mathbf{u}_{\min} \leq \mathbf{u}_k \leq \mathbf{u}_{\max}, \quad k = 0, 1, \dots, N_t - 1. \quad (2-12)$$

Podintegralna funkcija $F(\mathbf{x}_{k+1}, \mathbf{u}_k, k)$ u jednadžbi (2-9) može uključiti i penalizaciju različitih ograničenja na upravljačke varijable i varijable stanja (tzv. mekana ograničenja).

Dinamičko programiranje. S obzirom da optimalni/minimalni iznos ciljne funkcije (2-9) ovisi

o početnom uvjetu $\mathbf{x}_0 = \mathbf{x}_t$ i broju diskretnih vremenskih intervala N_t , uvodi se sljedeća notacija

$$J_{N_t}(\mathbf{x}_0) = \min_{\mathbf{u}_0, \dots, \mathbf{u}_{N_t-1}} \sum_{k=0}^{N_t-1} F(\mathbf{x}_{k+1}, \mathbf{u}_k, k). \quad (2-13)$$

Iz rekurzivne jednadžbe diferencijala (2-10) slijedi da \mathbf{x}_1 ovisi samo o \mathbf{x}_0 i \mathbf{u}_0 (svojstvo kauzalnosti)

$$\mathbf{x}_1 = \mathbf{f}(\mathbf{x}_0, \mathbf{u}_0, 0). \quad (2-14)$$

Iz toga slijedi da se minimizacija (2-13) može provesti kako slijedi

$$J_{N_t}(\mathbf{x}_0) = \min_{\mathbf{u}_0} \left\{ F(\mathbf{x}_1, \mathbf{u}_0, 0) + \min_{\mathbf{u}_1, \dots, \mathbf{u}_{N_t-1}} \sum_{k=1}^{N_t-1} F(\mathbf{x}_{k+1}, \mathbf{u}_k, k) \right\}. \quad (2-15)$$

Analogno s jednadžbom (2-13), drugi član s desne strane jednadžbe (2-15) može se zapisati kao

$$J_{N_t-1}(\mathbf{x}_1) = \min_{\mathbf{u}_1, \dots, \mathbf{u}_{N_t-1}} \sum_{k=1}^{N_t-1} F(\mathbf{x}_{k+1}, \mathbf{u}_k, k) \quad (2-16)$$

pa uz primjenu (2-10) jednadžba (2-15) postaje

$$J_{N_t}(\mathbf{x}_0) = \min_{\mathbf{u}_0} \left\{ F(\mathbf{f}(\mathbf{x}_0, \mathbf{u}_0, 0), \mathbf{u}_0, 0) + J_{N_t-1}(\mathbf{f}(\mathbf{x}_0, \mathbf{u}_0, 0)) \right\}. \quad (2-17)$$

Sada, optimizacijski problem (2-16) s N_t-1 diskretnih vremenskih intervala poprima istu formu kao i originalni optimizacijski problem (2-13) s N_t diskretnih vremenskih intervala. Na isti način se može zapisati i rekurzivna relacija koja povezuje općeniti optimizacijski problem s k diskretnih vremenskih intervala s optimizacijskim problemom s $k-1$ vremenskih intervala:

$$J_k(\mathbf{x}_{N_t-k}) = \min_{\mathbf{u}_{N_t-k}} \left\{ F(\mathbf{f}(\mathbf{x}_{N_t-k}, \mathbf{u}_{N_t-k}, N_t - k), \mathbf{u}_{N_t-k}, N_t - k) + J_{k-1}(\mathbf{f}(\mathbf{x}_{N_t-k}, \mathbf{u}_{N_t-k}, N_t - k)) \right\}, \quad (2-18)$$

gdje k poprima vrijednosti $\{2, \dots, N_t\}$. Slučaj $k = 1$ odgovara uvjetu na konačni vektor stanja $\mathbf{x}_{N_t} = \mathbf{x}_f$ i rješava se prvi. U ovoj fazi, problem se svodi na minimizaciju

$$J_1(\mathbf{x}_{N_t-1}) = \min_{\mathbf{u}_{N_t-1}} F(\mathbf{x}_f, \mathbf{u}_{N_t-1}, N_t), \quad (2-19)$$

koja je radi (2-11) ograničena jednadžbom stanja

$$\mathbf{x}_f = \mathbf{f}(\mathbf{x}_{N_t-1}, \mathbf{u}_{N_t-1}, N_t - 1). \quad (2-20)$$

Prvi korak sastoji se od pronalaženja i spremanja skupa optimalnih rješenja za ovaj jednokoračni optimizacijski problem, koji uključuje vrijednosti ciljne funkcije $J_1(\mathbf{x}_{N_t-1})$ i odgovarajuće vrijednosti optimalnog upravljačkog vektora \mathbf{u}_{N_t-1} za različite vrijednosti vektora stanja \mathbf{x}_{N_t-1} . Potom se jednadžba (2-18) rješava rekurzivno kako bi se dobili $\{J_2(\mathbf{x}_{N_t-2}), \mathbf{u}_{N_t-2}\}$, $\{J_3(\mathbf{x}_{N_t-3}), \mathbf{u}_{N_t-3}\}, \dots, \{J_{N_t}(\mathbf{x}_0), \mathbf{u}_0\}$, te se u svakom koraku traži skup optimalnih rješenja. Nakon faze optimiranja (unatrag u vremenu), optimalni upravljački vektori dobivaju se u rekonstrukcijskoj fazi algoritma iz spremljenih podataka (unaprijed u vremenu). Polazeći od \mathbf{x}_0 i odgovarajućeg optimalnog rješenja \mathbf{u}_0 , te koristeći $\mathbf{x}_1 = \mathbf{f}(\mathbf{x}_0, \mathbf{u}_0, 0)$, dobiva se sljedeći vektor stanja. Iz spremljenih podataka $\{J_{N_t-1}(\mathbf{x}_1), \mathbf{u}_1\}$ za različite vrijednosti vektora stanja \mathbf{x}_1 , dobiva se upravljački vektor \mathbf{u}_1 koji odgovara vektoru stanja $\mathbf{x}_1 = \mathbf{f}(\mathbf{x}_0, \mathbf{u}_0, 0)$. Ponavljajući navedenu proceduru, dobivaju se optimalni upravljački vektori za sve diskretne vremenske trenutke $\{\mathbf{u}_0, \mathbf{u}_1, \dots, \mathbf{u}_{N_t-1}\}$.

DP algoritam pretpostavlja diskretni model procesa i konačni broj diskretnih vrijednosti upravljačkog vektor \mathbf{u} i vektora varijabli stanja \mathbf{x} . Stoga primjena jednadžbe stanja (2-10) općenito rezultira novim vektorom stanja (npr. \mathbf{x}_{N_t-k+1}) koji se nalazi između dviju susjednih unaprijed definiranih diskretnih vrijednosti vektora stanja. U tom se slučaju u optimizacijskoj fazi iznos ciljne funkcije $J_{k-1}(\mathbf{x}_{N_t-k+1})$ u (2-18) dobiva linearnom interpolacijom temeljem iznosa ciljnih funkcija J_{k-1} u susjednim diskretnim vrijednostima vektora stanja. Iz istog se razloga linearna interpolacija koristi i za dobivanje optimalnih upravljačkih vektora u rekonstrukcijskoj fazi iz podataka $\{J_k(\mathbf{x}_{N_t-k}), \mathbf{u}_{N_t-k}\}$ dobivenih u fazi optimiranja.

Uvjet na konačni vektor varijabli stanja \mathbf{x}_{N_t} (2-11) može se zadovoljiti tako da se u ciljnu funkciju (2-19) doda član koji penalizira odstupanje krajnjeg iznosa vektora varijabli stanja \mathbf{x}_{N_t} od zadane vrijednosti \mathbf{x}_f . Penalizacijski član će za slučaj jednodimenzionalnog vektora varijabli stanja biti jednak

$$J_f = K_f (x_f - x_{N_t})^2 = K_f (x_f - f(x_{N_t-1}, \mathbf{u}_{N_t-1}, N_t - 1))^2, \quad (2-21)$$

gdje x_f predstavlja ciljanu konačnu vrijednost varijable stanja dok K_f predstavlja penalizacijski

težinski faktor kojeg treba podići na dovoljno visoku vrijednost da se konačni uvjet zadovolji.

2.2.2. Formulacija optimizacijskog problema za CD režim rada

Cilj optimizacije u CD režimu rada jest pronaći upravljački vektor $\mathbf{u}(t) = [0 \ \omega_{mg1}(t) \ s_{mode}(t)]^T$, $0 \leq t \leq t_f$, koji uz model procesa (2-3) ($x(k) = SoC(k)$) minimizira potrošnju električne energije iz baterije kroz minimizaciju ciljne funkcije (2-9) uz podintegralnu funkciju koja glasi:

$$\begin{aligned}
 F(x(k), \mathbf{u}(k), \mathbf{v}(k)) = & P_{batt}(\mathbf{u}(k), \mathbf{v}(k)) \cdot \Delta T \\
 & + K_g \left\{ H^-(x(k) - x_{\min}) + H^-(x_{\max} - x(k)) \right\} \\
 & + K_g \left\{ H^-(\tau_{mg1}(k) - \tau_{mg1,\min}) + H^-(\tau_{mg1,\max} - \tau_{mg1}(k)) \right\} \quad . \quad (2-22) \\
 & + K_g \left\{ H^-(\tau_{mg2}(k) - \tau_{mg2,\min}) + H^-(\tau_{mg2,\max} - \tau_{mg2}(k)) \right\} \\
 & + K_g \left\{ H^-(\omega_{mg2}(k) - \omega_{mg2,\min}) + H^-(\omega_{mg2,\max} - \omega_{mg2}(k)) \right\}
 \end{aligned}$$

i početni uvjet na varijablu stanja $x(0) = SoC(0) = 0.95$. Pritom se iznosi varijable stanja računaju korištenjem Eulerove diskretizacije $SoC(k+1) = SoC(k) + dSoC(k)/dt \cdot \Delta T$, gdje se $dSoC(k)/dt$ dobiva na temelju jednadžbe (2-3). Vektor $\mathbf{v}(k)$ sadržava brzinu i zahtijevani moment na kotačima, $\mathbf{v}(k) = [\tau_R \ \omega_L]^T$, koji su određeni voznim ciklusom i jednadžbom gibanja (vidi izraze (2-7) i (2-8)). Prvi član na desnoj strani jednadžbe (2-22) penalizira potrošnju električne energije (ΔT predstavlja trajanje jednog diskretnog vremenskog intervala), dok ostali članovi penaliziraju prekoračenje donjih i gornjih, varijabilnih limita momenata električnih strojeva ovisnih o brzinama vrtnje (vidi sliku 2-4) i fiksnih limita brzina vrtnje. Prekoračenje brzine vrtnje M/G1 stroja nije penalizirano zbog toga što se radi o upravljačkoj varijabli koja je ograničena kroz fiksna (“tvrda”) ograničenja na upravljačke varijable. Invertirana Heavisideova funkcija $H^-(x)$ u izrazu (2-22) jednaka je 1 za slučaj $x < 0$, te 0 za slučaj $x \geq 0$. Gornji i donji limiti na varijablu stanja SoC ($SoC_{\max} = 0.99$ i $SoC_{\min} = 0.6$) postavljeni su proizvoljno da pokriju raspon unutar kojeg je očekivano da će se SoC mijenjati tijekom CD radnog režima. Vrijednosti koje varijabla s_{mode} (način rada pogona, Tablica 2-1) može poprimiti su 0 i 1 (EV i TMEV način rada, Tablica 2-1). Penalizacijski težinski faktori K_g postavljaju se u dovoljno visoke vrijednosti da se osigura zadovoljenje postavljenih ograničenja. Kako bi se povećala računalna efikasnost optimizacijskog algoritma, u slučaju $s_{mode} = 0$ (EV način rada) algoritam automatski postavlja vrijednost upravljačke varijable ω_{mg1}

u 0.

2.2.3. Formulacija problema optimiranja za CS i kombinirani režim rada

Formulacija optimizacijskog problema za CS i kombinirani režim rada slična je onoj prikazanoj u odjeljku 2.2.2 za CD režim rada, uz sljedeća proširenja: a) upravljački vektor $\mathbf{u} = [\tau_e \ \omega_{mg1} \ s_{mode}]^T$ uključuje i moment SUI motora τ_e , b) umjesto potrošnje električne energije minimizira se potrošnja goriva, c) penalizacijski članovi uključuju i penalizacije prekoračenja limita brzine vrtnje i momenta SUI motora, te d) varijabla koja određuje način rada pogona dana je u punoj formi $s_{mode} \in \{0,1,2,3\}$ (vidi tablicu 2-1). Shodno tome, podintegralna funkcija iz (2-9) sada glasi:

$$\begin{aligned}
 F(x(k), \mathbf{u}(k), \mathbf{v}(k)) = & \dot{m}_f(\mathbf{u}(k)) \cdot \Delta T \\
 & + K_g \left\{ H^-(x(k) - x_{\min}) + H^-(x_{\max} - x(k)) \right\} \\
 & + K_g \left\{ H^-(\tau_e(k) - \tau_{e,\min}) + H^-(\tau_{e,\max} - \tau_e(k)) \right\} \\
 & + K_g \left\{ H^-(\omega_e(k) - \omega_{e,\max}) + H^-(\omega_{e,\max} - \omega_e(k)) \right\} \quad , \quad (2-23) \\
 & + K_g \left\{ H^-(\tau_{mg1}(k) - \tau_{mg1,\min}) + H^-(\tau_{mg1,\max} - \tau_{mg1}(k)) \right\} \\
 & + K_g \left\{ H^-(\tau_{mg2}(k) - \tau_{mg2,\min}) + H^-(\tau_{mg2,\max} - \tau_{mg2}(k)) \right\} \\
 & + K_g \left\{ H^-(\omega_{mg2}(k) - \omega_{mg2,\min}) + H^-(\omega_{mg2,\max} - \omega_{mg2}(k)) \right\}
 \end{aligned}$$

gdje \dot{m}_f predstavlja maseni protok goriva definiran jednadžbom (2-1) i slikom 2-4a. U slučaju CS režima rada, početni uvjet na varijablu stanja postavljen je na vrijednost $x(0) = SoC(0) = 0.3$, dok je konačni iznos varijable stanja postavljen tako da bude jednak početnoj vrijednosti $SoC(t_f) = SoC(0)$ (uvjet održivosti stanja napunjenosti baterije). Gornje i donje SoC granice postavljene su u $SoC_{\min} = 0.2$ i $SoC_{\max} = 0.4$. U slučaju BLND režima rada, podintegralna ciljna funkcija je ista, dok je početni uvjet na varijablu stanja postavljen na vrijednost $x(0) = SoC(0) = 0.95$ (kao i u CD režimu rada), a konačni uvjet u $SoC(t_f) = 0.3$ (kao i u slučaju CS režima rada). Iz tog su razloga gornje granice SoC varijable u tom slučaju postavljene na vrijednosti $SoC_{\min} = 0.2$ and $SoC_{\max} = 0.99$. U slučaju kad varijabla s_{mode} pretpostavlja vrijednosti 0 i 1 (električni načini rada, EV i TMEV), limit brzine vrtnje SUI motora $\omega_{e,\max}$ postavljen je u 0 kako bi se osiguralo da je SUI motor u tom slučaju isključen, i algoritam automatski postavlja upravljačku varijablu τ_e u 0. Za EV način rada, brzina vrtnje M/G1 stroja je dodatno

postavljena u 0, kao što je objašnjeno u odjeljku 2.2.2.

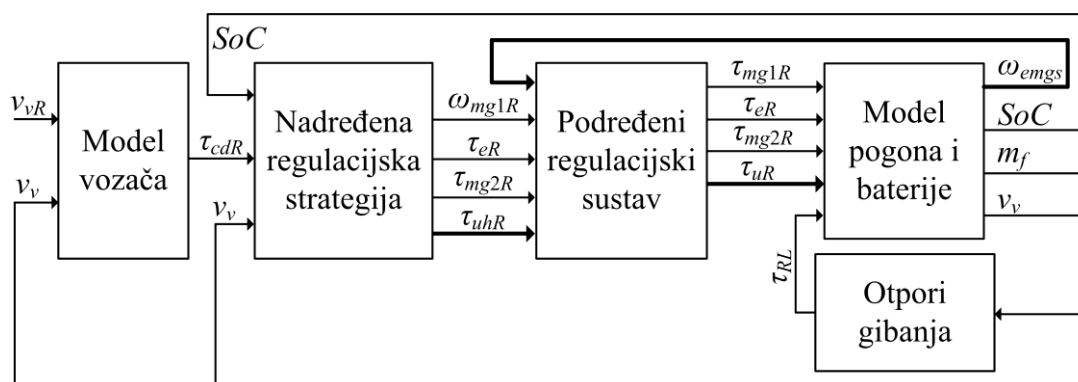
2.3. Upravljačka strategija pogona

2.3.1. Struktura sustava upravljanja

Upravljačka strategija hibridnog pogona uobičajeno se sastoji od podređenog regulacijskog i nadređenog upravljačkog dijela dijela sustava (Slika 2-8) [16, 38]. Podređeni regulacijski podsustav namijenjen je kvalitetnom (brzom i dobro prigušenom) dovođenju komponenti pogona u radne točke koje se postavljaju na nadređenoj razini. Nadređena upravljačka strategija EREV pogona predstavlja se u narednim potpoglavljima, dok je podređena regulacija opisana u disertaciji [74]. Pritom, τ_{uhR} na slici 2-8 označava vektor referentnih stanja spojki F1, F2, i F3 i poprima vrijednosti 0 (spojka isključena) i 1 (spojka uključena), vektor τ_{uR} označava referentne upravljačke varijable aktuatora spojki, a vektor ω_{emgs} sadrži brzine vrtnje SUI motora te M/G1 i M/G2 strojeva. Model prikazan blokovskom shemom na slici 2-8 tipično se realizira kao unaprijedni model (engl. *Forward Model*, FWD) s detaljno modeliranom longitudinalnom dinamikom vozila, dinamikom komponenti pogona te modelom spojki (detaljan dinamički model s pripadnim analizama dan je u disertaciji [74]). Vozač (blok *Model vozača* na slici 2-8) često se modelira kao PI regulator s parametrima podešenima kako bi model pogona točno slijedio zadanu referentnu brzinu vozila [16, 74]. Međutim, u ovom radu se koristi kvazistatički model (engl. skrać. *Backward Model*, BWD) radi računalne učinkovitosti prilikom ispitivanja različitih upravljačkih strategija. Pritom se zahtjev za momentom na kotaču τ_{cdR} , umjesto od modela vozača, dobiva na temelju jednadžbe gibanja (2-8).

Kao što je navedeno u potpoglavlju 2.1, postoje dva osnovna režima rada EREV pogona (Slika 2-2): a) CD/CS, te b) kombinirani (BLND) režim rada. Sukladno tome razmotriti će se zasebno upravljačke strategije za CD, CS i kombinirani režim rada.

Neovisno o režimu rada, upravljačka strategija sastoji se od dva temeljna dijela: a) određivanje optimalnog načina rada pogona i b) određivanja (referentnih) radnih točaka pogona za odabrani način rada, a s obzirom na zahtjev vozača za momentom i uzimajući u obzir fizička ograničenja brzina vrtnje i momenata komponenti pogona.



Slika 2-8: Opća blokovska shema sustava upravljanja EREV pogonom.

2.3.2. Određivanje optimalnog načina rada pogona

Određivanje optimalnog načina rada u CD režimu. U CD režimu rada, samo električki načini rada pogona mogu biti aktivirani: EV i TMEV (Tablica 2-1). U EV načinu rada, samo se M/G2 električni stroj koristi za pokretanje vozila. Njegova radna točka (ω_{mg2} , τ_{mg2}) i odgovarajuća korisnost pogona određena je brzinom vozila v_v i izlaznim momentom τ_{cd} (tj. zahtjevom vozača za momentom, τ_{cdR}). U TMEV načinu rada oba električna stroja (M/G1 i M/G2) koriste se kako bi se zadovoljio zahtjev vozača za momentom na danoj brzini vozila uz poboljšanu korisnost pogona. Na temelju jednadžbi danih u tablici 2-2 (uz $\tau_e = 0$), momenti τ_{mg1} and τ_{mg2} računaju se u proporcionalnoj ovisnosti o izlaznom momentu τ_{cd} . Jedna od brzina vrtnje električnih strojeva (ω_{mg1} ili ω_{mg2}) može se proizvoljno postaviti (dodatan stupanj slobode je uveden u odnosu na EV način rada) kako bi se maksimizirala ukupna korisnost pogona dana izrazom


$$\eta_{TMEV} = \frac{\eta_{mg1}P_{mg1} + \eta_{mg2}P_{mg2}}{P_{mg1} + P_{mg2}}. \quad (2-24)$$

Ova jednadžba daje mapu kombinirane korisnosti prikazane na slici 2-9a (usp. mapu pojedinačne korisnosti M/G2 stroja na slici 2-4c). Iako se za neke kombinacije brzine vozila v_v i zahtjeva za momentom τ_{cd} veća korisnost postiže u EV načinu rada, uglavnom je korisnost veća u TMEV načinu rada (vidi sliku 2-9b). Masno otisnute plave linije na slici 2-9 označavaju rubne krivulje između područja u izlaznoj mapi gdje TMEV način rada daje bolju korisnost nego EV način rada (donje područje) i obrnuto. Pritom je sa stanovišta implementacije graničnu krivulju na slici 2-9b jednostavnije aproksimirati jednostavnom monotonom funkcijom prikazanom punom crvenom

linijom na slici 2-9b.

Nadređena upravljačka strategija prebacuje između EV i TMEV načina rada kad radna točka u izlaznoj mapi prijeđe naznačenu graničnu krivulju. Kako bi se izbjeglo prečesto prekapčanje koje može negativno utjecati na udobnost vožnje, trošenje spojki i sl., uvodi se histereza na graničnu krivulju između dvaju načina rada (crvene krivulje na slici 2-9b).

Uvidom u [37], čini se da je upravljačka strategija pogona stvarnog vozila temeljena na modificiranoj/suženoj graničnoj krivulji (zelena linija na slici 2-9b). Ovo je vjerojatno motivirano željom da se prednosti TMEV načina rada iskoriste samo u radnom području gdje pogon tipično radi na približno konstantnim brzinama tj. pri malim i umjerenim iznosima akceleracija (vožnja na autoputu; vidi crnu liniju na slici 2-9b). Time se izbjegava prečesto prekapčanje dvaju načina rada pri nižim brzinama, tj. kada vozilo često ubrzava tijekom gradske vožnje (radno područje lijevo od zelene linije). Uvođenjem histereze granične krivulje, broj prebacivanja između EV i TMEV načina rada može biti znatno smanjen, što je posebno izraženo kod gradskih voznih ciklusa. Međutim, time se u određenoj mjeri povećava potrošnja električne energije zbog niže korisnosti pogona, što je izraženije uz veću širinu histereze.



Slika 2-9: Kombinirana izlazna mapa korisnosti za TMEV način rada (a), i razlika korisnosti u TMEV i EV načinu rada (b).

Dobar kompromis između udobnosti vožnje, za koju se pretpostavlja da raste s manjom učestalosti promjena načina rada, i korisnosti pogona može se ostvariti uvođenjem praćenja standardne devijacije zahtjeva vozača za momentom $\tau_{R,std}$ u stvarnom vremenu i moduliranjem širine histereze u ovisnosti o tom parametru. Ako je primjerice standardna devijacija zahtjeva

za momentom niska, pretpostavlja se da nagla promjena zahtjeva za momentom neće nastupiti ni u nadolazećem periodu vožnje, pa stoga širina histereze može biti smanjena povećavajući na taj način korisnost pogona čak i za male brzine vozila. S druge strane, veliki iznos $\tau_{R,std}$ ukazuje na gradski način vožnje s čestim stajanjima i kretanjima, i u tom se slučaju postavlja veća histereza kako bi se izbjeglo prečesto prebacivanje između EV i TMEV načina rada.


Ovisnost širine histereze λ i standardne devijacije zahtjeva za momentom $\tau_{R,std}$ uspostavlja se sljedećom linearnom relacijom:

$$\lambda = \frac{\lambda_U - \lambda_L}{\tau_{R,stdU} - \tau_{R,stdL}} (\tau_{R,std} - \tau_{R,stdL}) + \lambda_L, \quad (2-25)$$

gdje λ_U i λ_L predstavljaju redom gornji i donji limit širine histereze (Slika 2-10c), a $\tau_{R,stdU}$ i $\tau_{R,stdL}$ predstavljaju redom gornji i donji limit standardne devijacije zahtjeva za momentom (Slika 2-10b; numeričke vrijednosti pojedinih parametara dane su u Prilogu A). Širina histereze λ se u slučaju prekoračenja nekog od limita λ_U i λ_L postavlja u vrijednost tog limita. Standardna devijacija zahtjeva za momentom $\tau_{R,std}$ računa se korištenjem vrijednosti τ_R iz određenog broja prethodnih diskretnih vremenskih trenutaka (broj tih vrijednosti označava se s N_{buffer}). Pritom se parametar N_{buffer} , zajedno s $\tau_{R,stdU}$, optimira za svaki razmatrani vozni ciklus zasebno, s ciljem smanjenja broja prebacivanja načina rada (N_{mode}) uz zadržavanje povoljne potrošnje energije iz baterije. Optimiranje se provodi linearnim pretraživanjem kroz unaprijed definirane raspone ovih parametara uz ciljnu funkciju $N_{mode}/SoC(t_f)$ koja se minimizira. Pritom se povoljnija vrijednost te kriterijske funkcije postiže za manje iznose N_{mode} i veće iznose $SoC(t_f)$. Pritom su rasponi tih parametara, kao i vrijednosti ostalih parametara iz (2-25), odabrani na temelju analize ovisnosti tih parametara o različitim vrijednostima parametra N_{buffer} .

Slika 2-10 prikazuje vremenske odzive standardne devijacije zahtjeva za momentom $\tau_{R,std}$ i proračunate širine histereze λ za slučaj NEDC voznog ciklusa. Očito, parametar $\tau_{R,std}$ odražava razinu agresivnosti vožnje, i parametar λ se sukladno tome adaptira, što rezultira širom histerezom u slučaju „življe“ vožnje i relativno uskom histerezom za slučaj vožnje s malim varijacijama brzine. Prema (2-25) i pripadnim vrijednostima konstanti λ_U i λ_L danima u prilogu A (Tablica A-2), λ predstavlja širinu histereze na strani momenta M/G2 motora τ_{mg2} .

Međutim, na slici 2-10c, λ je preračunata na moment na izlaznoj osovini τ_R kako bi se mogla usporediti sa skicom histereze na slici 2-9b.



Slika 2-10: Zahtjev vozača za momentom (a), standardna devijacija zahtjeva vozača za momentom (b) i širina histereze EV-TMEV granične krivulje (c) za slučaj NEDC voznog ciklusa.

Određivanje optimalnog načina rada u CS režimu. Regulator zasnovan na bazi pravila (RB regulator) (opisan u odjeljku 2.3.4) određuje hoće li SUI motor biti uključen ili isključen. Kada je SUI motor isključen, električni način rada (EV ili TMEV) se određuje na temelju granične krivulje u izlaznoj mapi u kombinaciji s varijabilnom histerezom, kako je opisano u prethodnoj sekciji. U slučaju da je SUI motor uključen, optimalni način rada odabire se u skladu s pravilima opisanima u nastavku.

Prvo, potrebno je odrediti maksimalni moment koji se može podržati u SPHEV načinu rada za različite brzine vozila (krivulja $\tau_{SPHEV,max}$ na slici 2-11a). Taj moment se izračunava na temelju kinematskih jednadžbi danih u tablici 2-2, te pripadnih krivulja maksimalnih momenata (Slika 2-4). U EV (SHEV) načinu rada moguće je postići bitno veći moment na izlaznoj osovini na širokom rasponu brzine vozila (0-135 km/h; usporedi zelenu i crvenu krivulju). Međutim, na brzinama vozila većim od 135 km/h može se zamijetiti određeno povećanje izlaznog maksimalnog momenta u SPHEV načinu rada u odnosu na osnovni EV način rada ($\tau_{SPHEV,max}$

$> \tau_{EV,max} = \tau_{mg2,max}$).


Potom se za svaku radnu točku (v_v, τ_{cd}) koja se nalazi ispod krivulje maksimalnog SPHEV momenta ($\tau_{SPHEV,max}$), označene na slici 2-11a s plavim i crvenim kružićima, proračunava ECMS ciljna funkcija (definirana u odjeljku 2.3.4) za oba hibridna načina rada (SHEV i SPHEV). Način rada koji rezultira manjim iznosom ECMS ciljne funkcije proglašen je optimalnim (u smislu minimizacije ekvivalentne potrošnje goriva). Rezultati prikazani na slici 2-11a ukazuju da se granica između područja SHEV i SPHEV načina rada može aproksimirati monotonom rastućom krivuljom. Kako bi se izbjeglo prečesto prebacivanje između SPHEV i SHEV načina rada i kako bi se unaprijedila kvaliteta vožnje, na ovu graničnu krivulju se također uvodi histereza koja je ovdje postavljena u fiksnu vrijednost od 20 Nm u izlaznoj mapi (τ_{cd}, v_v). Ovo bi se dodatno moglo unaprijediti ako bi se širina histereza modulirala u ovisnosti o dinamici ciklusa koja se ogleda u standardnoj devijaciji zahtjeva vozača za momentom (kao i kod histereze između EV i TMEV načina rada).

Nadalje, kako bi se poboljšala ukupna korisnost pogona uključenjem potpuno električnog načina rada (EV i TMEV), RB regulator proširen je s dodatnim pravilima dobivenima na temelju rezultata DP optimiranja [30, 45]. Slika 2-11b prikazuje DP-optimalne radne točke za razne načine rada i US06 vozni ciklus, na temelju kojih se postavljaju dodatne granice između SHEV i EV te SPHEV i TMEV načina rada. Pokazano je da su ove granice u velikoj mjeri neovisne o voznom ciklusu (tj. o stilu vožnje; [45]). Temeljem uspostavljenih granica, te u slučaju kad se SoC nalazi u uskom području oko ciljane vrijednosti od 30% za CS režim rada (između 28% i 32%) i kad je SUI motor uključen, upravljanje načinom rada zasniva se na sljedećim pravilima:


1. Ako je SPHEV način rada predodređen kao optimalan (crveno područje na slici 2-11a) i ako se zahtjev vozača za momentom τ_{cd} za danu brzinu vozila nalazi ispod SPHEV-TMEV granice sa slike 2-11b, tada se pogon postavlja u TMEV način rada (inače ostaje aktivan SPHEV način rada).
2. Ako je SHEV način rada predodređen kao optimalan (plavo područje na slici 2-11a) i ako se zahtjev vozača za momentom τ_{cd} nalazi ispod SHEV-EV granice sa slike 2-11b, tada se pogon postavlja u EV način rada (inače ostaje aktivan SHEV način rada).

Konačne granice (bez histereza) svih radnih područja za CD i za CS režim rada prikazane su

na slici 2-12.



Slika 2-11: Optimalna područja hibridnih načina rada određenih minimiziranjem ECMS ciljne funkcije (a), i optimalni načini rada u izlaznoj mapi za US06 vozni ciklus dobiveni DP optimiranjem.



Slika 2-12: Načini rada i pripadna 2D područja u izlaznoj mapi za CD (a) i CS režim rada (b).

2.3.3. Upravljačka strategija za CD režim rada

Nakon određivanja optimalne granice EV i TMEV radnih područja za CD režim rada (vidi slike 2-9b i 2-12a), radne točke električnih strojeva postavljaju se na sljedeći način:

1. Ako je odabran EV način rada, samo se M/G2 stroj koristi za pogon vozila i njegova radna točka je jednoznačno određena zahtjevom vozača za momentom τ_R i brzinom vozila v_v , tj. u skladu s kinematskim jednadžbama danima u tablici 2-2.

2. Ako je odabran TMEV način rada, potrebno je izračunati radne točke (brzine vrtnje i momente) M/G1 i M/G2 električnih strojeva. Momenti ovih strojeva jednoznačno su određeni zahtijevanim momentom τ_{cd} (Tablica 2-2). Međutim, kod određivanja brzina vrtnje strojeva prisutan je jedan stupanj slobode. Stoga se optimalna brzina vrtnje M/G1 stroja zbog njihove kinematske međuzavisnosti (Tablica 2-2) dobiva linearnim pretraživanjem u rasponu od 0 do $\omega_{mg1,max}$ s ciljem maksimizacije kombinirane korisnosti dane izrazom (2-24).

2.3.4. Upravljačka strategija za CS režim rada


Regulator zasnovan na bazi pravila. Slika 2-13 prikazuje blokovski dijagram regulatora zasnovanog na bazi pravila (RB) [29], koji predstavlja jezgru nadređenog upravljačkog sustava, a koji je inspiriran upravljačkim sustavom hibridnog električnog pogona Toyote Prius predstavljenom u [22]. RB regulator računa zahtijevanu snagu SUI motora P_e^* tako da vozačevom zahtjevu za snagom $P_d = \tau_{cd} \cdot \omega_{cd}$ pribraja zahtjev za snagom SoC regulatora P_{batt} . SoC regulator je regulator proporcionalnog tipa s uključenom mrtvom zonom:

$$P_{batt} = \begin{cases} -K_{SoC}(e_{SoC} - \Delta_{SoC}), & \text{za } e_{SoC} > \Delta_{SoC} \\ -K_{SoC}(e_{SoC} + \Delta_{SoC}), & \text{za } e_{SoC} < -\Delta_{SoC} \\ 0, & \text{za } -\Delta_{SoC} \leq e_{SoC} \leq \Delta_{SoC} \end{cases} \quad (2-26)$$

gdje K_{SoC} predstavlja pojačanje regulatora, $e_{SoC} = SoC_R - SoC$ predstavlja odstupanje stvarnog SoC-a od referentnog, dok Δ_{SoC} predstavlja širinu mrtve zone SoC regulatora (vidi sliku 2-13, konkretne vrijednosti dane su u prilogu A, u tablici A-1). Osnovni RB regulator postavlja radnu točku SUI motora približno u područje najveće korisnosti odnosno na krivulju maksimalnog momenta (vidi sliku 2-4a) istodobno zadovoljavajući zahtjev za snagom P_e^* . Drugim riječima, radna točka definirana je presjecištem krivulje maksimalnog momenta SUI motora i hiperbolne krivulje konstantne snage (P_e^*) SUI motora.

RB regulator prikazan na slici 2-13 također sadrži i logiku koja isključuje SUI motor na niskim zahtjevima za snagom ($P_e^* < P_{off}$), kako bi se izbjegao rad ovog motora u području s visokom specifičnom potrošnjom goriva (vidi sliku 2-4a). SUI motor se ponovo uključuje kada zahtjev za snagom P_e^* prijeđe pred-definirani prag P_{on} za koji vrijedi $P_{on} > P_{off}$, kao posljedica povećanog vozačevog zahtjeva za snagom P_d ili zahtjeva SoC regulatora za

punjenjem baterije ($P_{batt} < 0$). Numeričke vrijednosti ovih pragova korištene u CS režimu rada su: $P_{off} = 0$ kW, $P_{on} = 10$ kW.



Slika 2-13: Blokovski dijagram kombiniranog RB i 1D-ECMS regulatora.

Minimizacija ekvivalentne potrošnje goriva (ECMS). U cilju daljnjeg smanjenja potrošnje goriva, uvodi se trenutno optimiranje/minimiziranje ekvivalentne potrošnje goriva (ECMS). Tok snage iz baterije može se promatrati kao ekvivalentan tok fiktivnog goriva \dot{m}_{batt} (prethodno potrošen za pohranu energije u bateriju) koji se pridodaje stvarnom toku gorivu SUI motora \dot{m}_{fuel} [27-29]:

$$\dot{m}_{eq} = \dot{m}_{fuel} + \dot{m}_{batt}(P_{batt}, \eta_{batt}, A_{ek}). \quad (2-27)$$

Na taj način se dobiva ekvivalentan tok goriva \dot{m}_{eq} koji se može zapisati kao

$$\dot{m}_{eq} = \begin{cases} A_{ek} P_e + A_{ek} \eta_{batt} P_{batt}, & \text{za } P_{batt} < 0 \\ A_{ek} P_e + \bar{A}_{ek} \eta_{batt}^{-1} P_{batt}, & \text{za } P_{batt} > 0 \end{cases} \quad (2-28)$$

gdje P_{batt} predstavlja snagu pražnjenja baterije danu izrazom (2-4), η_{batt} je korisnost baterije opisana izrazom (2-6), a A_{ek} je specifična potrošnja goriva SUI motora koja se iz mape prikazane na slici 2-4a, gdje je definirana u g/kWh, dobiva na sljedeći način:

$$A_{ek} = \frac{\bar{m}_f(\tau_e, \omega_e)}{3.6 \cdot 10^6} [\text{g/Ws}]. \quad (2-29)$$

U slučaju pražnjenja baterije, umjesto trenutne uzeta je ekvivalentna specifična potrošnja goriva \bar{A}_{ek} kako bi se u obzir uzela činjenica da je “cijena” trenutne snage pražnjenja baterije vezana uz energiju pohranjenu u bateriji u prethodnom periodu u kojem se baterija punila snagom iz SUI motora u uvjetima različitih vrijednosti A_{ek} . Pritom je za \bar{A}_{ek} uzeta prosječna specifična potrošnja goriva u radnim točkama koje se nalaze na krivulji maksimalnog momenta SUI motora.

U odnosu na gore definiranu ekvivalentnu potrošnju goriva, valjalo bi zamijetiti sljedeće: (i) posebna pažnja posvećena je preciznoj formulaciji \dot{m}_{batt} s naglaskom na formulaciju cikličke baterije i usrednjene specifične potrošnje goriva i (ii) jednadžba (2-27) ne uključuje penalizacijski faktor koji bi se trebao adaptirati složenim adaptivnim upravljačkim zakonom kako bi se SoC održao unutar dozvoljenih granica [28] (umjesto toga održavanje SoC-a prepušta se SoC regulatoru; Slika 2-13).

Cilj ECMS algoritma je minimiziranje sljedeće ciljne funkcije u svakom diskretnom vremenskom trenutku (usporedi izraz (2-23)):

$$\begin{aligned} J = \dot{m}_{eq} + K_g \{ & H^-(\omega_{mg2,max} - |\omega_{mg2R}|) + H^-(\omega_{mg1,max} - |\omega_{mg1R}|) \\ & + H^-(\omega_{eR} - \omega_{e,min}) + H^-(\omega_{e,max} - \omega_{eR}) + H^-(\tau_{eR} - \tau_{e,min}) \\ & + H^-(\tau_{e,max}(\omega_{eR}) - \tau_{eR}) + H^-(\tau_{mg1,max}(\omega_{mg1R}) - |\tau_{mg1R}|) \\ & + H^-(\tau_{mg2,max}(\omega_{mg2R}) - |\tau_{mg2R}|) \} \end{aligned} \quad (2-30)$$

tako minimizirajući ekvivalentnu potrošnju goriva, a pritom zadovoljavajući sva ograničenja u pogonu. Vrijednosti pojedinih fiksnih ograničenja dane su u prilogu A (Tablica A-1), dok su varijabilna ograničenja $\tau_{e,max}$, $\tau_{mg2,max}$, $\tau_{mg1,max}$ prikazana na slici 2-4, te $\tau_{e,min}$ na slici 2-14. Ograničenje na snagu baterije P_{batt} nije penalizirano jer je teorijski iznos maksimalne snage baterije (onaj za koji izraz pod korijenom jednadžbe (2-3) postaje jednak nuli) znatno veći nego što to može pokriti M/G2 ili M/G1 stroj ili njihova kombinacija u TMEV načinu rada.

Kombiniranje RB regulatora i ECMS optimiranja. RB regulator se može kombinirati s ECMS

optimiranjem tako da se ECMS ciljna funkcija optimira preko krivulje konstantne snage SUI motora P_e^* , a koji se proračunava na strani RB regulatora (vidi sliku 2-13). Ovo je ponešto drugačije od osnovnog RB regulatora gdje se radne točke postavljaju na krivulju maksimalnog momenta gdje je specifična potrošnja goriva minimalna (vidi sliku 2-4a). Ova kombinacija RB regulatora i optimiranja ECMS ciljne funkcije preko 1D krivulje konstantne snage (1D-ECMS) može se proširiti i na 2D područje gdje se ECMS ciljna funkcija optimira na širem 2D području u mapi SUI motora (2D-ECMS) s ciljem daljnjeg smanjenja potrošnje goriva (Slika 2-14). Pritom se područje pretraživanja u mapi SUI motora ograničava s donje strane (donja granica $\tau_{e,\min}$ na slici 2-14) kako bi se izbjegao odabir radnih točaka u kojima je specifična potrošnja goriva SUI motora izrazito visoka.

Međutim, iako je 2D-ECMS pristup povoljniji u smislu niže potrošnje goriva, on ne može jamčiti održivost SoC-a pa se stoga kombinira s osnovnim RB+1D-ECMS pristupom koji zbog uključenog SoC regulatora može garantirati održivost SoC-a. Kako bi se iskoristile prednosti obaju pristupa, RB+1D-ECMS-a i 2D-ECMS-a, uvodi se sljedeće pravilo: ako se vrijednost SoC-a nalazi u okolini referentne vrijednosti ($SoC \approx SoC_R$), tada 2D-ECMS dominantno postavlja radne točke pogona; a ako vrijednost SoC-a znatno odstupa od referentne vrijednosti SoC_R onda RB+1D-ECMS dominantno postavlja radne točke pogona.


Upravljačke varijable RB+1D-ECMS algoritma (ω_{eR} , τ_{eR}) kombiniraju se s 2D-ECMS upravljačkim varijablama (ω_{eopt} , τ_{eopt}) na sljedeći način (vidi sliku 2-15a):

$$\omega_{eRmod} = (\omega_{eR} - \omega_{eopt})W(e_{SoC}) + \omega_{eopt}, \quad (2-31)$$

$$\tau_{eRmod} = (\tau_{eR} - \tau_{eopt})W(e_{SoC}) + \tau_{eopt}, \quad (2-32)$$

gdje je $W(e_{SoC})$ glatka težinska funkcija koja poprima vrijednosti između 0 i 1 ovisno o pogrešci SoC-a e_{SoC} , a dobiva se kombiniranjem dviju tangens-hiperbolnih funkcija na sljedeći način:


$$W(e_{SoC}) = \left| \tanh\left\{b\left[e_{SoC} - \tanh(e_{SoC})\right]\right\} \right|. \quad (2-33)$$



Slika 2-14: Ilustracija 1D i 2D područja ECMS optimiranja.

Pritom parametar b određuje širinu raspona u kojem funkcija $W(e_{SoC})$ poprima vrijednosti približno 0. Na slici 2-15b, funkcija je prikazana za dvije vrijednosti parametra b : $b = 500000$ koji se koristi ovdje za potrebe regulacije EREV pogona, te $b = 500$ koji je prethodno korišten za regulaciju HEV pogona [29]. Širina funkcije $W(e_{SoC})$ implicira tolerirani raspon odstupanja SoC-a od željene vrijednosti koji je znatno širi kod HEV-a nego što je to slučaj kod EREV-a (jer se kod potonjeg CS regulacija provodi blizu donjeg dozvoljenog limita SoC-a baterije).

Kvazistatički model EREV pogona implementiran je u Matlab Simulink programskom okruženju, a upravljačka strategija implementirana je u C programskom jeziku u obliku S funkcije unutar Simulinka. Minimizacija ECMS ciljne funkcije provodi se unutar upravljačkog programa korištenjem Hooke-Jeeves optimizacijskog algoritma [81]. Prije provođenja optimizacije, ispituju se radne točke na 1D ili 2D mreži ovisno o tome koja se ECMS optimizacija provodi, te se računaju pripadni iznosi ECMS ciljne funkcije (2-30). Radna točka u kojoj je ECMS kriterij minimalan predstavlja početnu točku iz koje kreće Hooke-Jeeves optimizacija. Na ovaj način se smanjuje vjerojatnost “zaglavljivanja” optimizacijskog algoritma u lokalnom minimumu.



Slika 2-15: Blokovski dijagram RB+1D-ECMS regulatora kombiniranog s 2D-ECMS optimiranjem (a), i grafički prikaz funkcije dane s (2-32).

2.3.5. Upravljačka strategija za kombinirani način rada


Analiza rezultata optimiranja u kombiniranom (BLND) načinu rada. Upravljačke varijable EREV pogona optimirane su za slučaj višestrukih ponavljajućih certifikacijskih voznih ciklusa. Broj voznih ciklusa (prvi stupac u tablici 2-3) izabran je kako bi CD režim rada trajao približno isto vremena kao i CS režim rada (Slika 2-16) u slučaju CD/CS optimizacije. Prema detaljnijim rezultatima optimiranja prikazanim u [45], u ovom su slučaju prednosti BLND režima rada pred CD/CS režimom najviše izražene. Rezultati optimiranja pokazuju da se u BLND režimu rada može postići smanjenje potrošnje goriva od 2.5% do 5% u odnosu na CD/CS režim rada ovisno o voznom ciklusu (detaljni rezultati su dani u tablici 2-7).

Ovo značajno poboljšanje učinkovitosti pogona može se objasniti sljedećim efektima, gdje se prvi efekt smatra dominantnim [45]:

- U BLND režimu postoji veća sloboda optimiranja radnih točaka pogona zbog mogućnosti uključenja svih načina rada za čitavo vrijeme vožnje, gdje se SUI motor tipično koristi za pokrivanje visokih zahtjeva za momentom jer na većim momentima SUI motor ima nižu specifičnu potrošnju goriva (Slika 2-4a), dok električni strojevi pokrivaju niže zahtjeve za momentom/strujom kako bi se minimizirali gubici na unutarnjem otporu u bateriji,

- CD/CS je za razliku od BLND režima karakteriziran relativno dugim radom na niskim vrijednostima SoC-a (CS režim rada), gdje baterija ima nižu korisnost zbog izraženog pada napona i porasta struje i posljedično povećanih gubitaka na unutarnjem otporu.


Iz perspektive sinteze upravljačke strategije tj. definiranja signala SoC_R na slici 2-13, važno je analizirati oblik optimalne SoC trajektorije tijekom BLND režima rada. Slika 2-16 pokazuje da neovisno o voznom ciklusu optimalne SoC trajektorije imaju približno linearan oblik, i dosežu krajnju vrijednost od 30% tek pri kraju voznog ciklusa. Isto zapažanje (ali uz manje egzaktno optimiranje) dano je u [41] za slučaj kad je cesta ravna (bez nagiba), što je upravo slučaj u ovom radu. Prema [41], SoC trajektorija može bitno odstupati od linearnog oblika u slučaju kad je nagib ceste različit od nule.



Slika 2-16: Optimalne SoC trajektorije u CD/CS i BLND režimu rada za slučaj NEDC, HWFET, UDDS i US06 ponavljajućih voznih ciklusa dobivene DP optimiranjem.

Rezultati optimiranja se također mogu iskoristiti za dobivanje optimalnih razdioba pragova uključivanja/isključivanja SUI motora (Slika 2-17). Optimalno podešenje pragova može bitno

doprinijeti smanjenju potrošnje goriva u BLND načinu rada u odnosu na slučaj kad bi se u BLND režimu rada koristili pragovi podešeni za CS režim rada ($P_{off} = 0$ kW, $P_{on} = 10$ kW; pokazano u odjeljku 2.4.3). Kako bi se dobile najučestalije vrijednosti ovih pragova, njihovi medijani su izračunati za svaki vozni ciklus zasebno i za sve cikluse zajedno (DP rezultati u tablici 2-3). Ove vrijednosti daju područja optimalnih vrijednosti pragova, koje će biti iskorištene za postavljanje raspona unutar kojih će se ti pragovi izravno optimirati za slučaj realne upravljačke strategije objašnjene u nastavku, a vezano uz kolonu „DIRECT“ u tablici 2-3. Optimalne vrijednosti pragova isključivanja su većinom ispod 10 kW, dok pragovi uključivanja dostižu vrijednosti od 15 kW, osim u slučaju US06 voznog ciklusa gdje taj prag dostiže vrijednost od 25 kW.



Slika 2-17: Razdioba pragova isključivanja (a) i pragova uključivanja (b) SUI motora, dobivenih iz DP optimizacija za slučaj BLND režima rada i kombiniranog i ponavljajućeg NEDC, HWFET, UDDS i US06 voznog ciklusa (vidi legendu tablice 2-3).

Tablica 2-3: Pragovi uključivanja i isključivanja SUI motora rekonstruirani iz rezultata DP optimiranja i dobiveni primjenom DIRECT optimizacijskog algoritma kod realne upravljačke strategije.

	DP		DIRECT	
	P_{off} [kW]	P_{on} [kW]	P_{off} [kW]	P_{on} [kW]
17xNEDC	2.9	11.0	12.2	14.4
11xHWFET	10.3	14.2	7.8	16.7
15xUDDS	5.3	9.7	6.3	16.7
10xUS06	10.4	25.4	23.9	27.2
COMB¹⁾	7.6	14.1	13.2	14.4

¹⁾ COMB = 17xNEDC+11xHWFET+15xUDDS+10xUS06 za DP,
COMB = 4x(NEDC+HWFET+UDDS+US06) za DIRECT.

Primjena osnovne upravljačke strategije za BLND režim rada. Upravljačka strategija predložena za CD/CS režim rada (slike 2-13 i 2-15) može se uz minimalne modifikacije primijeniti i na BLND režim rada. Ovo je olakšano jer RB uključuje i SoC regulator (Slika 2-13), koji se sada može iskoristiti za slijedenje vremenski promjenjive (umjesto konstantne) referentne SoC trajektorije. Kako je pokazano na slici 2-16, optimalna SoC trajektorija je (približno) linearna i njezin nagib ovisi o trajanju voznog ciklusa t_{dc} :

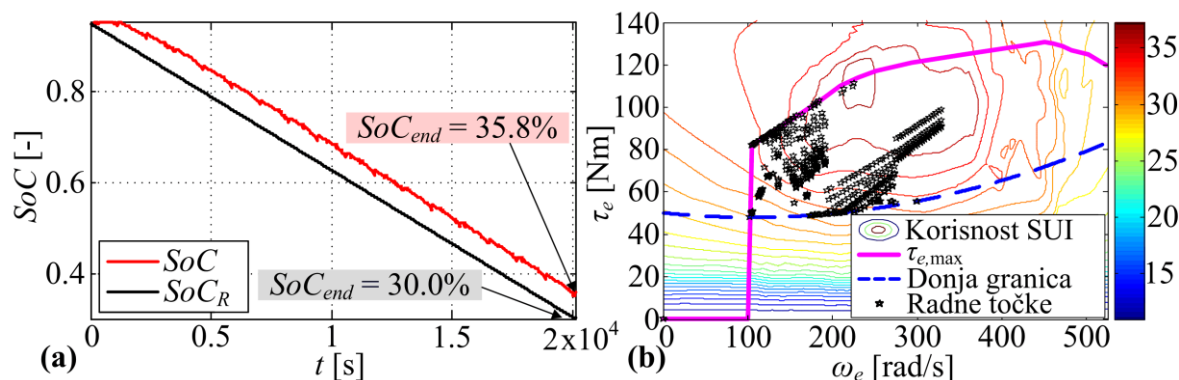
$$SoC_R(t) = SoC_R(0) + \frac{SoC_R(t_f) - SoC_R(0)}{t_{dc}} t. \quad (2-34)$$

Korištenjem polazne upravljačke strategije (podešene za CD/CS način rada) i referentne SoC trajektorije dane izrazom (2-34), dobiva se krajnji iznos SoC-a (na kraju voznog ciklusa) i potrošnja goriva prikazana u tablici 2-8 pod oznakom RB+ECMS1. Usporedbom s rezultatima dobivenima za slučaj CD/CS režima rada (oznaka RB+ECMS0), potrošnja goriva povećava se u slučaju NEDC (+2.9%) i HWFET (+6.7%) voznih ciklusa, a smanjuje u slučaju UDSS (-5.9%) i US06 (-2.7%) voznih ciklusa. Ovo je u suprotnosti s prethodno dobivenim DP optimizacijskim rezultatima, koji pokazuju konzistentno smanjenje potrošnje goriva u BLND režimu rada u odnosu na CD/CS režim rada; NEDC: -4.6%, HWFET: -2.6%, UDSS: -4.1%, US: -4.9% (Tablica 2-7). Dodatne analize provedene su s ciljem razumijevanja zašto RB+ECMS upravljačka strategija ne postiže konzistentno smanjenje potrošnje goriva u BLND režimu rada.

Pokazatelji kvalitete polazne upravljačke strategije primijenjene na BLND režim rada (RB+ECMS1), prikazani u tablici 2-9, pokazuju da je 1D-ECMS upravljanje prilično dominantno u odnosu na 2D-ECMS upravljanje u slučaju svih voznih ciklusa (oko 98% vremena trajanja voznog ciklusa). Također, srednja specifična potrošnja goriva SUI motora prilično odstupa od minimalne/optimalne (260 g/kWh u odnosu na 230 g/kWh).

Radi specifičnog odabira pragova snage SUI motora karakteriziranih niskim pragom isključenja ($P_{off} = 0$ kW, $P_{on} = 10.0$ kW), upravljačka strategija u početku voznog ciklusa puni bateriju i SoC počinje odstupati od referentne SoC trajektorije (Slika 2-18a). Potom, kad odstupanje SoC-a od referentne trajektorije postane značajnije, tj. kad SoC regulator dođe do ruba mrtve zone (Slika 2-13), RB+1D-ECMS preuzima dominaciju i počinje prazniti bateriju

(Slika 2-15 i 2-18a). Kako bi se baterija praznila i kako bi se SoC prisilio da slijedi referentnu trajektoriju, podoptimalan RB+1D-ECMS koji je gotovo cijelo vrijeme tijekom voznog ciklusa aktivan, prisiljava SUI motor da radi u radnom području s manjom korisnošću (Slika 2-18b). Ovo objašnjava lošije performanse realistične upravljačke strategije u BLND režimu rada od CD/CS režima rada za slučaj NEDC i HWFET voznih ciklusa (Tablica 2-8).



Slika 2-18: Referentne i ostvarene SoC trajektorije (a), i razdioba radnih točaka u mapi SUI motora za slučaj inicijalne upravljačke strategije (RB+ECMS1) i 17xNEDC voznog ciklusa.

Unaprjeđenje osnovne upravljačke strategije za BLND režim rada. Kako je 2D-ECMS upravljanje bliže optimalnom djelovanju nego RB+1D-ECMS u smislu potrošnje goriva [30, 40], potrebno je osigurati veću aktivnost 2D-ECMS upravljanja tijekom BLND režima rada. Ovo se može postići tako da se spriječi dodatno punjenje baterije uzrokovano pre niskim pragovima snaga uključivanja/isključivanja SUI motora. Očekivane vrijednosti optimalnih pragova dobivene su DP optimiranjem (Tablica 2-3), i one znatno odstupaju od pragova snaga postavljenih u osnovnoj upravljačkoj strategiji (prag snage isključivanja je bliži pragu snage uključivanja nego što je to slučaj kod osnovne upravljačke strategije, vidi sliku 2-17).

Kako bi se pronašli optimalni pragovi snaga P_{on} and P_{off} upravljačke strategije, korišten je DIRECT (engl. skrać. *Dividing Rectangles*) optimizacijski algoritam [82], koji je inače široko korišten za parametarsko optimiranje. Ciljna funkcija koja se minimizira postavlja se na sljedeći način

$$J = K |SoC_R(t_f) - SoC(t_f)| + m_f(t_f). \quad (2-35)$$

Vrijednost težinskog faktora K postavlja se u vrijednost 10^5 s ciljem uravnoteženja utjecaja

odstupanja krajnjeg iznosa SoC-a od referentne vrijednosti ($SoC_R(t_f) - SoC(t_f)$) i potrošnje goriva $m_f(t_f)$ na rezultate optimizacije. Pritom se postavljaju sljedeća ograničenja na pragove prekapčanja:

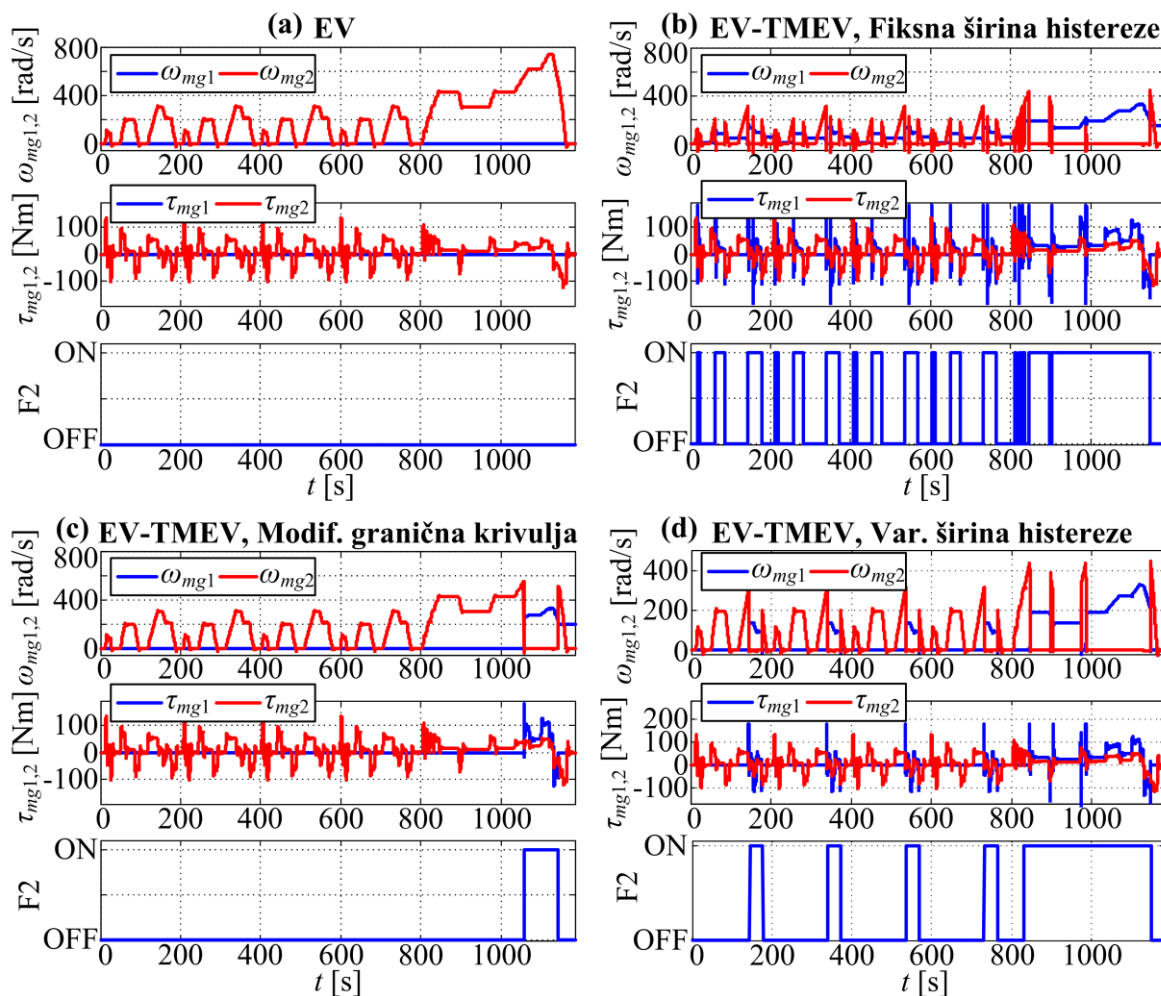
$$P_{off} + 1000 \text{ W} \leq P_{on}. \quad (2-36)$$

Ograničenjem (2-36) osigurava se minimalna vrijednost širine histereze kod uključivanja/isključivanja SUI motora, čime se osigurava praktični zahtjev na udobnost vožnje zbog sprječavanja čestog uključivanja/isključivanja SUI motora. Temeljem rezultata DP optimiranja iz tablice 2-3, raspon unutar kojeg se ovi parametri optimiraju postavljen je u $[0, 20000]$ W za slučaj NEDC, HWFET, UDSS voznih ciklusa, i u $[0, 30000]$ W za slučaj US06 voznog ciklusa. Pragovi snaga dobiveni optimiranjem DIRECT algoritmom, prikazani su u tablici 2-3 zajedno s pragovima rekonstruiranima iz DP optimizacijskih rezultata.

2.4. Simulacijska provjera sustava upravljanja

2.4.1. CD režim rada

Slika 2-19 prikazuje simulacijske rezultate (brzine vrtnje i momente električnih strojeva i stanje spojki $F_2 = \overline{F_1}$) za slučaj samo EV načina rada (Slika 2-19a), te kombiniranog EV i TMEV načina rada s različitim EV/TMEV graničnim krivuljama: i) granična krivulja s histerezom fiksne širine (Slika 2-19b), ii) s modificiranom graničnom krivuljom prikazanoj na slici 2-9b (Slika 2-19c), i iii) s graničnom krivuljom s varijabilnom širinom histereze (Slika 2-19d) za slučaj NEDC voznog ciklusa. Na slici 2-19 može se zamijetiti da se maksimiziranjem kombinirane korisnosti (2-24) u TMEV načinu rada (spojka F2 aktivna) aktivira samo M/G1 stroj ($\tau_{mg1} \cdot \omega_{mg1} \neq 0$) koji ima bitno veću korisnost od M/G2 stroja na manjim opterećenjima (vidi slike 2-4b i 2-4c). M/G2 stroj se deaktivira postavljanjem brzine vrtnje ω_{mg2} u 0.



Slika 2-19: Simulacijski rezultati za CD režim rada za slučaj samo EV načina rada i kombiniranog EV i TMEV načina rada s različitim graničnim krivuljama između EV i TMEV načina rada (b-d) u slučaju NEDC voznog ciklusa.

U slučaju samo EV načina rada, spojka F2 je za vrijeme čitavog voznog ciklusa neaktivna i oblik brzine vrtnje ω_{mg2} prati brzinu vozila v_v (vidi sliku 2-19a i usporedi sa slikom 2-7). Nasuprot tome, simulacijski rezultati za EV-TMEV način rada prikazani na slici 2-19b ukazuju na brojna i česta prebacivanja između EV i TMEV načina rada iako je uvedena histereza kod granične krivulje. To utječe na smanjenje udobnosti vožnje zbog povećane razine vibracija uzrokovanih prečestim mijenjanjem načina rada pogona (također povećavaju se gubici i trošenje spojki). Ovo je značajno unaprijeđeno kod primjene modificirane granične krivulje, gdje su samo dva prebacivanja između EV i TMEV načina rada detektirana, ali nauštrb povećane potrošnje energije (manji SoC na kraju ciklusa, Tablica 2-4). Približno

optimalan EV-TMEV način rada u smislu potrošnje energije postiže se, uz izbjegavanje prečestih promjena načina rada, uvođenjem histereze promjenjive širine (vidi odjeljak 2.3.2 i sliku 2-10). U tablici 2-4 dani su rezultati vezani uz krajnji iznos SoC-a (SoC_f) i broj prebacivanja (N_{mode}) za razmatrane upravljačke strategije i NEDC, HWFET, UDSS i US06 vozne cikluse. Ovi rezultati pokazuju da kombinirani EV-TMEV način rada s uključenom varijabilnom širinom histereze (EV-TMEV-Var.) daje dobar kompromis između potrošnje energije i broja prebacivanja načina rada N_{mode} . Potrošnja energije je u svim slučajevima kombiniranog EV-TMEV načina rada manja (veći SoC_f) u usporedbi s EV načinom rada.

Tablica 2-4: Krajnji iznos SoC-a (SoC_f) te broj prebacivanja načina rada (N_{mode}) za različite upravljačke strategije u CD režimu rada.

	NEDC		HWFET	
	SoC_f [%]	N_{mode} [-]	SoC_f [%]	N_{mode} [-]
EV	86.41	0	81.39	0
EV-TMEV (Fiksna hist.)	87.74	28	83.75	6
EV-TMEV (Modificirana hist.)	86.88	2	82.73	8
EV-TMEV (Varijabilna hist.)	87.62	10	83.74	6
	UDSS		US06	
	SoC_f [%]	N_{mode} [-]	SoC_f [%]	N_{mode} [-]
EV	86.15	0	80.08	0
EV-TMEV (Fiksna hist.)	87.15	66	81.71	40
EV-TMEV (Modificirana hist.)	86.35	4	81.68	28
EV-TMEV (Varijabilna hist.)	86.51	8	81.63	22

Konačno, u tablici 2-5 prikazani su krajnji iznosa SoC-a (uz početni SoC $SoC_i = 0.95$) dobiveni DP optimizacijom i korištenjem kombiniranog EV i TMEV načina rada s varijabilnom histerezom označenog s EV-TMEV (Var.). Rezultati pokazuju da se predložena realistična upravljačka strategija EV-TMEV (Var.) približava globalno optimalnim DP rezultatima unutar 1% za NEDC, HWFET i US06 vozne cikluse. U slučaju UDSS voznog ciklusa, EV-TMEV (Var.) upravljačka strategija je lošija za oko 7%. Ovo se može objasniti nepostojanjem ograničenja na učestalost prebacivanja načina rada kod DP optimiranja, što nije slučaj kod realistične upravljačke strategije gdje je to realizirano uvođenjem histereze na graničnu krivulju. Degradacija kvalitete upravljanja je izražena upravo kod UDSS ciklusa

zbog toga što se radi veće standardne devijacije zahtjeva za momentom (zbog veće „živosti“ ciklusa; vidi sliku 2-7) histereza granične krivulje održava relativno širokom što u konačnici utječe na povećanu potrošnju energije.

Tablica 2-5: RB+ECMS (varijabilna histereza) rezultati u odnosu na globalno optimalne DP rezultate za CD režim rada.

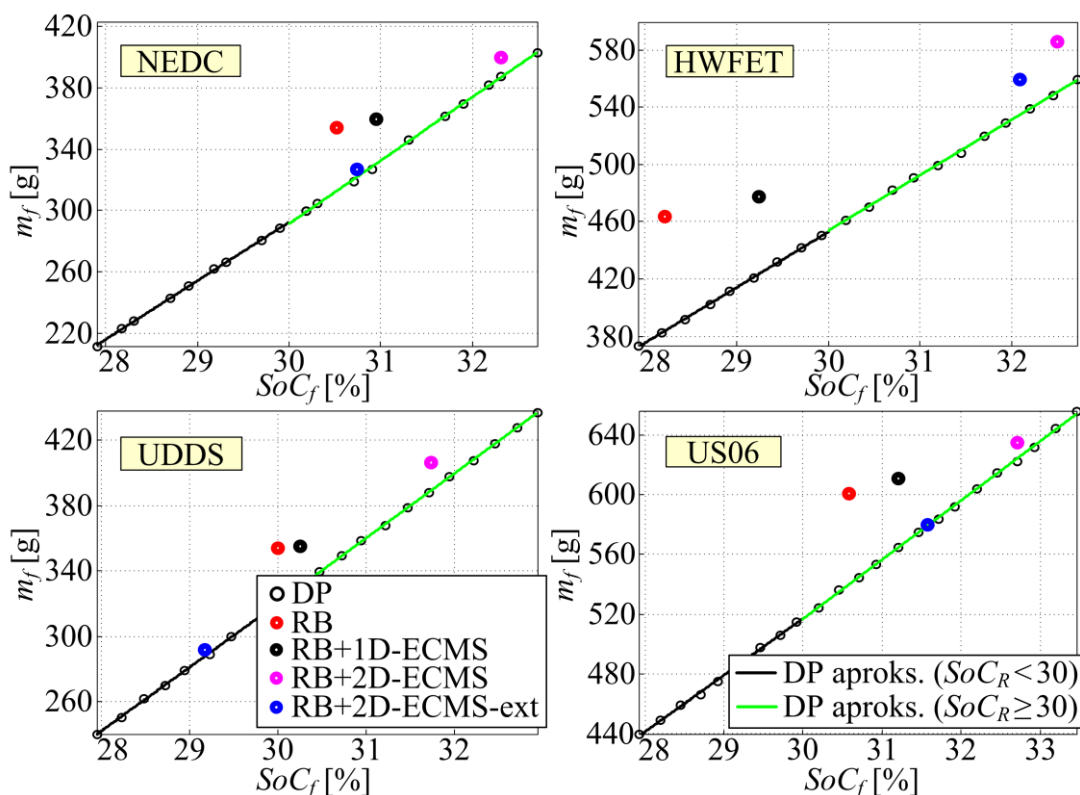
CD režim ($SoC_i = 95\%$)	DP		TMEV (Var.)	
	SoC_f [%]	$SoC_i - SoC_f$ [%]	SoC_f [%]	$SoC_i - SoC_f$ [%]
NEDC	87.68	7.32	87.62	7.38 (+0.8%)
HWFET	83.74	11.26	83.74	11.26 (+0.0%)
UDDS	87.08	7.92	86.51	8.49 (+7.2%)
US06	81.65	13.35	81.63	13.37 (+0.2%)

2.4.2. CS režim rada

Slika 2-20 prikazuje simulacijske rezultate različitih realističnih upravljačkih strategija usporedno s DP rezultatima optimiranja za slučaj CS režima rada. Početni iznos SoC-a se pritom postavlja u vrijednost 30% ($SoC_i = 0.3$). DP optimiranje provedeno je za različite ciljane krajnje iznose SoC-a (vidi izraz (2-21)) u rasponu u kojem se očekivalo da će završiti krajnji iznosi SoC-a realističnih upravljačkih strategija. Dobiveni DP rezultati (m_f vs. SoC_f) aproksimirani su pravcima koji predstavljaju minimalnu moguću potrošnju za različite krajnje iznose SoC-a, jer se radi o globalno optimalnim rezultatima. Realistične upravljačke strategije potom se validiraju u odnosu na te pravce. Prikazani rezultati dobiveni su korištenjem sljedećih realističnih upravljačkih strategija:

- RB – regulator zasnovan na bazi pravila koji radne točke SUI motora postavlja na krivulju maksimalnog momenta,
- RB+1D-ECMS – regulator zasnovan na bazi pravila kombiniran s 1D-ECMS trenutnom optimizacijom (vidi sliku 2-13),
- RB+2D-ECMS – RB+1D-ECMS kombiniran s 2D-ECMS optimizacijom (vidi sliku 2-15a),
- RB+2D-ECMS-ext – RB+2D-ECMS regulator proširen s dodatnim pravilima za određivanje optimalnog načina rada, a temeljenih na SPHEV/TMEV i SHEV/EV granicama dobivenima iz rezultata DP optimiranja (vidi odjeljak 2.3.2 i sliku 2-12b).

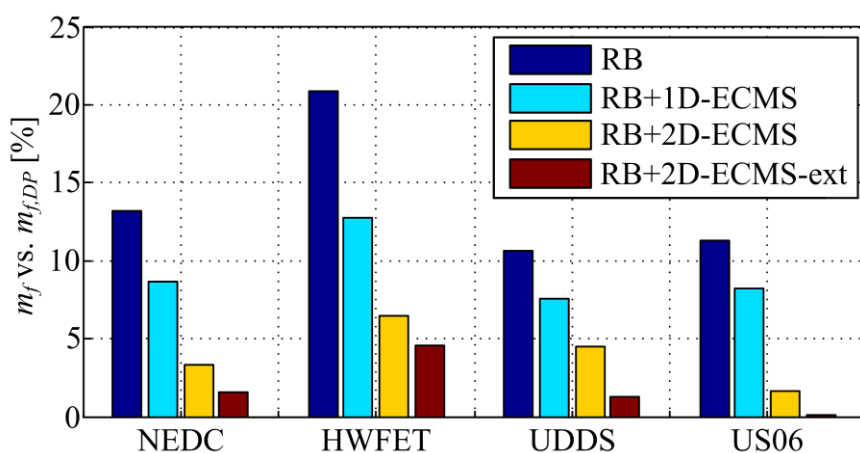
Rezultati na slici 2-20 pokazuju da se rezultati realističnih upravljačkih strategija približavaju DP-optimalnim pravcima, idući od osnovne RB strategije pa do najnaprednije RB+2D-ECMS-ext strategije koja će se u nastavku rada označavati s oznakom RB+ECMS.



Slika 2-20: Grafička ilustracija različitih rezultata realističnih upravljačkih strategija ostvarenih u CS režimu rada u odnosu na globalno optimalne DP rezultate za slučaj različitih vozničkih ciklusa.

Relativno odstupanje potrošnje goriva uz primjenu realističnih upravljačkih strategija od potrošnje goriva dobivene DP optimiranjem na istim krajnjim iznosima SoC-a prikazano je na slici 2-21. Ovi rezultati potvrđuju trendove uočene na slici 2-20. Tablica 2-6 prikazuje numeričke vrijednosti krajnjih iznosa SoC-a i potrošnje goriva DP-a (procijenjene na temelju pravaca sa slike 2-20) i konačne upravljačke strategije RB+ECMS (RB+2D-ECMS-ext). Rezultati pokazuju da RB+ECMS potrošnja goriva prilazi DP potrošnji na oko 1.5% za slučaj NEDC i UDDS ciklusa, 4.6% za slučaj HWFET ciklusa, te 0.2% za slučaj US06 ciklusa. U tablici je dana i procjena prosječne potrošnje goriva na 100 km prijeđene udaljenosti za svaki od ciklusa, koja se kreće oko 3.5l za NEDC, HWFET i UDDS vozne cikluse, te oko 5.5l za

US06 vozni ciklus. Veća prosječna potrošnja goriva kod US06 ciklusa može se objasniti većim brzinama koje se javljaju kod tog ciklusa (do 120 km/h, Slika 2-7) pa posljedično i većim zahtijevanim snagama, zbog čega je RB+ECMS regulator prisiljen postavljati radne točke izvan radnog područja povoljne korisnosti SUI motora (vidi sliku 2-23), ali i koristiti SHEV način rada (manja korisnost pogona nego kod SPHEV načina rada). Osim toga, pri velikim brzinama također se značajno povećava aerodinamički otpor što bitno doprinosi povećanju potrošnje goriva (vidi crnu liniju na slici 2-9b).



Slika 2-21: Usporedba potrošnje goriva različitih realističnih upravljačkih strategija ostvarenih u CS režimu rada u odnosu na DP-optimalnu potrošnju goriva za slučaj različitih voznih ciklusa.

Tablica 2-6: RB+ECMS rezultati u odnosu na globalno optimalne DP rezultate za CS režim rada.

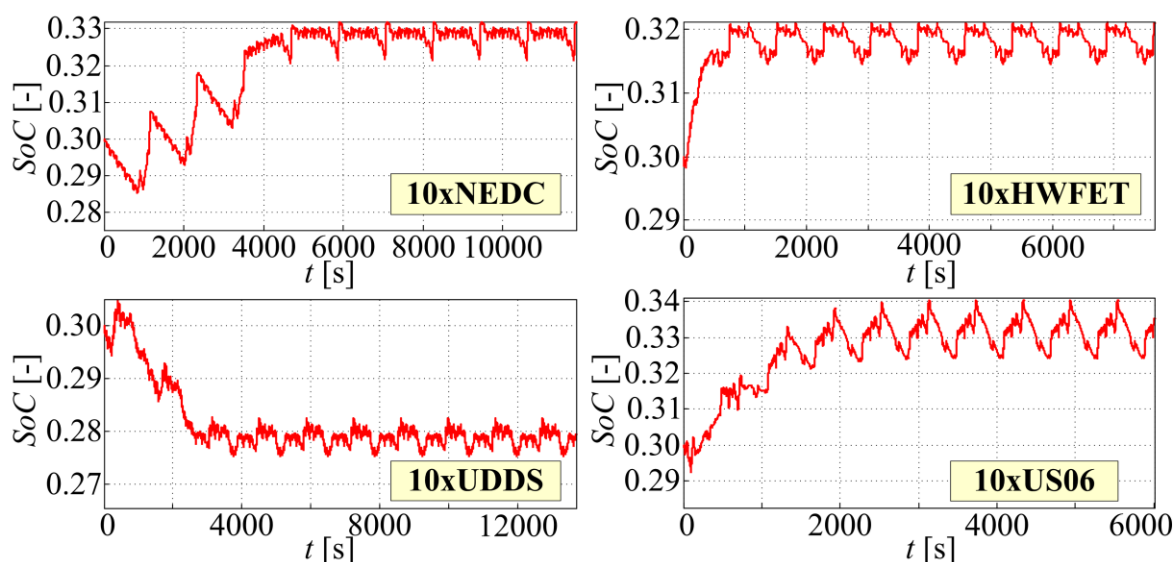
CS režim ($SoC_i = 30\%$)	SoC_f [%]	DP	RB+ECMS	
		** m_f [g]	m_f [g]	* m_f [l/100km]
NEDC	30.74	322.1	327.1 (+1.6 %)	3.59
HWFET	32.10	534.8	559.1 (+4.6 %)	3.63
UDDS	29.17	287.7	291.6 (+1.4 %)	3.43
US06	31.58	579.1	580.1 (+0.2%)	5.35

*Simulacije su provedene na 20 uzastopnih ciklusa kako bi se smanjio utjecaj krajnjeg iznosa SoC-a na procjenu prosječne potrošnje goriva

** DP potrošnja goriva procijenjena je na temelju pravaca danih na slici 2-20 i krajnjih iznosa SoC-a dobivenih RB+ECMS strategijom

Konačno, simulacije su provedene uz korištenje RB+ECMS upravljačke strategije za 10 različitih ponavljajućih voznih ciklusa kako bi se ispitala održivost SoC-a. Slika 2-22

prikazuje SoC trajektorije dobivene tim simulacijama, na kojoj se može vidjeti da je SoC u svim slučajevima ostao održan tj. unutar granica prihvatljivih odstupanja od referentne vrijednosti $SoC_R = 0.3$ u CS režimu rada. Radne točke SUI motora dobivene istim simulacijama za iste ponavljajuće vozne cikluse prikazane su na slici 2-23 gdje se može vidjeti da RB+ECMS većinom smješta radne točke SUI motora u područje visoke korisnosti za slučaj svih voznih ciklusa uz određena odstupanja koja su uzrokovana specifičnostima pojedinih voznih ciklusa.

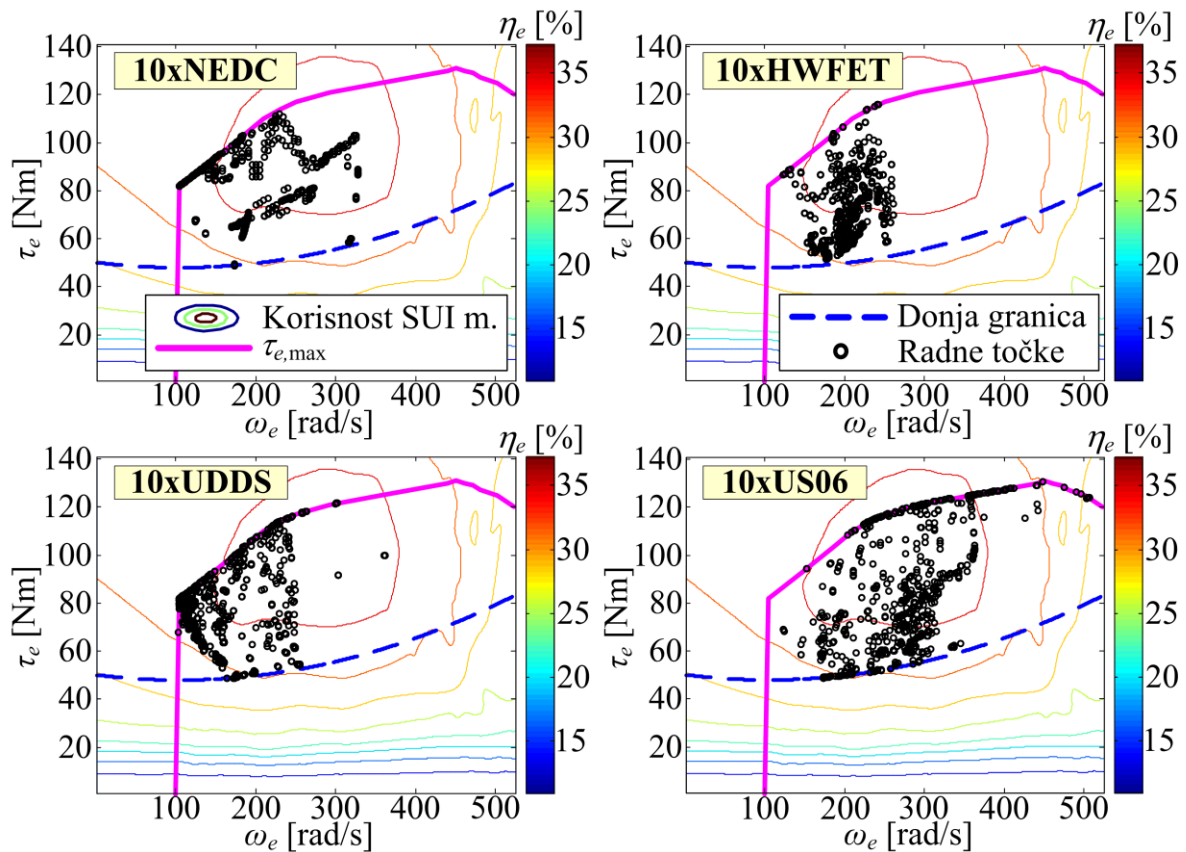


Slika 2-22: SoC trajektorije za 10 NEDC, HWFET, UDDS i US06 ponavljajućih voznih ciklusa (RB+ECMS, CS režim rada).

2.4.3. Kombinirani (BLND) režim rada

Realistična upravljačka strategija RB+ECMS u kombiniranom režimu rada verificirana je usporedbom rezultata simulacija na ponavljajućim voznim ciklusima (za različite pragove snaga P_{off} i P_{on} SUI motora) s globalno optimalnim rezultatima postignutima DP optimiranjem preko istih voznih ciklusa (Tablica 2-7). Pritom su uvedene sljedeće oznake za rezultate:

- (1) RB+ECMS0: rezultati dobiveni u CD/CS režimu rada za slučaj vrijednosti pragova SUI motora inicijalno korištenih u CS režimu ($P_{off}=0$ kW, $P_{on}=10$ kW),
- (2) RB+ECMS1: rezultati dobiveni u BLND režimu rada za slučaj vrijednosti pragova SUI motora inicijalno korištenih u CS režimu ($P_{off}=0$ kW, $P_{on}=10$ kW),



Slika 2-23: Radne točke SUI motora za slučaj 10 NEDC, 10 HWFET, 10 UDDS te 10 US06 ponavljajućih voznih ciklusa (RB+ECMS, CS režim rada).

- (3) **RB+ECMS2**: rezultati dobiveni u BLND režimu rada za slučaj vrijednosti pragova SUI motora optimiranih za svaki ciklus zasebno (stupac DIRECT u tablici 2-3),
- (4) **RB+ECMS3**: rezultati dobiveni u BLND režimu rada za slučaj vrijednosti pragova SUI motora optimiranih za kombinirani ciklus (COMB redak, DIRECT stupac u tablici 2-3).

Vrijednosti konačnog SoC-a (SoC_f) i potrošnje goriva (m_f) dobivaju se simulacijama. Očito, u slučaju nepodešene upravljačke strategije (RB+ECMS1), konačni SoC znatno premašuje ciljane vrijednosti od 0.3 (Tablica 2-7). Ovo je vezano uz nepreciznu SoC regulaciju, komentiranu kod opisa slike 2-18. U slučaju podešene strategije, posebno u slučaju strategije podešene za svaki ciklus zasebno (RB+ECMS2), krajnja vrijednost SoC-a bitno se približava ciljanoj vrijednosti od 0.3 (vidi odziv SoC-a na slici 2-24). Međutim, kako bi se postigla valjana usporedba potrošnje goriva za različite strategije (u odnosu na DP rezultate u tablici 2-

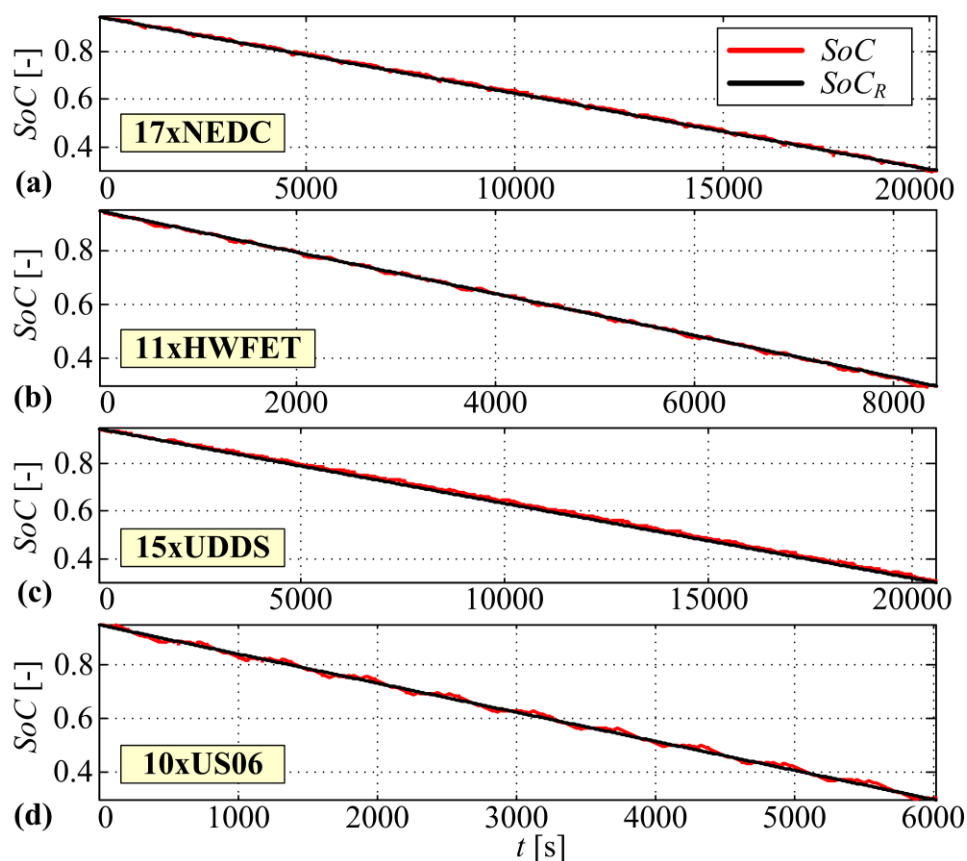
7, odnosno na RB+ECMS0 u tablici 2-8), potrebno je podesiti krajnje iznose SoC-a, rezultata koji se uspoređuju, na iste vrijednosti. To se postiže uzastopnim ponavljanjem simulacija za različite vrijednosti nagiba referentne trajektorije SoC-a (korekcija trajektorije dane s (2-34)). Vrijednosti nagiba trajektorije SoC-a u uzastopnim simulacijama postavljane su korištenjem algoritma binarnog pretraživanja. Dobivene vrijednosti tako korigiranog krajnjeg iznosa SoC-a i potrošnje goriva prikazani su u tablici 2-7 kao $SoC_{f,c}$ odnosno $m_{f,c}$. Korigirana potrošnja goriva $m_{f,c}$ korištena je za računanje relativnih odnosa izraženih u postocima (Tablica 2-7).

Tablica 2-7: Usporedni rezultati DP optimiranja i simulacija različitih realističnih upravljačkih strategija za slučaj NEDC, HWFET, UDDS, i US06 ponavljajućih voznih ciklusa.

17xNEDC	SoC_f [%]	m_f [g]	$SoC_{f,c}$ [%]	$m_{f,c}$ [g]
DP, CD/CS	29.90	2439.7	29.90	2439.7 (0.0%, -)
DP, BLND	29.89	2328.1	29.89	2328.1 (-4.6%, 0.0%)
RB+ECMS1	35.81	3014.0	29.9	2749.8 (+12.7%, +18.1%)
RB+ECMS2	30.02	2442.7	29.9	2438.6 (-0.1%, +4.7%)
RB+ECMS3	29.98	2441.1	29.9	2441.8 (+0.08%, +4.9%)
11xHWFET	SoC_f [%]	m_f [g]	$SoC_{f,c}$ [%]	$m_{f,c}$ [g]
DP, CD/CS	29.75	2444.3	29.75	2444.3 (0.0%, -)
DP, BLND	29.76	2379.8	29.76	2379.8 (-2.6%, 0.0%)
RB+ECMS1	35.25	3043.9	29.76	2793.4 (+14.3%, +17.4%)
RB+ECMS2	30.01	2422.2	29.76	2413.6 (-1.3%, +1.42%)
RB+ECMS3	26.96	2331.3	29.76	2443.4 (-0.04%, +2.67%)
15xUDDS	SoC_f [%]	m_f [g]	$SoC_{f,c}$ [%]	$m_{f,c}$ [g]
DP, CD/CS	30.22	2247.6	30.22	2247.6 (0.0%, -)
DP, BLND	29.82	2156.1	29.82	2156.1 (-4.1%, 0.0%)
RB+ECMS1	35.04	2646.8	29.82	2438.7 (+8.5%, +13.1%)
RB+ECMS2	30.65	2450.2	29.82	2424.2 (+7.9%, +12.4%)
RB+ECMS3	30.13	2411.6	29.82	2402.4 (+6.9%, +11.4%)
10xUS06	SoC_f [%]	m_f [g]	$SoC_{f,c}$ [%]	$m_{f,c}$ [g]
DP, CD/CS	29.88	2726.5	29.88	2726.5 (0.0%, -)
DP, BLND	29.91	2593.8	29.91	2593.8 (-4.9%, 0.0%)
RB+ECMS1	40.59	3296.0	29.91	2863.6 (+5.0%, +10.4%)
RB+ECMS2	30.61	2728.9	30.61	2728.9 (+0.09%, +5.2%)
RB+ECMS3	38.51	3133.2	29.91	2795.9 (+2.5%, +7.7%)

Legenda: RB+ECMS i (BLND), $i = 1$: Vrijednosti pragova SUI motora korištene inicijalno u CS režimu rada ($P_{off}=0$ kW, $P_{on} = 10$ kW); $i = 2$ and 3: Pragovi snaga optimirani za individualne vozne cikluse odnosno za kombinirani vozni ciklus. Prvi postotak unutar zagrade označava relativni odnos potrošnje goriva u odnosu na DP-CD/CS, dok drugi označava relativni odnos prema DP-BLND.

Na temelju rezultata danih u tablici 2-7, može se primijetiti da je potrošnja goriva RB+ECMS2 usporediva s rezultatima DP optimiranja za slučaj CD/CS režima rada (prvi postotak u zagradama u tablici 2-7). Usporedbom s rezultatima DP optimiranja za BLND režim rada (drugi postotak u zagradama u tablici 2-7), potrošnja goriva podešenih upravljačkih strategija je veća za oko 2% za HWFET ciklus, oko 5% za NEDC i US06 cikluse, i oko 10% za UDSS vozni ciklus. Ovi postotci su bitno lošiji (veći) za nepodešenu upravljačku strategiju RB+ECMS1.



Slika 2-24: Referentne i ostvarene SoC trajektorije za slučaj NEDC (a), HWFET (b), UDSS (c) i US06 (d) ponavljajućih voznih ciklusa (RB+ECMS čiji su pragovi optimirani za svaki ciklus zasebno – RB+ECMS2, BLND režim rada).

U tablici 2-8 dana je usporedba rezultata simulacija istih upravljačkih strategija s osnovnom upravljačkom strategijom RB+ECMS0. U ovom slučaju su krajnji iznosi SoC-a različitih strategija podešeni (podešavanjem nagiba referentne trajektorije SoC-a) da budu jednaki krajnjem SoC-u dobivenom RB+ECMS0 strategijom. Rezultati pokazuju da podešene

upravljačke strategije RB+ECMS2 i RB+ECMS3 daju konzistentno smanjenje (otprilike -5% do -7%) potrošnje goriva u odnosu na osnovnu CD/CS upravljačku strategiju (RB+ECMS0). Pri tome je važno zamijetiti da je potrošnja goriva usporediva za RB+ECMS2 i za RB+ECMS3 (vidi također tablicu 2-7), što znači da nema značajnijeg pogoršanja performansi kad je podešavanje upravljačke strategije obavljeno na kombiniranom voznom ciklusu umjesto na ciljanom (unaprijed) poznatom voznom ciklusu. Osim postizanja bolje točnosti slijeđenja referentne SoC trajektorije (Slika 2-24), poboljšanje performansi podešenih upravljačkih strategija može se objasniti podacima danima u tablici 2-9, koji pokazuju da je 2D-ECMS upravljanje, koje inače postiže bolju korisnost pogona, dominantno većinu vremena kod podešenih upravljačkih strategija za razliku od nepodešenih gdje je 1D-ECMS upravljanje dominantno većinu vremena. Poboljšanje se također ogleda i u smanjenju prosječne specifične potrošnje goriva $A_{ek,mean}$ kod RB+ECMS2 i RB+ECMS3 rezultata. Konačni zbirni rezultati prikazani u tablicama 2-7 i 2-8 dani su u tablici 2-10.

Tablica 2-8: Usporedni rezultati RB+ECMS (CD/CS) strategije i različitih tipova RB+ECMS (BLND) strategije za slučaj NEDC, HWFET, UDDS, i US06 ponavljajućih voznih ciklusa.

17xNEDC	SoC_{f,c} [%]	m_{f,c} [g]
RB+ECMS0	33.19	2813.0 (0.0%)
RB+ECMS1	33.19	2895.28 (+2.9%)
RB+ECMS2	33.19	2647.71 (-5.9%)
RB+ECMS3	33.19	2618.25 (-6.9%)
11xHWFET	SoC_{f,c} [%]	m_{f,c} [g]
RB+ECMS0	32.11	2723.7 (0.0%)
RB+ECMS1	32.11	2905.43 (+6.7%)
RB+ECMS2	32.11	2609.29 (-4.2%)
RB+ECMS3	32.11	2535.38 (-6.9%)
15xUDDS	SoC_{f,c} [%]	m_{f,c} [g]
RB+ECMS0	27.95	2511.7 (0.0%)
RB+ECMS1	27.95	2364.18 (-5.9%)
RB+ECMS2	27.95	2360.01 (-6.0%)
RB+ECMS3	28.08	2346.72 (-6.6%)
10xUS06	SoC_{f,c} [%]	m_{f,c} [g]
RB+ECMS0	33.52	3086.2 (0.0%)
RB+ECMS1	33.52	3003.92 (-2.7%)
RB+ECMS2	33.52	2882.3 (-6.6%)
RB+ECMS3	33.52	2935.96 (-4.9%)

Legenda: RB+ECMS_i, *i* = 0: CD/CS režim za slučaj pragova SUI motora inicijalno korištenih u CS režimu rada; za *i* = 1, 2, 3: pogledati legendu u tablici 2-7. Postotne vrijednosti u zagradama označavaju relativnu potrošnju goriva u odnosu na RB+ECMS0.

Tablica 2-9: Specifična potrošnja goriva, te postotci vremena aktivnosti 1D-ECMS i 2D-ECMS upravljanja (vidi sliku 2-15a) za slučaj NEDC, HWFET, UDDS, US06 ponavljajućih voznih ciklusa (RB+ECMS, BLND režim rada).

17xNEDC	$A_{ek,mean}$ [g/kWh]	1D-ECMS [%]	2D-ECMS [%]
RB+ECMS1	267.6	97.9	2.1
RB+ECMS2	240.3	3.9	96.1
RB+ECMS3	240.3	3.9	96.1
11xHWFET	$A_{ek,mean}$ [g/kWh]	1D-ECMS [%]	2D-ECMS [%]
RB+ECMS1	268.1	98.5	1.5
RB+ECMS2	239.7	3.4	96.6
RB+ECMS3	247.5	92.8	7.2
15xUDDS	$A_{ek,mean}$ [g/kWh]	1D-ECMS [%]	2D-ECMS [%]
RB+ECMS1	257.8	98.5	1.5
RB+ECMS2	241.3	17.8	82.2
RB+ECMS3	235.4	10.7	89.3
10xUS06	$A_{ek,mean}$ [g/kWh]	1D-ECMS [%]	2D-ECMS [%]
RB+ECMS1	252.1	97.7	2.3
RB+ECMS2	240.3	13.4	86.6
RB+ECMS3	246.4	97.0	3.0

Legenda: RB+ECMS i , $i = 1, 2, 3$: pogledati legendu u tablici 2-7. $A_{ek,mean}$ označava srednju vrijednost specifične potrošnje goriva. Postotci kod 1D-ECMS-a i 2D-ECMS-a označavaju relativno trajanje pojedinih strategija u ukupnom vremenu.

Tablica 2-10: Zbirni usporedni rezultati iz tablica 2-7 i 2-8.

17xNEDC	RB+ECMS1	RB+ECMS2	RB+ECMS3
DP, CD/CS	+12.7%	-0.1%	+0.1%
DP, BLND	+18.1%	+4.7%	+4.9%
RB+ECMS0	+2.9%	-5.9%	-6.9%
11xHWFET	RB+ECMS1	RB+ECMS2	RB+ECMS3
DP, CD/CS	+14.3%	-1.3%	-0.04%
DP, BLND	+17.4%	+1.4%	+2.7%
RB+ECMS0	+6.7%	-4.2%	-6.9%
15xUDDS	RB+ECMS1	RB+ECMS2	RB+ECMS3
DP, CD/CS	+8.5%	+7.9%	+6.9%
DP, BLND	+13.1%	+12.4%	+11.4%
RB+ECMS0	-5.9%	-6.0%	-6.6%
10xUS06	RB+ECMS1	RB+ECMS2	RB+ECMS3
DP, CD/CS	+5.0%	+0.1%	+2.5%
DP, BLND	+10.4%	+5.2%	+7.7%
RB+ECMS0	-2.7%	-6.6%	-4.9%

Legenda: Objašnjenje notacije pogledati u tablicama 2-7 i 2-8. Postotci u tablici označavaju relativni odnos potrošnje goriva dobivene strategijama danima u stupcima s potrošnjom goriva dobivenom strategijama danima u retcima.

3. Analiza i sinteza voznih ciklusa

Ovo poglavlje uključuje statističku analizu snimljenih voznih podataka vezanih uz flotu dostavnih vozila, te sintezu reprezentativnih voznih ciklusa primjenom postupka Markovljevih lanaca. Pritom se ispituju i uspoređuju dva pristupa sintezi voznih ciklusa, koji se razlikuju po tome uzimaju li se kao stanja Markovljevog lanca samo podaci o brzini vozila ili podaci i o brzini i o akceleraciji vozila.

3.1. Prikupljanje, obrada i analiza voznih ciklusa flote vozila

3.1.1. Opis transportnog sustava

Razmatrani transportni sustav tvrtke Konzum d.d. sastoji se od nekoliko tipova dostavnih vozila koji uključuju laka dostavna vozila, namijenjena opskrbi prodajnih centara u užem gradskom centru, te teška dostavna vozila namijenjena opskrbi prodajnih centara u susjednim i udaljenim gradovima. Skup srednjih dostavnih vozila, svaki nosivosti 7460 kg, odabran je kao reprezentativan skup razmatrane flote dostavnih vozila iz razloga što su ova vozila široko korištena i pokrivaju oba tipa spomenutih voznih misija. Prije analize snimljenih voznih podataka provode se sljedeći koraci: i) planiranje prikupljanja podataka, ii) snimanje podataka, i iii) računalna predobrada podataka koja uključuje i provjeru konzistentnosti podataka.

Budući da su dostavna vozila većinu vremena parkirana u distributivnom centru na Žitnjaku, odakle preuzimaju robu za opskrbu prodajnih centara, većina statističkih analiza biti će vezana za distributivni centar. Razlog tome je predviđanje da bi se hipotetska flota električnih vozila, u slučaju elektrifikacije postojeće flote konvencionalnih vozila, punila upravo u distributivnom centru.

3.1.2. Prikupljanje i početna obrada podataka

Vozni podaci prikupljeni su korištenjem namjenske GPS opreme ugrađene u vozila i bežičnog prijenosa podataka temeljenog na GPRS tehnologiji. Vrijeme uzorkovanja postavljeno je na 1

sekundu, a rezolucija mjerenja brzine vozila iznosi 0.1 km/h. Vrijeme uzorkovanja od 1 sekunde osigurava dovoljnu gustoću podataka potrebnu za različite analize podataka kao i za rekonstrukciju raznih signala kao što su akceleracija i brzina vozila u slučaju gubitaka signala.

Snimljeni vozni podaci uključuju:

1. ID broj vozila,
2. vremenske trenutke u formatu: datum : sat : minuta: sekunda,
3. geografska dužina (GPS X koordinata) u stupnjevima,
4. geografska širina (GPS Y koordinata) u stupnjevima,
5. nadmorska visina [m],
6. brzina vozila [km/h],
7. brzina motora [rpm],
8. kumulativna potrošnja goriva u litrama (rezolucija 0.5 l).

ID broj vozila omogućava statističke analize vezane uz pojedinačna vozila, ali taj podatak ovdje nije korišten jer su analize usmjerene na sve podatke u svrhu karakterizacije čitave flote vozila. Podaci vezani uz nadmorsku visinu mogu biti upotrijebljeni za buduće studije vezane uz utjecaj nagiba ceste na potrošnju goriva (koji nije dominantan jer se radi o pretežno ravnim cestama, npr. grad Zagreb i okolica). Konačno, snimljeni podaci o kumulativnoj potrošnji goriva mogu se iskoristiti za različite studije vezane uz potrošnju energije kao i za rekonstrukciju mapa specifične potrošnje goriva (inače ovisne o brzini vrtnje i okretnom momentu motora).

Podaci upotrijebljeni u ovom radu uključuju vremenske trenutke, geografsku dužinu i širinu, brzinu vozila i kumulativnu potrošnju goriva. Podaci o vremenskim trenutcima iskorišteni su za detekciju mogućih gubitaka podataka (u slučajevima kad je vremenska razlika dvaju susjednih podataka veća od 1 sekunde), za detekciju dupliciranih podataka (u slučajevima kad dva ili više susjednih podataka imaju zabilježeno isto vrijeme), i posebno za statističke analize za koje su potrebni podaci o vremenu. Na temelju geografske dužine i širine, izračunati su pomaci vozila u referentnom 2D koordinatnom sustavu između dva susjedna vremenska trenutka korištenjem jednadžbi koje se općenito koriste za određivanje malih pomaka na sferi velikog radijusa

$$\Delta X(k) \approx \frac{R_z \pi}{180} \cdot [X_{GPS}(k) - X_{GPS}(k-1)], \quad (3-1)$$

$$\Delta Y(k) \approx \frac{R_z \pi}{180} \cdot [Y_{GPS}(k) - Y_{GPS}(k-1)], \quad (3-2)$$

gdje $R_z = 6370$ km označava srednji radijus Zemlje. Dakle, označavanjem koordinata referentne točke s $(X(0), Y(0))$, i korištenjem jednadžbi (3-1) i (3-2), moguće je pomoću sljedećih jednadžbi rekonstruirati 2D trajektoriju vozila:

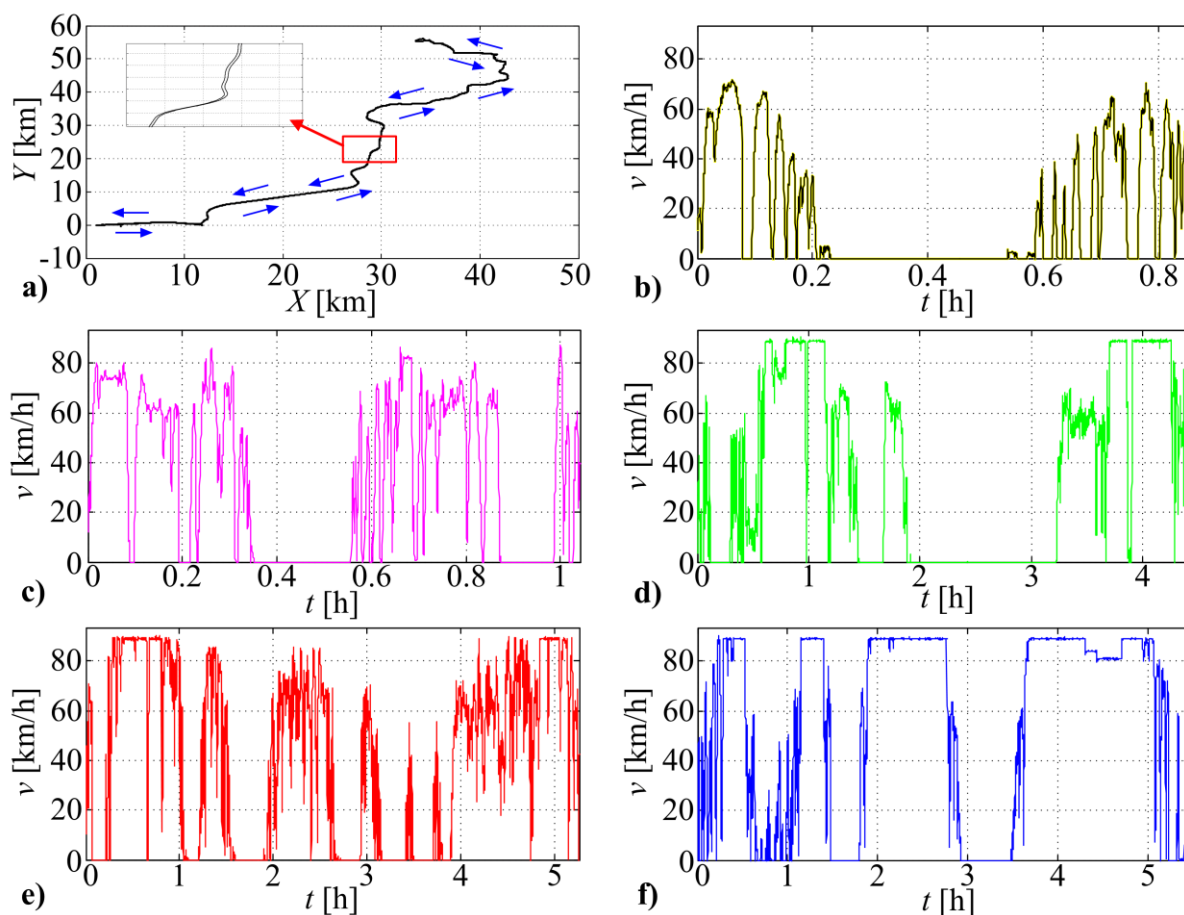
$$X(k) = X(0) + \sum_{i=1}^k \Delta X(i). \quad (3-3)$$

$$Y(k) = Y(0) + \sum_{i=1}^k \Delta Y(i). \quad (3-4)$$

Također, korištenjem izračunatih pomaka iz jednadžbi (3-1) i (3-2) moguće je izračunati i ukupni prijeđeni put:

$$L(k) = \sum_{i=1}^k \sqrt{\Delta X^2(i) + \Delta Y^2(i)}. \quad (3-5)$$

Slika 3-1a prikazuje snimljenu trajektoriju dostavnog vozila tijekom jedne od međugradskih voznih misija. Detalj trajektorije prikazan na istoj slici ilustrira kvalitetu snimljenih podataka u smislu glatkoće trajektorije i točnosti prikaza lijeve i desne kolničke trake autoputa. Slika 3-1b-f prikazuje razne snimljene vozne cikluse (od trenutka odlaska pa do trenutka povratka u distributivni centar), koji ovisno o destinacija vozila, uključuju gradsku vožnju (kraći vozni ciklusi), te vožnju na autocesti na konstantnoj maksimalnoj brzini od 90 km/h (dulji vozni ciklusi).



Slika 3-1: Trajektorija vozila snimljena na međugradskoj ruti (a) i primjeri raznih snimljenih voznih ciklusa (b)-(f).

3.1.3. Statistička obrada podataka


Detaljna statistička analiza voznih podataka neophodna je sa stanovišta procjene mogućnosti i isplativosti zamjene konvencionalnih vozila s električnima, i za svrhu dobivanja pouzdanih modela transportnog sustava. Razmatrana izolirana flota vozila posebno je pogodna za analize zbog minimalnih pretpostavki koje se trebaju uvesti kod tvorbe modela, za razliku od složenih transportnih sustava na razini gradova ili država.

Geografske lokacije glavnog distributivnog centra ili individualnih prodajnih centara važne su za analize zato što su vozila često parkirana ondje (i spremna za punjenje u slučaju primjene električnih vozila). Smatra se da se vozilo nalazi u distributivnom ili prodajnom centru ako je zadovoljena sljedeća jednadžba

$$(X(k) - X_{centre})^2 + (Y(k) - Y_{centre})^2 \leq R, \quad (3-6)$$


gdje, u skladu s jednadžbama (3-3) i (3-4), $X(k)$ i $Y(k)$ označavaju koordinate vozila u diskretnom vremenskom trenutku k , X_{centre} i Y_{centre} označavaju središnje koordinate distributivnog ili prodajnog centra, a R označava radijus kružnice koja obuhvaća centar i unutar koje se pretpostavlja da je vozilo parkirano.

Vremenske razdiobe dolazaka i odlazaka vozila. Vremenske razdiobe dolazaka i odlazaka vozila dobivene su prebrojavanjem dolazaka i odlazaka unutar svakog sata tijekom perioda od tri mjeseca. Ove razdiobe su prikazane na 24-satnoj vremenskoj bazi. Vozilo se smatra da je došlo u centar (distributivni ili prodajni) u diskretnom vremenskom trenutku k ako jednadžba (3-6) vrijedi za k -ti i ne vrijedi za $k-1$ trenutak. Slično tome, vozilo se smatra da je napustilo centar u k -tom trenutku ako jednadžba (3-6) vrijedi za $k-1$ trenutak i ne vrijedi za k -ti trenutak. Slika 3-2 prikazuje razdiobe dolazaka i odlazaka vozila vezanih uz distributivni centar i flotu od 10 vozila za čitavi period od tri mjeseca (91 dan). Može se zamijetiti nekoliko karakterističnih vrhova u objema vremenskim razdiobama. U vremenskoj razdiobi odlazaka istaknuti vrhovi nalaze se oko 7h, 15h i 21h. Razdioba dolazaka ima približno isti oblik kao i razdioba odlazaka. Međutim, razdioba odlazaka je vremenski pomaknuta u odnosu na razdiobu dolazaka, gdje pomak tijekom ranih jutarnjih sati iznosi oko 5 sati, dok pomaci vezani uz dnevne vrhove iznose oko 1-2 sata. Navedeni pomaci ukazuju na prosječno trajanje parkiranosti vozila i posljedično na spremnost hipotetskih električnih vozila za punjenje: sporo i jeftino punjenje tijekom noći, te brzo i znatno skuplje punjenje tijekom dana ili večeri.



Slika 3-2: Vremenske razdiobe dolazaka u i odlazaka vozila iz distributivnog centra.

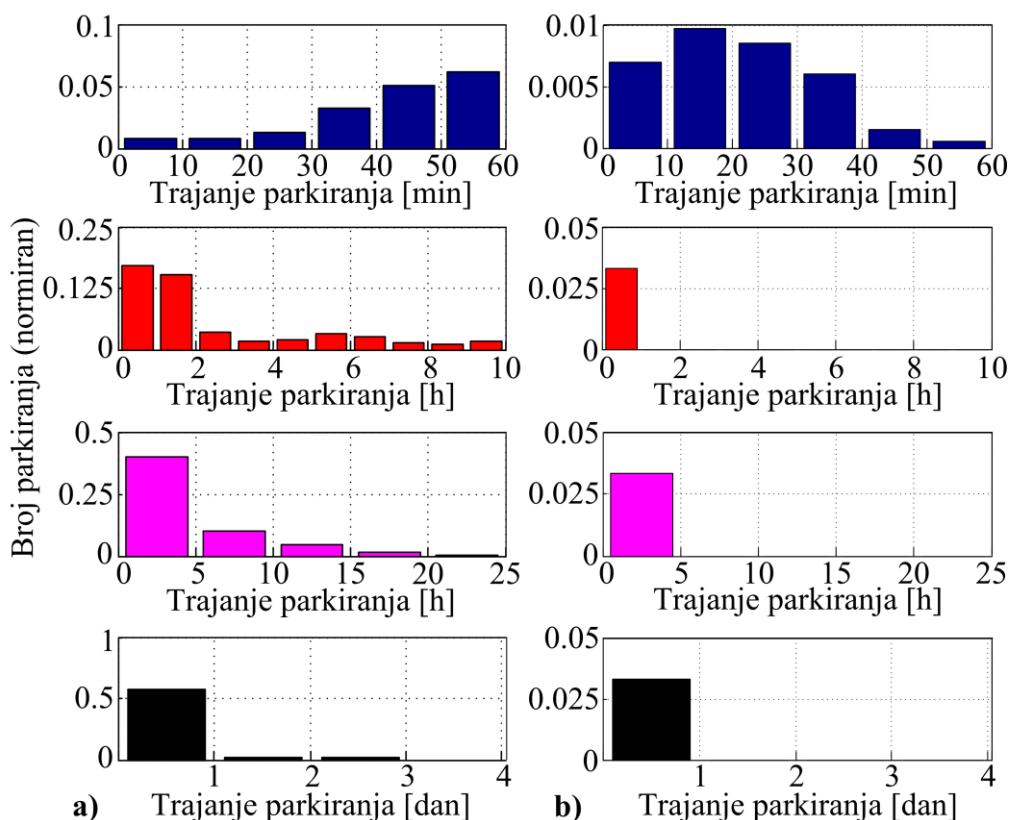
Slika (3-3) prikazuje razdiobe vremena dolazaka i odlazaka za jedan od prodajnih centara. Kao što je očekivano, postoji jasna korelacija između oblika razdioba dolazaka u prodajni centar i odlazaka iz distributivnog centra, i obratno. Međutim, jutarnji vrh (7-9h) prisutan u razdiobi odlazaka iz distributivnog centra (Slika 3-2) izostaje iz razdiobe dolazaka u dani (pojedinačni) centar. Također, u slučaju prodajnog centra, nije zamijećen pomak između razdioba dolazaka i odlazaka danih na satnoj vremenskoj bazi, što implicira da je stvarno kašnjenje odlazaka u odnosu na dolaske, odnosno vrijeme boravka vozila u prodajnom centru manje ili jednako jednom satu.



Slika 3-3: Vremenske razdiobe dolazaka u i odlazaka vozila iz jednog prodajnog centra.

Razdiobe trajanja mirovanja vozila na parkingu. Razdiobe trajanja mirovanja vozila na parkingu distributivnog centra ili prodajnih centara predstavlja ključni podatak za planiranje sustava punjenja električnih vozila, koji uključuje algoritme naprednog (tzv. „pametnog“) punjenja i procjenu utjecaja punjenja vozila na elektroenergetski sustav distributivnog ili prodajnog centra.

Slika 3-4a prikazuje razdiobe trajanja mirovanja za distributivni centar (na različitim vremenskim bazama od minuta do dana). Ovi rezultati pokazuju da većina trajanja mirovanja iznose između 30 minuta i 2 sata. Drugi izražen vrh trajanja mirovanja je oko 6 sati, što je povezano s noćnim i ranojutarnjim periodima. Ovi rezultati potvrđuju preliminarna opažanja vezana uz analize razdioba dolazaka i odlazaka vozila za slučaj distributivnog centra (Slika 3-2). Trajanja mirovanja dulja od 6 sati vezana su uz vikend (treća podslika na slici 3-4a), dok su trajanja mirovanja dulja od jednog dana iznimke (četvrta podslika na slici 3-4a).

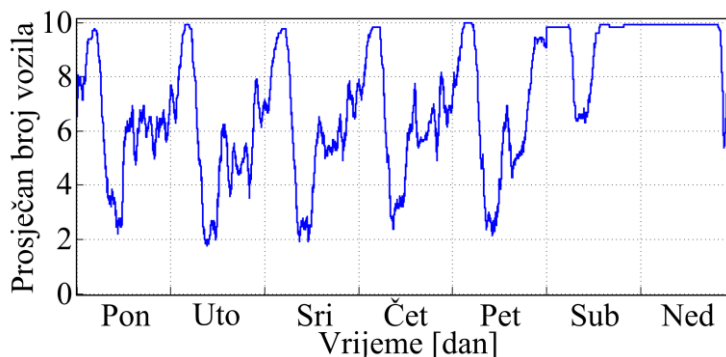


Slika 3-4: Razdiobe trajanja mirovanja/parkiranosti vozila u distributivnom centru (a) i u jednom prodajnom centru (b).

Slika 3-4b prikazuje trajanje mirovanja vozila za isti prodajni centar za koji su na slici 3-3 prikazane razdiobe dolazaka i odlazaka. U skladu s rezultatima sa slika 3-2 i 3-3, trajanja mirovanja značajno su kraća u slučaju prodajnog centra nego što je to bio slučaj kod distributivnog centra. Vrh razdiobe trajanja mirovanja u prodajnom centru je oko 20-30 minuta, a razdioba pada na nulu već kod trajanja mirovanja od 50-60 minuta. Trajanja mirovanja dulja od jednog sata nisu zabilježena za slučaj ovog prodajnog centra.

Sljedeća relevantna statistička veličina vezana je uz vremensku razdiobu prosječnog broja vozila (od ukupno 10 vozila) parkiranih u distributivnom centru. Ova razdioba prikazana je na slici 3-5 za vremenski period od jednog tjedna (dobiven usrednjavanjem podataka s punog perioda od 91 dana) i vremena uzorkovanja od 1 sekunde. Razdiobe su dobivene na sljedeći način. Prvo, za svaki dan u tjednu, inicijaliziran je nul vektor (brojač) veličine $24 \times 3600 = 86400$ elemenata (ukupan broj sekundi u danu). Nadalje, vrijednost svakog elementa vektora, koji odgovara jednoj sekundi u danu, povećana je za 1 ako se pripadni vremenski trenutak (sekunda) nalazi između

neko vrijeme dolaska i odlaska vozila (vrijeme unutar kojeg se vozilo nalazi u distributivnom centru). Taj postupak se ponavlja za sve zabilježene parove dolazaka i odlazaka iz distributivnog centra. Konačno se svaki element vektora dijeli s ukupnim brojem tjedana (ovdje 13) unutar kojih su se snimali podaci.



Slika 3-5: Tjedna razdioba prosječnog broja parkiranih vozila u distributivnom centru (podaci snimljeni tijekom 91 dana usrednjeni na tjednoj vremenskoj bazi).


Razdioba broja parkiranih vozila sa slike 3-5, prikazana je na slici 3-6a na 24-satnoj vremenskoj bazi zasebno za svaki pojedinačni dan u tjednu. Ove 24-satne razdiobe prosječnog broja parkiranih vozila preko jednog tjedna usrednjene su i prikazane na slici 3-6b. Rezultati dani na slikama 3-5 i 3-6 pokazuju da su vremenske razdiobe prosječnog broja parkiranih vozila vrlo slične za radne dane u tjednu (PON-PET). Iznimno, razdioba vezana uz petak počinje odstupati od razdioba ostalih radnih dana (PON-ČET) u drugoj polovici dana (oko 19h). Razdioba vezana uz subotu karakterizirana je određenom, vrlo malom aktivnošću samo tijekom jutarnjih sati. Tijekom većeg dijela nedjelje, gotova sva vozila parkirana su u distributivnom centru, te počinju svoje vozne misije u večernjim satima, kada razdioba počinje nalikovati onima za večernje sate radnih dana.

Razdiobe preko radnih dana (Slika 3-6) otkrivaju da su u prosjeku gotovo sva vozila parkirana u distributivnom centru između 3h i 5h. Do 9h broj parkiranih vozila postepeno opada do minimalne vrijednosti koja nastupa između 9 i 12h. Potom, broj parkiranih vozila raste te se stabilizira u popodnevnim satima, te postepeno dodatno raste približavanjem večeri.

Prikazani rezultati, pogotovo oni sa slike 3-6b, važni su iz perspektive naprednog punjenja hipotetske flote električnih vozila u glavnom distributivnom centru i njegovog utjecaja na

električnu mrežu. Vozila su većinom dostupna za punjenje tijekom večernjih sati i vikenda kad je električna energija jeftina i kad bi punjenje električnih vozila efektivno pridonijelo poravnanju opterećenja mreže. Također, značajna dostupnost za punjenje tijekom popodnevnih sati može se iskoristiti za punjenje vozila električnom energijom proizvedenom iz solarnih panela potencijalno instaliranih na krovu distributivnog centra.

Iz perspektive agregatnog modeliranja flote električnih vozila, važno je zamijetiti da jednostavno usrednjavanje svih dana u tjednu na jedan dan uvodi određenu pogrešku (Slika 3-6b). Razdiobe prikazane na slici 3-6a sugeriraju da bi se minimalno tri različite dnevne razdiobe trebale upotrijebiti za visoku točnost modeliranja: one za radni dan, za subotu te za nedjelju.

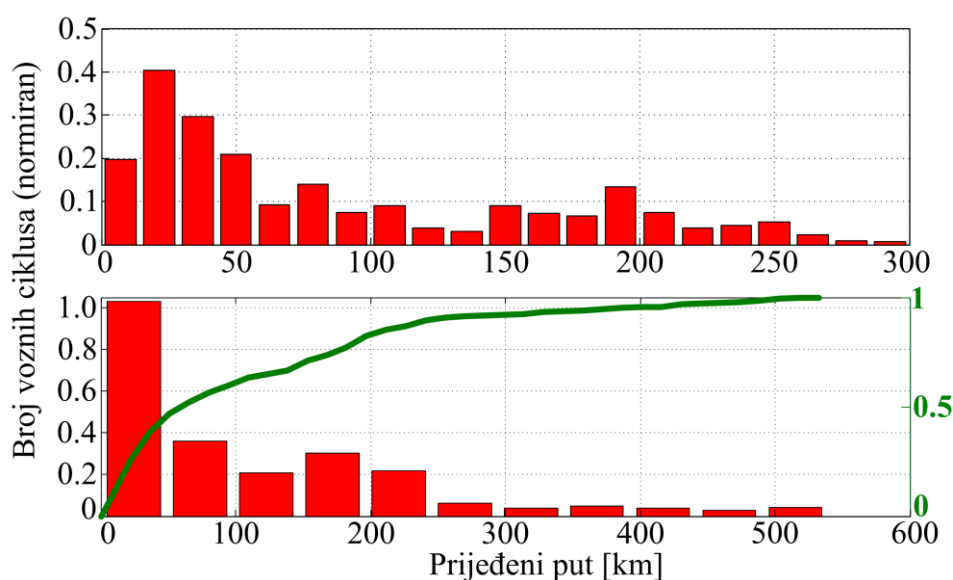


Slika 3-6: Usporedni prikaz razdioba prosječnog broja vozila parkiranih u distributivnom centru za svaki pojedini dan tjedna (a), te razdiobe usrednjene na radne dane (PON-PET) i puni tjedan (PON-NED) (b).

Razdioba prijeđenog puta. Posljednja razmatrana statistička veličina je prijeđeni put tijekom svakog voznog ciklusa, tj. od odlaska iz do povratka u distributivni centar, gdje se prijeđena udaljenost računa korištenjem jednadžbe (3-5). Analiza ove razdiobe predstavlja temelj za određivanje prikladnog tipa električnog vozila, kao i za optimalno dimenzioniranje komponenti njegovog pogona (npr. za određivanje optimalnog kapaciteta baterije).

Slika 3-7 prikazuje razdiobu prijeđenog puta za razmatranu flotu vozila i puni period snimanja podataka od 91 dana. Gornja podslika prikazuje razdiobu prijeđenog puta do 300 km, dok donja podslika prikazuje istu razdiobu za puni raspon prijeđenog puta (do 600 km). Donja podslika također prikazuje kumulativnu razdiobu prijeđenog puta tijekom pojedinačnih voznih ciklusa,

koja pokazuje da za gotovo polovicu voznih ciklusa prijeđeni put iznosi do 50 km, dok više od 90% ciklusa imaju udaljenost do 250 km. Tijekom ostalih 10% ciklusa prijeđeni put poprima vrijednosti između 250 i 550 km. Hipotetska flota električnih vozila bi se tako mogla sastojati od nekoliko tipova vozila. Potpuno električna vozila mogla bi pokriti većinu voznih ciklusa koji imaju domet do 100 km (oko 60% voznih misija), dok bi se ostali ciklusi mogli pokriti s hibridnim električnim vozilima ili s električnim vozilima s proširenim dometom.

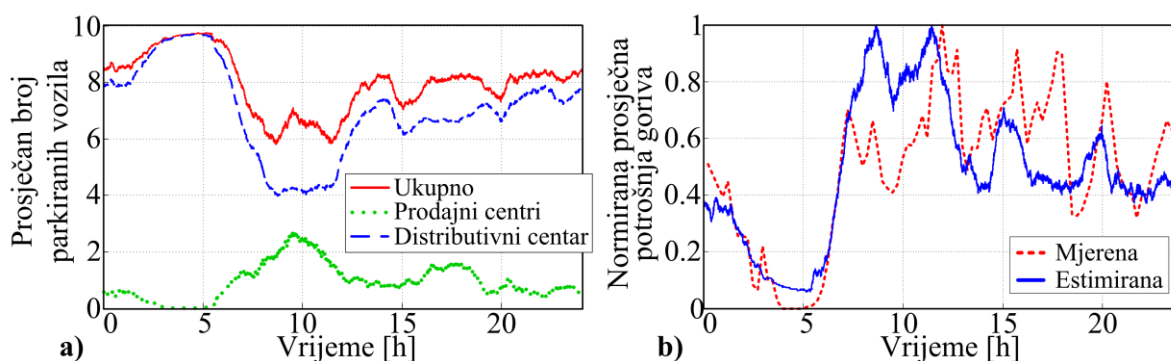


Slika 3-7: Razdioba prijeđenog puta tijekom pojedinačnih voznih ciklusa.

Analiza potrošnje energije u ovisnosti o aktivnosti vozila. Općenito, u nedostatku snimljenih vremenskih profila potrošnje goriva ili električne energije, oni se mogu estimirati računanjem ukupne potrošnje energije u nekom dužem periodu (npr. 1 godina) i distribuiranjem iste na temelju razdiobe dnevne aktivnosti vozila na cesti [4]. Slijedeći referencu [4], vremenska razdioba aktivnosti vozila na cesti izračunata je invertiranjem razdiobe prosječnog broja parkiranih vozila (tj. oduzimanjem od ukupnog broja vozila, koji je ovdje jednak 10). U slučaju flote dostavnih vozila razmatrane u ovom radu, krivulja koja bi se trebala invertirati prikazana je u crvenoj boji na slici 3-8a. Ova krivulja predstavlja razdiobu ukupnog broja parkiranih vozila koja uključuje ona parkirana u distributivnom centru (plava krivulja) te ona parkirana u prodajnim centrima (zelena krivulja). Pritom je pretpostavljeno da se ostala vozila nalaze na cesti tj. da su u vožnji.

Ukupna razdioba potom je invertirana i normirana kako bi odrazila prosječnu potrošnju goriva

(plava krivulja na slici 3-8b). Crvena krivulja na istoj slici prikazuje prosječnu potrošnju goriva (također prikazanu u normiranoj formi) dobivenu iz snimljenih podataka. Usporedni rezultati prikazani na slici 3-8b potvrđuju dobru korelaciju između stvarne/mjerene i estimirane potrošnje goriva dobivene na temelju razdiobe o aktivnosti vozila. Ovo opravdava korištenje pojednostavljenog pristupa za potrebe računanja zahtjeva (elektrificiranog) transporta za energijom, kako je predloženo u [4] kao dio studije energetskog planiranja. Međutim, među navedenim razdiobama ipak postoje određene razlike, posebno u smislu izraženijih varijacija stvarne potrošnje goriva tijekom dana. Ovo se može objasniti sljedećim razlozima: (i) različiti vozni uvjeti tijekom dana (npr. prometne gužve), (ii) činjenica da vozila mogu biti parkirana ne samo u distributivnom centru i prodajnim centrima nego i drugdje. Zbog toga bi općenito bilo pouzdanije korištenje modela temeljenih na nezavisno određenim (snimljenim) razdiobama zahtjeva transporta za energijom i broja parkiranih vozila (spremnih za punjenje).



Slika 3-8: Razdiobe prosječnog broja parkiranih vozila (a) i normirani prikaz mjerene i estimirane potrošnje goriva (b).

3.2. Sinteza voznih ciklusa

Cilj sinteze voznih ciklusa je zamjena velikog skupa stvarnih (snimljenih) voznih ciklusa s nekoliko sintetičkih, ali još uvijek reprezentativnih voznih ciklusa, koji se mogu koristiti tijekom sinteze i verifikacije upravljačkih strategija električnih vozila umjesto „umjetnih“ certifikacijskih voznih ciklusa koji ne odražavaju stvarne uvjete vožnje [83]. Sinteza je temeljena na metodi diskretnih Markovljevih lanaca [53]. Postupak sinteze može se podijeliti u tri glavna koraka: (i) klasteriranje snimljenih voznih ciklusa, (ii) određivanje matrice prijelaznih vjerojatnosti i (iii) generiranje i validacija sintetičkih voznih ciklusa.

3.2.1. Klasteriranje voznih ciklusa


Prije sinteze voznih ciklusa potrebno je klasterirati (kategorizirati) snimljene vozne cikluse u karakteristične grupe za koje će sintetički vozni ciklusi biti generirani. Specifična potrošnja energije (kWh/km) je jedan od najvažnijih parametara voznog ciklusa, a usko je povezana s prijeđenim putem tijekom voznog ciklusa i s karakteristikama ceste (npr. nagib ceste, uvjeti u prometu, i sl.). Iz tog bi razloga kod klasteriranja voznih ciklusa trebalo u obzir uzeti prijeđeni put i karakteristike ceste. Pritom se ovdje pretpostavlja da za svaki vozni ciklus postoji jedna „virtualna“ destinacija na koju vozilo prevozi teret (iako ih u stvarnosti može biti i više) i da se ona nalazi na polovici ukupnog prijeđenog puta. Izračunate „virtualne“ destinacije prikazane su na X-Y mapi danoj na slici 3-9a za svaki vozni ciklus snimljen tijekom 91 dana. S obzirom na očekivanje da vozila čije su „virtualne“ destinacije blizu, koriste približno iste ceste za prijevoz robe od distributivnog centra do prodajnih centara, pretpostavljeno je da „virtualne“ destinacije u određenoj mjeri odražavaju karakteristike voznih ciklusa koje ovise o karakteristikama cesta i prometa. Zbog toga se kod klasteriranja voznih ciklusa, osim prijeđenog puta, u obzir uzimaju i X i Y koordinate „virtualnih“ destinacija za svaki vozni ciklus. Klasteriranje se provodi korištenjem algoritma k srednjih vrijednosti koji se inače široko koristi za klasteriranje različitih podataka [84]. Prototip funkcije tog algoritma u Matlab programskom okruženju glasi

$$\mathbf{idx} = \mathbf{kmeans}(X, k),$$

gdje X označava matricu dimenzija $n \times p$, pri čemu broj redaka n označava broj podataka (ovdje broj voznih ciklusa), a p broj varijabli po kojima se provodi klasteriranje (ovdje X i Y koordinate „virtualne“ destinacije, te prijeđeni put). Ulazni parametar k označava zadani broj klastera (ovdje je postavljen u 5). Izlaz funkcije \mathbf{idx} predstavlja vektor koji sadrži indekse klastera za svaki pojedini podatak odnosno vozni ciklus. Algoritam k srednjih vrijednosti radi iterativno na sljedeći način [84]: (a) u p -dimenzionalni Euklidski koordinatni sustav slučajno se postavlja k točaka koje predstavljaju centroide klastera, (b) p -dimenzionalni podaci, na temelju kojih se provodi klasteriranje, pridijeljuju se, po Euklidskoj udaljenosti, najbližim centroidima, (c) računaju se težišta podataka za svaki klaster zasebno, te ta težišta postaju novi centriodi pripadnih klastera, (d) ako su pozicije novoizračunatih centroida jednake starim pozicijama, postupak se prekida, inače se postupak vraća u korak (b). Krajnji cilj algoritma je

minimiziranje sume udaljenosti svakog od podataka do pripadnog centroida klastera kojem je taj podatak dodijeljen.

Slika 3-9b prikazuje trajanje voznih ciklusa za različite klasterne voznih ciklusa. Na istoj slici također je istaknut medijan trajanja voznih ciklusa za svaki klaster, a koji će biti iskorišten kao ulazni parametar kod generiranja sintetičkih voznih ciklusa.



Slika 3-9: Klasterirani vozni ciklusi predstavljeni geografskim lokacijama na polovini prijednog puta („virtualna“ destinacija) tijekom svakog voznog ciklusa (a) i vremensko trajanje klasteriranih voznih ciklusa (b).

3.2.2. Određivanje matrice prijelaznih vjerojatnosti

Markovljevi lanac definiran je sa skupom dostižnih diskretnih stanja sustava i s razdiobom vjerojatnosti prijelaza među tim stanjima. Niz slučajnih varijabli X_1, X_2, X_3, \dots smatra se Markovljevim lancem, ako je za svako stanje i_1, \dots, i_k zadovoljena sljedeća jednadžba [85]:

$$P(X_{k+1} = i_{k+1} | X_k = i_k, \dots, X_0 = i_0) = P(X_{k+1} = i_{k+1} | X_k = i_k), \quad (3-7)$$

gdje $P(X_{k+1} = i_{k+1} | X_k = i_k)$ označava vjerojatnost prijelaza iz stanja i_k u stanje i_{k+1} . Jednadžba (3-7) označava da prijelaz iz stanja i_k u trenutnom diskretnom vremenskom trenutku k u stanje i_{k+1} u sljedećem diskretnom vremenskom trenutku $k+1$ ovisi samo o trenutnom stanju i_k bez ikakvog utjecaja stanja i_0, \dots, i_{k-1} u kojima je sustav bio u prethodnim

diskretnim vremenskim trenucima (svojstvo odsustva memorije).


Polazeći od opće definicije Markovljevog lanca, dane izrazom (3-7), razmatraju se dva različita pristupa sintezi voznih ciklusa ovisno o izboru skupa stanja Markovljevog lanca.

Sinteza voznih ciklusa – Pristup 1. U prvom su pristupu kao stanja Markovljevog lanca odabrane diskretne vrijednosti brzine vozila u rasponu od 0 do 90 km/h (napomena: brzina dostavnih vozila ograničena je na 90 km/h, vidi sliku 3-1b-f). Rezolucija brzine vozila postavljena je na 0.1 km/h kako bi odgovarala rezoluciji brzine snimljenih voznih ciklusa, rezultirajući tako s 901 stanjem Markovljevog lanca. Razdioba vjerojatnosti prijelaza među pojedinim stanjima definirana je matricom prijelaznih vjerojatnosti (*engl. transition probability (TP) matrix*) [85]

$$p_{ij} := P(X_{k+1} = v_j | X_k = v_i), \quad \Pi := (p_{ij}), \quad (3-8)$$


gdje element matrice p_{ij} označava vjerojatnost prijelaza iz stanja v_i u stanje v_j . Snimljeni uzorci brzina vozila pridruženi su najbližim diskretnim stanjima Markovljevog lanca, te su prijelazi među pojedinim stanjima prebrojani i spremljeni u TP matricu. Budući da suma svakog retka u TP matrici mora biti jednaka 1 ($\sum_j p_{ij} = 1$), svaki element retka podijeljen je sumom svih elemenata u istom retku. Za svaki klaster voznih ciklusa sa slike 3-9 određena je zasebna TP matrica.

Slika 3-10 grafički prikazuje primjer jedne od TP matrica. Prikazani podaci ukazuju na nešto širu razdiobu pri manjim brzinama vozila, zbog toga što su akceleracije vozila na tim brzinama tipično veće. S druge strane, na većim brzinama vozila razdioba vjerojatnosti postaje uža (tj. centrirana) s većim iznosima vjerojatnosti, zbog toga što je vjerojatnost promjene brzine pri ovim brzinama relativno niska (npr. vožnja na autocesti).



Slika 3-10: Matrica prijelaznih vjerojatnosti za treći klaster voznih ciklusa sa slike 3-9b: 3D prikaz (a) i konturni prikaz (b).

Sinteza voznih ciklusa - Pristup 2. Kod drugog pristupa sintezi voznih ciklusa, kao stanja Markovljevog lanca uzimaju se sve kombinacije odabranih diskretnih vrijednosti brzine i akceleracije vozila. Iz istog razloga kao kod pristupa 1, raspon brzina vozila postavljen je od 0 do 90 km/h s rezolucijom 0.1 km/h, dok je opseg akceleracija postavljen u rasponu od -0.7 do 0.7 m/s² s rezolucijom 0.1 m/s². Ovaj odabir raspona akceleracija uključuje veliku većinu akceleracija snimljenih voznih ciklusa, a da je pritom broj diskretnih stanja akceleracije prihvatljivo velik (vidi sliku 3-11). Inače, veći broj stanja Markovljevog lanca može bitno numerički usložniti i usporiti generiranje sintetičkih voznih ciklusa.



Slika 3-11: Normirana razdioba akceleracije svih snimljenih voznih ciklusa.

Kako su samo podaci o brzini vozila mjereni i dostupni, akceleracija vozila rekonstruirana se diferenciranjem brzine vozila (prethodno preračunate iz km/h u m/s) na sljedeći način:

$$a_k = \frac{v_k - v_{k-1}}{T}, \quad (3-9)$$

gdje $T = 1$ s predstavlja vrijeme diskretizacije.

Razdioba vjerojatnosti prijelaza među različitim stanjima Markovljevog lanca definiranog na ovaj način računa se kao [85]

$$p_{qr,ij} := P(X_{k+1} = a_i, v_j | X_k = a_q, v_r), \quad \Pi_{qr} := (p_{ij}) \quad (3-10)$$

i zapisuje u matricu čiji je svaki element Π ponovo matrica kako je grafički ilustrirano na slici 3-12 [53]. Indeksi redaka i stupaca matrice (indeksi q i r u jednadžbi 3-10) označavaju diskretne vrijednosti akceleracija i brzina u trenutnom diskretnom vremenskom trenutku k . Svaki element matrice sadržava podmatricu koja sadrži vjerojatnosti prijelaza iz trenutnog stanja (a_q, v_r) u bilo koje drugo stanje (a_i, v_j) u sljedećem $k + 1$ -om diskretnom trenutku. Prijelazi među stanjima su ponovno kao kod pristupa 1 prebrojani na temelju snimljenih podataka i spremljeni u TP matricu. Budući da suma prijelaznih vjerojatnosti iz trenutnog stanja u bilo koje sljedeće stanje treba biti jednaka 1 ($\sum_i \sum_j p_{qr,ij} = 1$), svaki element podmatrice (Slika 3-12) podijeljen je sumom svih elemenata iste matrice.

	$v_{k,1}$	$v_{k,2}$...	$v_{k,r}$...	$v_{k,m-1}$	$v_{k,m}$		$v_{k+1,1}$	$v_{k+1,2}$...	$v_{k+1,j}$...	$v_{k+1,m-1}$	$v_{k+1,m}$	
$a_{k,1}$	[]	[]	...	[]	...	[]	[]	}	$a_{k+1,1}$	$p_{1,1}$	$p_{1,2}$...	$p_{1,j}$...	$p_{1,m-1}$	$p_{1,m}$
$a_{k,2}$	[]	[]	...	[]	...	[]	[]		$a_{k+1,2}$	$p_{2,1}$	$p_{2,2}$...	$p_{2,j}$...	$p_{2,m-1}$	$p_{2,m}$
\vdots	\vdots	\vdots	\ddots	\ddots	\ddots	\vdots	\vdots		\vdots	\vdots	\vdots	\ddots	\ddots	\ddots	\vdots	\vdots
$a_{k,q}$	[]	[]	\ddots	\ddots	\ddots	[]	[]		$a_{k+1,i}$	$p_{i,1}$	$p_{i,2}$	\ddots	$p_{i,j}$	\ddots	$p_{i,m-1}$	$p_{i,m}$
\vdots	\vdots	\vdots	\ddots	\ddots	\ddots	\vdots	\vdots		\vdots	\vdots	\vdots	\ddots	\ddots	\ddots	\vdots	\vdots
$a_{k,n-1}$	[]	[]	...	[]	...	[]	[]		$a_{k+1,n-1}$	$p_{n-1,1}$	$p_{n-1,2}$...	$p_{n-1,j}$...	$p_{n-1,m-1}$	$p_{n-1,m}$
$a_{k,n}$	[]	[]	...	[]	...	[]	[]		$a_{k+1,n}$	$p_{n,1}$	$p_{n,2}$...	$p_{n,j}$...	$p_{n,m-1}$	$p_{n,m}$


Slika 3-12: Matrica prijelaznih vjerojatnosti i pripadne pod-matrice, korištene u pristupu 2 sinteze voznih ciklusa.

3.2.3. Generiranje sintetičkih voznih ciklusa

Za generiranje sintetičkih voznih ciklusa koriste se TP matrice određene u prethodnom

odjeljku i generator slučajnih brojeva. Za trenutno stanje sustava (v_i) kod pristupa 1 (jednadžba (3-8)) ili (a_q, v_r) kod pristupa 2 (jednadžba (3-10)), vjerojatnosti prijelaza u sljedeće stanje sadržane su u i -om retku TP matrice, odnosno u podmatrici pozicioniranoj u q -tom retku i r -tom stupcu pripadne TP matrice.

Primjerice, kod pristupa 1, ilustracije radi može se pretpostaviti da brzina vozila u k -tom trenutku iznosi v_i . Tada prijelaz u stanje u $k+1$ -om trenutku ovisi o vjerojatnostima zapisanima u retku i TP matrice. Na slici 3-13 prikazana je ilustracija vjerojatnosti iz i -tog retka TP matrice poredanih na jediničnoj dužini, gdje svaki pojedini odjeljak odgovara jednom stanju, a dužina pojedinog odjeljka odgovara iznosu pripadne vjerojatnosti prijelaza u to stanje iz i -tog stanja. Ovo je u skladu sa spomenutom činjenicom da je suma vjerojatnosti u svakom retku TP matrice (kod pristupa 1) jednaka 1. Sljedeće stanje (brzina vozila u $k+1$ -om koraku) dobiva se tako da se generira slučajan broj u intervalu $[0, 1]$, te onaj odjeljak koji uključuje taj broj određuje novo stanje u $k+1$ -om koraku. Na ovaj način će učestalost odabira pojedinih stanja ovisiti od dužini pripadnih odjeljaka, odnosno o pripadnim vjerojatnostima. Na isti način generira se i sintetički vozni ciklus kod pristupa 2, samo uz korištenje drugačije strukturiranih i parametriranih TP matrica. Ovaj način simuliranja stohastičkog procesa naziva se Monte Carlo metoda [86].




Slika 3-13: Ilustracija vjerojatnosti sadržanih u retku TP matrice i poredanih na jediničnoj dužini.

Polazeći od početnog stanja u $k = 0$ i pripadnog retka ili podmatrice sadržane u TP matrici, stanje (brzina ili brzina/akceleracija) u sljedećem koraku $k = 1$ slučajno se odabire kako je prethodno opisano. Postupak se potom iterativno ponavlja za $k = 2, 3, \dots, l$, gdje l označava ukupan broj uzoraka generiranog voznog ciklusa. U početnom koraku ($k = 0$) brzina i akceleracija vozila tipično su postavljene u 0 ($v(0) = 0$ i $a(0) = 0$ za vozni ciklus koji se generira). Valja napomenuti da se na ovaj način može generirati velik broj različitih voznih ciklusa koji znatno premašuje ukupan broj snimljenih ciklusa. Zbog toga je potrebno provesti validaciju sintetiziranih voznih ciklusa kako bi se odabrao ciklus koji najbolje predstavlja

skup snimljenih voznih ciklusa.

Gornji postupak iskorišten je za generiranje skupa sintetičkih voznih ciklusa za svaki klaster sa slike 3-9, gdje je trajanje svakog sintetičkog ciklusa postavljeno da odgovara medijanu trajanja svih snimljenih ciklusa iz odgovarajućeg klastera (Slika 3-9b). Primjeri generiranih sintetičkih voznih ciklusa za oba pristupa prikazani su na slici 3-14. Može se zamijetiti da sintetički vozni ciklusi u prva dva retka slika više nalikuju gradskim voznim ciklusima, dok dulji ciklusi u zadnja tri retka uključuju i dijelove vožnje na autocesti, što je u direktnoj korelaciji s odgovarajućim rezultatima klasteriranja prikazanim na slici 3-9. Također,



Slika 3-14: Primjer sintetičkih voznih ciklusa dobivenih korištenjem pristupa 1 (diskretne vrijednosti brzine vozila su stanja Markovljevog lanca) (a) i pristupa 2 (diskretne vrijednosti brzine i akceleracije vozila su stanja Markovljevog lanca) (b) za svaki klaster snimljenih voznih ciklusa sa slike 3-9.

vizualnom inspekcijom sintetičkih voznih ciklusa sa slike 3-14 i snimljenih voznih ciklusa iz pripadnih klastera (npr. sa slike 3-1b-f; sintetički i snimljeni vozni ciklusi sa slika 3-1b-f i 3-14 označeni su istim bojama za iste klustere), utvrđeno je da ciklusi generirani korištenjem pristupa 2 više nalikuju snimljenim/realističnim voznim ciklusima nego ciklusi generirani korištenjem pristupa 1. Sintetički ciklusi, generirani korištenjem pristupa 2, mogu se skinuti s web stranice https://www.fsb.unizg.hr/acg/syn_natural_driv_cy.html.

3.2.4. Validacija sintetičkih voznih ciklusa

Kako je napomenuto, korištenjem opisanog postupka temeljenog na Markovljevim lancima moguće je generirati mnogo sintetičkih voznih ciklusa različitih statističkih svojstava. Kako bi se testirala reprezentativnost voznih ciklusa, nekoliko značajnih statističkih parametara vezanih uz vozne cikluse odabrano je za potrebe validacije (vidi [53]):

- 1) srednja brzina vozila (v_{mean}),
- 2) standardna devijacija brzine vozila (v_{std}),
- 3) srednja pozitivna akceleracija vozila ($a_{pos,mean}$),
- 4) standardna devijacija pozitivne akceleracije vozila ($a_{pos,std}$),
- 5) srednja negativna akceleracija vozila ($a_{neg,mean}$),
- 6) standardna devijacija negativne akceleracije vozila ($a_{neg,std}$).

Normirane razdiobe navedenih statističkih parametara za slučaj 2375 snimljenih voznih ciklusa različitog trajanja prikazane su na slici 3-15 (oznaka 'Rec'). Sintetički ciklusi čiji su statistički parametri bliži srednjim vrijednostima odgovarajućih statističkih parametara snimljenih voznih ciklusa smatraju se reprezentativnijim. U tom smislu, uveden je i kombinirani vozni ciklus koji uključuje spojene (nadovezane) pojedinačne snimljene vozne cikluse, zbog toga što njegove vrijednosti statističkih parametara (vidi 'Comb' na slici 3-15) predstavljaju značajke svih snimljenih voznih ciklusa na konzistentan način (detaljnije objašnjenje dano je ispod).


Slika 3-15 također prikazuje normirane razdiobe statističkih parametara sintetičkih voznih ciklusa generiranih korištenjem pristupa 1 (Syn_1) i pristupa 2 (Syn_2) za slučaj 1000 generiranih sintetičkih voznih ciklusa. Pritom je trajanje ciklusa u oba slučaja fiksirano na relativno veliku vrijednost od 15000 sekundi (15000 uzoraka; $\approx 4.2h$) kako bi trendovi u smislu srednjih

vrijednosti i standardnih devijacija razdioba statističkih parametara bili izraženiji. Srednje vrijednosti i standardne devijacije razdioba statističkih parametara sa slike 3-15 dane su u tablici 3-1. U većini slučajeva Syn_1 i Syn_2 razdiobe imaju vrlo slične srednje vrijednosti razdioba (Slika 3-15, Tablica 3-1). Osnovna razlika među ovim grupama razdioba je u njihovoj standardnoj devijaciji, koja je značajno niža u slučaju Syn_2 razdioba (Tablica 3-1). To se odražava u užim Syn_2 razdiobama u odnosu na Syn_1 razdiobe (Slika 3-15). Praktična vrijednost ovog nalaza je činjenica da je značajno manji broj iteracija potreban da se generira sintetički ciklus zadovoljavajućeg stupnja reprezentativnosti u slučaju korištenja pristupa 2 (manje je rasipanje značajnih statističkih parametara).


Međutim, na slici 3-15 i u tablici 3-1 može se zamijetiti da srednje vrijednosti Syn_1 i Syn_2 razdioba ponešto odstupaju od odgovarajućih srednjih vrijednosti individualnih snimljenih voznih ciklusa. Ovo se može objasniti činjenicom da individualni snimljeni vozni ciklusi, koji su korišteni za dobivanje TP matrice Markovljevog lanca, imaju varijabilni broj uzoraka odnosno varijabilnu duljinu. Naime, dulji snimljeni vozni ciklusi imaju veći utjecaj kod određivanja TP matrice nego kraći vozni ciklusi, što je suprotno nego kod računanja statističkih parametara snimljenih voznih ciklusa gdje se pretpostavlja da svaki snimljeni vozni ciklus ima istu težinu. Slika 3-16 jasno označava da česti ciklusi kraćeg trajanja (tipično gradski ciklusi) imaju niže srednje vrijednosti brzine vozila (te također veće iznose srednje vrijednosti akceleracije), što objašnjava zamijećeni pomak razdioba vezanih uz srednje brzine vozila snimljenih ciklusa prema nižim vrijednostima (i razdioba vezanih uz akceleracije prema višim vrijednostima). U slučaju korištenja kombiniranog voznog ciklusa, svaki snimljeni vozni ciklus (sadržan u kombiniranom voznom ciklusu) pridonosi srednjoj vrijednosti statističkih parametara proporcionalno svojoj duljini odnosno broju uzoraka kao i kod postupka računanja TP matrice. Zbog toga bi srednje vrijednosti Syn_1 i Syn_2 razdioba teorijski trebale konvergirati u odgovarajuće vrijednosti statističkih parametara kombiniranog voznog ciklusa. Ovo je očito na slici 3-15 i tablici 3-1 u slučaju Syn_2 razdiobe, dok u slučaju Syn_1 razdiobe određena odstupanja postoje. Ta odstupanja bi se smanjila u slučaju da je trajanje Syn_1 ciklusa dovoljno povećano. Osim niže standardne devijacije Syn_2 razdioba, ovo se smatra dodatnom prednošću pristupa 2 u odnosu na pristup 1.

Tablica 3-1: Srednje vrijednosti i standardne devijacije razdioba značajnih statističkih parametara za snimljene pojedinačne vozne cikluse, generirane sintetičke vozne cikluse te za kombinirani snimljeni vozni ciklus.

Vozni ciklusi	v_{mean} [km/h]		$a_{pos,mean}$ [m/s ²]		$a_{neg,mean}$ [m/s ²]	
	Mean	Std	Mean	Std	Mean	Std
Snimljeni	50.77	15.51	0.34	0.10	-0.34	0.10
Kombinirani	60.50	-	0.29	-	-0.29	-
<i>Syn₁</i>	57.50	12.12	0.30	0.07	-0.30	0.07
<i>Syn₂</i>	59.95	4.5	0.29	0.03	-0.30	0.03
Vozni ciklusi	v_{std} [km/h]		$a_{pos,std}$ [m/s ²]		$a_{neg,std}$ [m/s ²]	
	Mean	Std	Mean	Std	Mean	Std
Snimljeni	23.05	3.47	0.33	0.06	0.39	0.08
Kombinirani	27.43	-	0.32	-	0.37	-
<i>Syn₁</i>	23.90	3.71	0.31	0.04	0.37	0.05
<i>Syn₂</i>	27.00	1.06	0.32	0.02	0.37	0.02




Slika 3-15: Normirane razdiobe značajnih statističkih parametara snimljenih vozničkih ciklusa (Rec), sintetičkih vozničkih ciklusa generiranih korištenjem pristupa 1 (Syn1) i pristupa 2 (Syn2), te kombiniranog voznog ciklusa (Comb).



Slika 3-16: Ovisnost značajnih statističkih parametara o trajanju snimljenih voznih ciklusa.

3.2.5. Sinteza voznih ciklusa za potrebe modeliranja zahtjeva transporta za energijom

Motivacija. U prethodnim odjeljcima demonstrirano je klasteriranje voznih ciklusa na temelju koordinata „virtualne“ destinacije i prijeđenog puta svakog ciklusa, te sinteza voznih ciklusa za svaki od odabranih klastera (Slika 3-14). Ti sintetički vozni ciklusi bi mogli primjerice poslužiti za detaljno vrednovanje prikladnih tipova vozila (električnih ili konvencionalnih), kao i optimalno dimenzioniranje te parametiranje upravljačkih strategija pripadnih pogona za pojedine tipove voznih misija (uključujući adaptivne strategije upravljanja). Međutim, za potrebe modeliranja zahtjeva transporta za energijom odzivnim površinama (poglavlje 5), klasteriranje snimljenih voznih ciklusa provodi se samo na temelju prijeđenog puta. Ovo se opravdava rezultatima dodatne analize, kojom je utvrđeno da je snimljena potrošnja goriva u velikoj mjeri proporcionalna prijeđenom putu (Slika 3-17). Nakon klasteriranja, sinteza i odabir validiranih sintetičkih voznih ciklusa provodi se za svaki od klastera (za potrebe modeliranja zahtjeva transporta za energijom) korištenjem pristupa 2 i prethodno opisanog postupka validacije.



Slika 3-17: Ovisnost snimljene (normirane) potrošnje goriva o prijeđenom putu za sve snimljene vozne cikluse.

Klasteriranje snimljenih voznih ciklusa. Skup snimljenih voznih ciklusa dijeli se u osam klastera na temelju prijeđenog puta (Tablica 3-2). Zbog relativno velikog broja voznih ciklusa s manjim prijeđenim putem (Slika 3-7), granice između pojedinih klastera odabrane su na način da se gušće pokriju vozni ciklusi s kraćom prijeđenom udaljenošću (vidi retke d_{mean} i N_c u tablici 3-2). U tablici 3-2 se, također, može zamijetiti da srednja brzina voznih ciklusa v_{mean} raste s prijeđenim putem, što je očekivano s obzirom da dulji vozni ciklusi uključuju veći dio vožnje na autocesti, za koju je tipična veća brzina. Valja napomenuti da se ovdje, za razliku od sintetičkih ciklusa prikazanih na slici 3-14, kao uvjet prekida iterativnog postupka sinteze ciklusa postavlja prijeđeni put umjesto trajanje ciklusa. Postupak sinteze prekida se kad sintetički vozni ciklus premaši zadani (ciljani) prijeđeni put, odnosno sredinu raspona prijeđenog puta za odgovarajući klaster (d_{mean} u tablici 3-2).

Tablica 3-2: Karakteristike snimljenih voznih ciklusa po pojedinim klasterima.

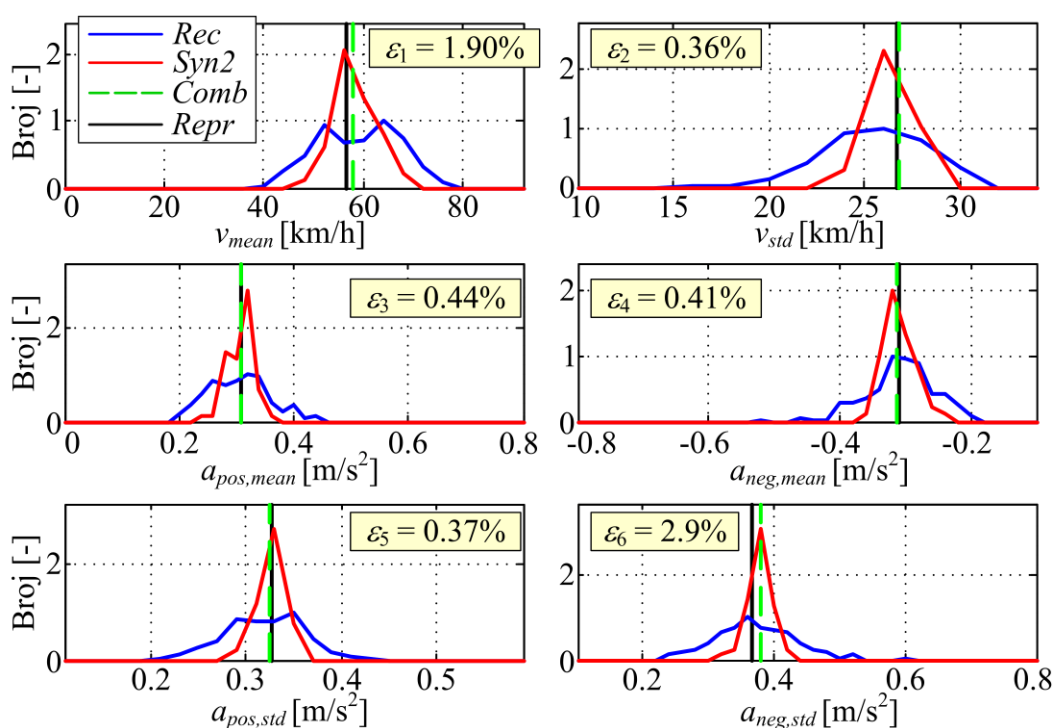
	Indeks klastera							
	1	2	3	4	5	6	7	8
d_{lower} [km]	0	18	36	54	90	144	234	378
d_{mean} [km]	9	27	45	72	117	189	306	495
d_{upper} [km]	18	36	54	90	144	234	378	612
N_c [-]	312	506	265	269	223	490	184	126
v_{mean} [km/h]	33.3	37.5	41.9	49.3	57.8	62.7	67.7	76.1

Srednja brzina v_{mean} za svaki klaster računa se za slučaj kombiniranog voznog ciklusa koji se dobiva spajanjem svih snimljenih voznih ciklusa iz tog klastera; d_{lower} – donja margina prijeđenih udaljenosti voznih ciklusa u danom klasteru, d_{upper} – gornja margina prijeđenih udaljenosti voznih ciklusa u danom klasteru, d_{mean} – sredina raspona od d_{lower} do d_{upper} , N_c – broj voznih ciklusa u danom klasteru.

Validacija sintetičkih voznih ciklusa. Kao i u prethodnom odjeljku i ovdje se koriste istih šest značajnih statističkih parametara za validaciju sintetiziranih vozni ciklusa. Slika 3-18 prikazuje primjer normiranih razdioba tih statističkih parametara za snimljene vozne cikluse iz klastera 5 (*Rec*), 50 generiranih sintetičkih vozni ciklusa (*Syn2*), kombiniranog voznog ciklusa za isti klaster (*Comb*) i voznog ciklusa (*Repr*) odabranog iz skupa sintetičkih vozni ciklusa kao najreprezentativnijeg. Pritom je najreprezentativniji sintetički vozni ciklus odabran na temelju minimizacije sljedećeg kriterija:

$$\varepsilon_{total} = \sum_{i=1}^6 |\varepsilon_i|, \quad (3-11)$$

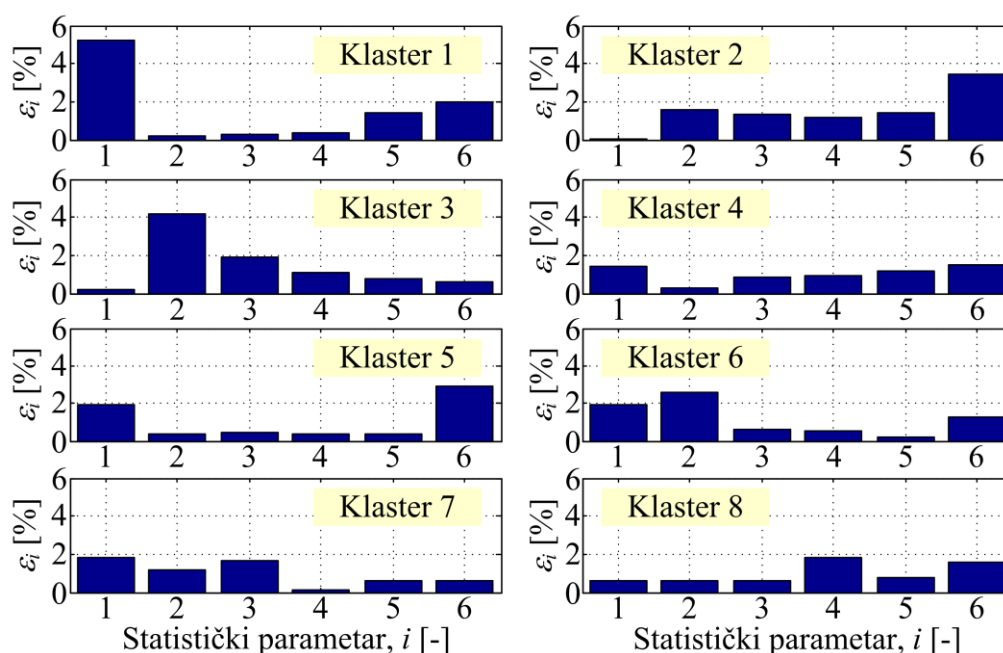
gdje ε_i označava odstupanje i -tog statističkog parametra sintetičkog voznog ciklusa u odnosu na statistički parametar kombiniranog voznog ciklusa (vidi crne i zelene-isprekidane linije na slici 3-18). Slika 3-19 prikazuje odstupanja statističkih parametara ε_i za sintetičke vozne




Slika 3-18: Normirane razdiobe značajnih statističkih parametara za snimljene (*Rec*) i sintetičke (*Syn2*) vozne cikluse, kao i za kombinirane (*Comb*) i odabrane/reprezentativne (*Repr*) vozne cikluse za Klaster 5.

cikluse koji su odabrani kao reprezentativni za odgovarajuće klaster. Ovi rezultati ukazuju da su odstupanja statističkih parametara većinom unutar 2%, s nekolicinom iznimaka gdje to odstupanje doseže i 5%. Ovi se pokazatelji mogu smatrati zadovoljavajućim uzimajući u obzir da su reprezentativni vozni ciklusi odabrani iz skupa od samo 50 sintetičkih voznih ciklusa.

Slika 3-20 prikazuje odabrane reprezentativne sintetičke vozne cikluse za svaki od osam klastera, zajedno s ostvarenom srednjom brzinom i prijeđenim putem (usporedi s tablicom 3-2). Slično kao i kod sintetičkih voznih ciklusa prikazanih na slici 3-14, kraći vozni ciklusi na slici 3-20 više su nalik gradskim voznim ciklusima, dok se kod duljih mogu zamijetiti i značajke vožnje na autoputu, što je u skladu s podacima o srednjim brzinama danima u tablici 3-2.



Slika 3-19: Relativno odstupanje značajnih statističkih parametara (ϵ_i , $i = 1, 2, \dots, 6$) odabranih/reprezentativnih sintetičkih voznih ciklusa (*Repr*) u odnosu na odgovarajuće statističke parametre kombiniranog voznog ciklusa (*Comb*) za svaki klaster voznih ciklusa (statistički parametri: 1 – v_{mean} , 2 – v_{std} , 3 – $a_{pos,mean}$, 4 – $a_{pos,std}$, 5 – $a_{neg,mean}$, 6 – $a_{neg,std}$).



Slika 3-20: Validirani sintetički vozni ciklusi za osam klastera voznih ciklusa.

4. Modeliranje flote električnih vozila

4.1. Modeli flote električnih vozila

U ovom je radu flota električnih vozila radi jednostavnosti modelirana kao spremnik energije s maksimalnim energetske kapacitetom $E_{\max,agg}$ i korisnošću punjenja η_{ch} te korisnošću pražnjenja η_{dch} . Realističniji pristup, ali i znatno složeniji iz perspektive modeliranja i optimiranja punjenja, bio bi modeliranje baterije kao spremnika naboja umjesto kao spremnika energije. Takav nelinearni model flote EV predložen je u prilogu B.

4.1.1. Osnovni agregatni model flote vozila

Osnovni agregatni model flote vozila preuzet je iz [4] i definiran je sljedećom vremenski-diskretnom jednačinom stanja:

$$SoC_{agg}(k+1) = SoC_{agg}(k) + \eta_{ch} \frac{(P_{c,agg}(k) + |P_{reg,agg}(k)|)\Delta T}{E_{\max,agg}} - \frac{P_{dem,agg}(k)\Delta T}{\eta_{dch}E_{\max,agg}}, \quad k = 0, 1, \dots, N_t - 1 \quad (4-1)$$

u kojoj agregatno stanje napunjenosti (SoC_{agg}) u narednom diskretnom vremenskom trenutku $k+1$ ovisi o $SoC_{agg} = E_{agg}/E_{\max,agg}$ (E_{agg} je agregatna razina energije u baterijama svih vozila u floti), snazi punjenja ($P_{c,agg} + |P_{reg,agg}|$) i snazi pražnjenja $P_{dem,agg}$ agregatne baterije u tekućem diskretnom vremenskom trenutku k , gdje $\Delta T = t_{k+1} - t_k$ i N_t redom označavaju trajanje jednog diskretnog vremenskog koraka te ukupan broj diskretnih vremenskih koraka. Model agregatne baterije (4-1) ponešto se razlikuje (proširen je) od modela danog u [4], jer se snaga regenerativnog kočenja $P_{reg,agg}$ razmatra zasebno od zahtjeva za snagom za vožnju $P_{dem,agg}$. Osim što je ovaj model time realističniji od modela danog u [4] (ali, također i zahtjevniji u smislu dodatne vremenske razdiobe potrebne za parametriranje modela), ovom modifikacijom postignuta je kompatibilnost ovog osnovnog modela s naprednijim modelom danom u sljedećem odjeljku u smislu jednake ukupne potrošnje energije za isti skup vozila i voznih ciklusa.

Zbog ograničene snage punjenja pojedinačnih vozila/baterija ($P_{c,max,ind}$), ograničenje na snagu punjenja agregatne baterije ovisno je o broju EV spojenih na mrežu $n_{dc,agg}$ (tj. parkiranih u

distributivnom centru, vidi jednadžbu (3-6)):

$$P_{c,agg}(k) \leq n_{dc,agg}(k)P_{c,max,ind}, \quad k = 0, 1, \dots, N_t - 1 \quad (4-2)$$

Također, na agregatni SoC postavljaju se sljedeća donja i gornja ograničenja:

$$0 \leq SoC_{agg,min} \leq SoC_{agg}(k) \leq SoC_{agg,max} \leq 1, \quad k = 0, 1, \dots, N_t - 1 \quad (4-3)$$

Valja napomenuti da se ograničenja (4-2) i (4-3) implementiraju kao ograničenja tipa nejednakosti u okviru algoritma optimiranja snage punjenja agregatne baterije $P_{c,agg}$ (poglavlje 5), a ne kao ograničenja (zasićenja) dana u okviru modela baterije.

Model predstavljen jednadžbama (4-1)-(4-3) zahtijeva sljedeće ulazne vremenske razdiobe:

- 1) razdioba vezana uz agregatni zahtjev transporta za snagom $P_{dem,agg}(k)$,
- 2) razdioba vezana uz agregatnu snagu regenerativnog kočenja $P_{reg,agg}(k)$,
- 3) razdioba broja vozila spojenih na mrežu, $n_{dc,agg}(k)$.

Ovaj jednostavan model, koji zahtijeva samo osnovne vremenske razdiobe vezane uz transport, ima smisla koristiti u slučajevima kad detalji vezani uz dolaske (spajanje na mrežu) i odlaske vozila (odspajanje s mreže), te vozni ciklusi nisu poznati. Naime, ukupna potrošnja energije transporta preko nekog većeg vremenskog perioda uobičajeno je poznata (ili može biti estimirana), te je korištenjem te informacije i poznate razdiobe aktivnosti vozila na cesti (vozila u vožnji) moguće procijeniti vremensku razdiobu zahtjeva transporta za energijom/snagom (vidi poglavlje 3 tj. sliku 3-8). Nadalje, kad se invertira razdioba aktivnosti vozila u vožnji dobiva se razdioba vozila dostupnih za punjenje, $n_{dc,agg}(k)$ (ako se pretpostavi da su sva parkirana vozila spojena na mrežu).

S druge strane, jednostavnost osnovnog modela unosi određenu netočnost zbog nerealistične pretpostavke da je ukupni kapacitet agregatne baterije $E_{max,agg}$ dostupan cijelo vrijeme. To, naime, nije točno jer dio vozila koja su na cesti, odspojena su s mreže te nisu dostupna za punjenje. Primjerice, u slučaju samo jednog EV spojenog na mrežu ($n_{dc,agg} = 1$), ograničenje na snagu punjenja je veće od 0 (vidi izraz (4-2)), što teorijski omogućava potpuno punjenje agregatne baterije ($SoC_{agg} = 1$). To bi značilo da su se baterije EV u vožnji napunile posredno preko EV spojenog na mrežu što je nerealistično. Realnije bi bilo za pretpostaviti da agregatna baterija predstavlja samo ona vozila koja su spojena na mrežu, te da vozila koja se odspajaju s

mreže trenutno smanjuju stanje napunjenosti agregatne baterije, dok vozila koja se spajaju na mrežu trenutno povećavaju stanje napunjenosti agregatne baterije (ovisno o broju vozila i njihovom prosječnom SoC-u). Također, zbog vremenski varijabilnog broja vozila koja su spojena na mrežu, gornji limit na SoC agregatne baterije (koji je u nejednakosti (4-3) konstantan) trebalo bi postaviti varijabilnim u ovisnosti o broju tih vozila kako bi se dobili realistični uvjeti za punjenje (odnosno za opterećenje mreže). Navedeni nedostaci osnovnog modela i ocrtane smjernice za njegovo unapređenje motivirali su razvoj naprednog modela agregatne baterije predstavljenog u sljedećem odjeljku.

4.1.2. Napredni agregatni model flote vozila

Diskretna jednadžba stanja predloženog (naprednog) agregatnog modela flote glasi

$$SoC_{agg}(k+1) = SoC_{agg}(k) + SoC_{in,avg}(k) \frac{\Delta n_{in,dc}(k)}{N_v} - SoC_{out,avg} \frac{\Delta n_{out,dc}(k)}{N_v} + \eta_{ch} \frac{P_{c,agg}(k)\Delta T}{E_{max,agg}}, \quad k = 0, 1, \dots, N_t - 1 \quad (4-4)$$

Stanje napunjenosti se, kao i kod osnovnog modela agregatne baterije, definira sa $SoC_{agg} = E_{agg} / E_{max,agg}$, s temeljnom razlikom što E_{agg} ovdje predstavlja agregatnu energiju sadržanu samo u baterijama EV koja su spojena na mrežu. Ovdje se potrošnja energije iz agregatne baterije, odnosno zahtjev za energijom flote EV, odražava kroz smanjenje prosječnog SoC-a vozila koja pristižu u distributivni centar ($SoC_{in,avg}$) unutar diskretnog vremenskog intervala ΔT u odnosu na prosječan SoC koji su „odnijeli“ prilikom odspajanja s mreže ($SoC_{out,avg}$). U većem dijelu ovog rada, pretpostavlja se da vozila napuštaju mjesto punjenja s punim baterijama ($SoC_{out,avg} = 1$).

Gornje ograničenje (4-2) na agregatnu snagu punjenja $P_{c,agg}$ ostaje vrijediti i za napredni model. S druge strane, zbog strukturnih poboljšanja modela kroz jednadžbu (4-4), gornje ograničenje na SoC_{agg} sada može biti postavljeno varijabilno u ovisnosti o broju vozila spojenih na mrežu $n_{dc,agg}$ (usp. jednadžbu (4-3)):

$$0 \leq SoC_{agg,min} \leq SoC_{agg}(k) \leq SoC_{agg,max}(k) = \frac{n_{dc,agg}(k)}{N_v} \leq 1, \quad k = 0, 1, \dots, N_t - 1, \quad (4-5)$$

gdje N_v označava ukupan broj EV u floti (vidi jednadžbu (4-4)). Na ovaj način, samo se vozila spojena na mrežu mogu puniti i doprinijeti agregatnom SoC-u.

Napredni model flote EV zahtijeva sljedeće vremenske razdiobe:

- 1) broj vozila koja dolaze na mjesto punjenja, $\Delta n_{in,dc}(k)$,
- 2) prosječan SoC vozila koja dolaze na mjesto punjenja, $SoC_{in,avg}(k)$,
- 3) broj vozila koja odlaze s mjesta punjenja, $\Delta n_{out,dc}(k)$,
- 4) broj vozila spojenih na mrežu, $n_{dc,agg}(k)$.

Valja zamijetiti da se razdioba broja vozila spojenih na mrežu $n_{dc,agg}(k)$ može iterativno izračunati korištenjem razdioba $\Delta n_{in,dc}(k)$ i $\Delta n_{out,dc}(k)$ i poznatog početnog broja vozila na mjestu punjenja korištenjem sljedećeg izraza:

$$n_{dc,agg}(k) = n_{dc,agg}(k-1) + \Delta n_{in,dc}(k) - \Delta n_{out,dc}(k).$$

Međutim, zbog preglednosti ove se razdiobe daju odvojeno. Dodatno, valja istaknuti kako razdioba prosječnog SoC-a odlazećih vozila ($SoC_{out,avg}$) predstavlja podesivi „upravljački“ parametar (najčešće jednak 1), ili pak upravljačku varijablu za općenitiji slučaj da se dokine pretpostavka da odlazeća vozila imaju punu bateriju (vidi dvorazinsko optimiranje u poglavlju 5).

4.1.3. Distribuirani model flote vozila

U distribuiranom (ili tzv. više-agentnom) modelu flote EV svako vozilo/baterija razmatra se zasebno. Model pojedinačne baterije opisan je sljedećom vremenski diskretnom jednadžbom stanja:

$$SoC_j(k+1) = SoC_j(k) + \eta_{ch} \frac{P_{c,j}(k)\Delta T}{E_{max,ind}} - \Delta SoC_j(k), \quad k = 0, 1, \dots, N_t - 1, \quad (4-6a)$$

gdje $P_{c,j}(k)$ označava snagu punjenja j -tog vozila ($j = 1, \dots, N_v$), a $\Delta SoC_j(k)$ potrošnju SoC-a istog vozila u k -tom vremenskom trenutku, koja se definira sljedećim izrazom:

$$\Delta SoC_j(k) = \frac{P_{dem,j}(k)\Delta T}{\eta_{dch}E_{max,ind}} - \eta_{ch} \frac{|P_{reg,j}(k)|\Delta T}{E_{max,ind}}, \quad k = 0, 1, \dots, N_t - 1, \quad (4-6b)$$

gdje $P_{dem,j}(k)$ i $P_{reg,j}(k)$ predstavljaju zahtjev aktivne snage za potrebe vožnje, odnosno snagu

regenerativnog kočenja za dano vozilo. Konstanta $E_{max,ind}$ predstavlja energetska kapacitet pojedinačne baterije. Valja naglasiti da je model pojedinačne baterije (4-6) identičan osnovnom modelu agregatne baterije (4-1), samo s drugim parametrima. Slično, ograničenja osnovnog agregatnog modela (4-2) i (4-3) vrijede i kod pojedinačnog modela baterije (uz izostavljanje indeksa agg i dodavanje indeksa j za pojedinačna vozila). Pritom, razdioba $n_{dc}(k) \in [0,1]$ ovdje predstavlja vremensku razdiobu udjela vremena parkiranosti pojedinačnog vozila (spremnog za punjenje) unutar svakog diskretnog vremenskog trenutka (umjesto broja vozila spojenih na mrežu). Pritom $n_{dc,j}(k) = 0$ znači da j -to vozilo uopće nije bilo parkirano i spremno za punjenje u k -tom diskretnom vremenskom trenutku, dok $n_{dc,j}(k) = 1$ znači da je vozilo bilo čitavo vrijeme parkirano unutar k -tog diskretnog vremenskog trenutka.

Prema navedenom, distribuirani model flote EV zahtijeva sljedeće vremenske razdiobe za svako vozilo $j=1, 2, \dots, N_v$ u floti:

- 1) udio vremena parkiranosti unutar svakog diskretnog vremenskog trenutka, $n_{dc,j}(k)$,
- 2) zahtjev snage za vožnju, $P_{dem,j}(k)$,
- 3) snaga regenerativnog kočenja, $P_{reg,j}(k)$.


4.2. Parametriranje modela flote vozila

Za potrebe parametriranja i validacije predloženih modela flote EV iskoristiti će se snimljeni podaci vezani uz flotu dostavnih vozila čija je analiza i obrada detaljno opisana u poglavlju 3. U studijama energetskog planiranja tipično se koristi vrijeme diskretizacije od 1 sata (vidi npr. [4]). Iz tog se razloga vremenske razdiobe koje izvorno imaju vrijeme diskretizacije 1 sekundu usrednjavaju na satnu razinu ($\Delta T = 1$ h).

4.2.1. Razdiobe vezane uz broj parkiranih vozila spremnih za punjenje

S obzirom na pretpostavku da se hipotetska flota EV puni samo u distributivnom centru, vremenske razdiobe vezane uz broj vozila odnose se na vozila koja dolaze u, odlaze iz ili su parkirana u distributivnom centru. Na temelju snimljenih podataka o geografskim koordinatama vozila i primjeni uvjeta (3-6), određene su sljedeće vremenske razdiobe potrebne za parametriranje distribuiranih i agregatnih modela flote vozila (prikazane usrednjene na tjednoj vremenskoj bazi na slici 4-1 uz $\Delta T = 1$ h):

- (1) udio vremena koje svako vozilo provede parkirano u distributivnom centru unutar svakog diskretnog vremenskog trenutka $n_{dc}(k)$ (na slici 4-1a prikazana je razdioba za vozilo $j=1$),
- (2) broj vozila parkiran u distributivnom centru $n_{dc,agg}(k)$ (Slika 4-1b, usporedi sa slikom 3-5),
- (3) broj vozila koja dolaze u distributivni centar $\Delta n_{in,dc}(k)$ (Slika 4-1c),
- (4) broj vozila koja odlaze iz distributivnog centra $\Delta n_{out,dc}(k)$ (Slika 4-1d).



Slika 4-1: Vremenske razdiobe vezane uz broj vozila u distributivnom centru usrednjene na tjednoj vremenskoj bazi.

4.2.2. Razdiobe vezane uz zahtjev transporta za energijom

Kako bi se dobile precizne vremenske razdiobe zahtjeva transporta za snagom/energijom potrebno je modelirati pojedinačno EV i provesti simulaciju razvijenog modela preko snimljenih voznih ciklusa. Bez obzira što razmatrana flota vozila uključuje dostavne kamione, prethodno razvijen model *putničkog* električnog vozila proširenog dometa (uključujući njegovu upravljačku

strategiju; vidi poglavlje 2) iskorišten je za dobivanje vremenskih razdioba vezanih uz zahtjev transporta. Ovakav pristup zadovoljava svrhu demonstracije funkcionalnosti predloženog naprednog modela agregatne baterije i njegovu kvantitativnu usporedbu s osnovnim agregatnim i distribuiranim modelom. Međutim, za potrebe tehno-ekonomske analize sustava *dostavnih* EV, u poglavlju 6 postavlja se model električnog *kamiona* i koristi za modeliranje zahtjeva za energijom.

Model električnog vozila proširenog dometa (engl. skrać. EREV) tipa Chevrolet Volt detaljno je opisan u poglavlju 2. Model koji je korišten ovdje, ponešto je izmijenjen za potrebe parametriranja modela flote. Naime, umjesto nelinearnog nabojskog modela baterije (2-3), temeljenog na nadomjesnom električnom krugu, korišten je linearni energetska model baterije, kako bi bio kompatibilan s energetska agregatnim modelima flote vozila (vidi jednadžbu (4-6)):

$$\dot{SoC}_j(t) = \frac{1}{3600E_{\max,ind}} (\eta_{ch} P_{reg,j}(t) - P_{dem,j}(t) / \eta_{dch}), \quad j = 1, 2, \dots, N_v, \quad (4-7)$$


gdje se faktor $3600 = 1h/1s$ pojavljuje zbog definicije energetska kapaciteta baterije $E_{\max,ind}$ u Wh.

Kvazistatički model EREV vozila simuliran je preko svakog snimljenog voznog ciklusa (u nastavku se radi jednostavnosti umjesto EREV koristi kratica EV). Pritom je na početku svakog voznog ciklusa odnosno svake simulacije, SoC pojedinačnog EV postavljen u 1 što odgovara pretpostavci da je baterija svakog EV pri kraju perioda punjenja potpuno puna. Ova pretpostavka se uvodi kako bi se vremenski i računalno zahtjevne simulacije EREV vozila preko voznih ciklusa provele samo jednom. Relaksacija ove pretpostavke razmatra se u odjeljku 5.3.3 gdje se zahtjev transporta za energijom modelira odzivnim površinama. U intervalima kad je aktivan CS režim rada, tj. kad pogonska snaga dolazi iz goriva, varijable $P_{dem,j}(k)$ i $P_{reg,j}(k)$ postavljaju se u 0. Poznavajući vremena dolazaka i odlazaka svakog vozila, pojedinačni vremenski profili zahtjeva za snagom svih vozila u floti usrednjeni su i mapirani na satnu vremensku bazu. Agregatni zahtjev za snagom $P_{dem,agg}(k)$ tada se u diskretnom vremenskom trenutku k jednostavno računa sumiranjem zahtjeva za snagom $P_{dem,j}(k)$ od strane pojedinačnih EV:

$$P_{dem,agg}(k) = \sum_{j=1}^{N_v} P_{dem,j}(k). \quad (4-8)$$

Na isti način dobiva se i agregatna snaga regenerativnog kočenja $P_{reg,agg}(k)$. Dobivene vremenske razdiobe, usrednjene na tjednoj vremenskoj bazi, prikazane su na slici 4-2.

Slika 4-2a prikazuje razdiobu zahtjeva aktivne snage i razdiobu snage regenerativnog kočenja za jedno vozilo. Slika 4-2b prikazuje agregirane razdiobe zahtjeva aktivne snage i snage regenerativnog kočenja koje se koriste za parametrisiranje osnovnog modela flote vozila. Kod naprednog modela flote (4-4), potrošnja energije ne odražava se kroz razdiobu zahtjeva transporta za snagom kao kod osnovnog modela, već se ogleda kroz prosječni SoC EV koja pristižu u distributivni centar. SoC svake pojedinačne baterije se na kraju svakog voznog ciklusa mapira na vremensku os te se potom te vrijednosti SoC-a usrednjavaju za sva EV u floti na satnu vremensku bazu. Ako se EV tijekom vožnje prebaci u CS režim rada (za dulje vozne cikluse), minimalna vrijednost SoC-a od 0.3 uzima se kao vrijednost SoC-a na destinaciji (tj. pri dolasku EV na destinaciju). Pritom je uzeta vrijednost SoC-a na destinaciji iznosa 0.3 jer se CS režim rada uključuje upravo kada SoC poprimi tu vrijednost kako bi se SoC održao na toj vrijednosti s ciljem sprječavanja „predubokog“ pražnjenja, a time i ubrzanog starenja baterije. Dobivena satna razdioba prosječnog SoC-a vozila pri spajanju na mrežu, usrednjena preko perioda od jednog tjedna, prikazana je na slici 4-2c.



Slika 4-2: Vremenske razdiobe pojedinačnog zahtjeva za snagom jednog vozila (a), agregatnog zahtjeva za snagom (b) i prosječnog SoC-a vozila koja pristižu u distributivni centar prikazane na tjednoj vremenskoj bazi (c).


4.3. Algoritmi upravljanja punjenjem flote EV

Kako bi se mogli validirati i usporediti postavljeni agregatni modeli baterije, u ovom se potpoglavlju predstavljaju algoritmi punjenja flote EV, tj. algoritmi raspodjele agregatne snage punjenja flote na pojedinačna EV.

4.3.1. Optimiranje punjenja EV flote primjenom dinamičkog programiranja

Ovaj odjeljak sažeto predstavlja optimiranje punjenja flote EV korištenjem algoritma dinamičkog programiranja (DP) i prethodno postavljenih modela. Detalji vezani uz optimiranje punjenja flote dani su u poglavlju 5. Valja napomenuti da se pretpostavlja jednosmjernan tok energije iz mreže prema vozilima ($P_c \geq 0$, $P_{c,agg} \geq 0$), tj. samo punjenje koje doprinosi balansiranju opterećenja mreže te se najčešće primjenjuje u praksi. Ograničenje na jednosmjerni tok energije može se jednostavno izostaviti, te se na taj način automatski razmatra dvosmjerni tok energije karakterističan za V2G primjene (vidi poglavlje 1). U tom slučaju bi (agregatni) model flote vozila i funkcija cilja trebali, osim troškova energije, uključiti i efekt degradacije baterije [87], jer je povrat energije u mrežu opravdan samo ako je time ostvareni dobitak na troškovima energije dominantniji nego gubitak kroz ubrzano starenje baterije.

Optimiranje punjenja temeljem agregatnih modela EV flote. DP algoritam određuje vremensku razdiobu agregatne snage punjenja $P_{c,agg}(k)$ za slučaj nekoliko različitih modela cijene električne energije (Slika 4-3), a s ciljem minimiziranja troška ukupne električne energije i zadovoljenja različitih ograničenja zadanih izrazima (4-2), (4-3) i (4-5).



Slika 4-3: Modeli cijena električne energije korišteni u analizama (model „Cijena 1“ preuzet je s <http://www.hep.hr/>, dok su ostali preuzeti s <http://www.nordpoolspot.com/>).

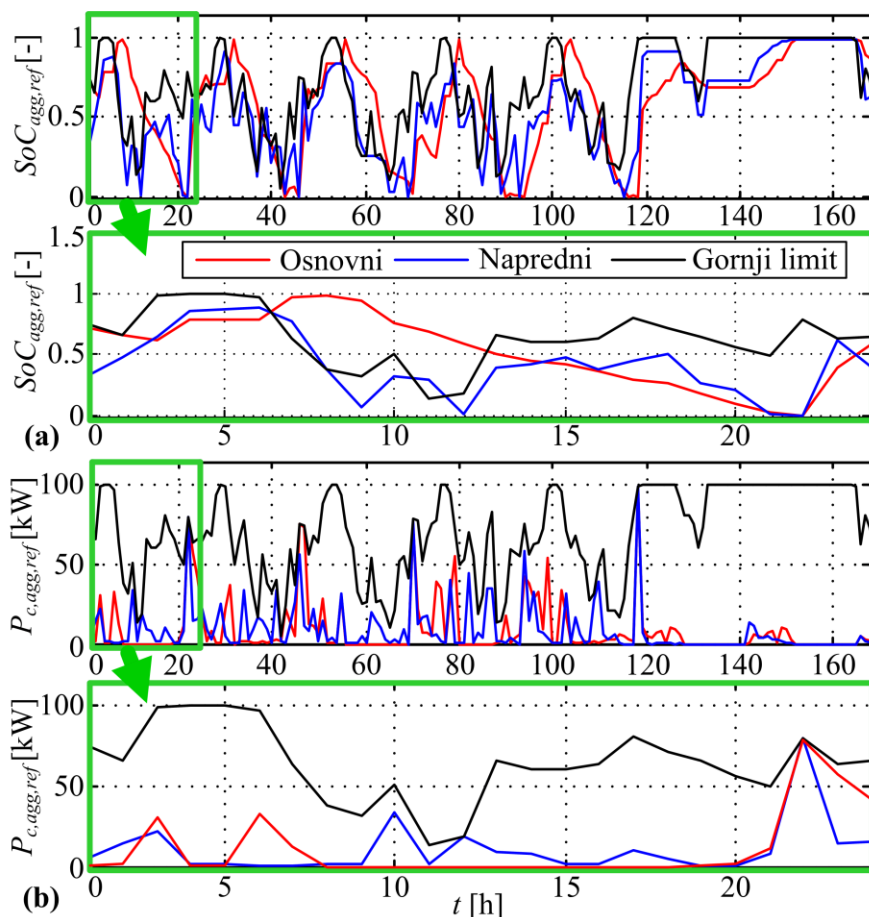
Ukupni trošak električne energije koji se nastoji minimizirati dan je s

$$C_{bat} = \sum_{k=0}^{N_t-1} C_{el}(k) \frac{P_{c,agg}(k)\Delta T}{1000}, \quad (4-9)$$

gdje je agregatna snaga $P_{c,agg}$, inače dana u W, podijeljena faktorom 1000 kako bi se pretvorila u kW zbog cijene električne energije koja je zadana u jedinici EUR/kWh.

Valja podsjetiti da su rješenja dobivena DP optimiranjem globalno optimalna za danu vremensku diskretizaciju i diskretizaciju prostora varijabli stanja i upravljačkih varijabli (vidi poglavlje 2).

Optimalni profili agregatne snage punjenja i agregatnog SoC-a dani su na slici 4-4 za osnovni i napredni model na tjednoj vremenskoj bazi (puni profili uključuju period od tri mjeseca jer su ulazne razdiobe modela dane na tom periodu). Profili snaga punjenja razlikuju se zbog razlika između agregatnih modela, te pripadnih ulaznih razdioba i formulacija ograničenja vezanih uz SoC (usporedi izraze (4-3) i (4-5)). Valja zamijetiti da je ograničenje vezano uz gornji limit $SoC_{agg,max}$ (vidi izraz (4-5)) većinom zadovoljeno u slučaju naprednog modela agregatne baterije, što nije slučaj kod osnovnog modela agregatne baterije. Pritom je kršenje tog ograničenja kod osnovnog modela agregatne baterije uzrokovano fiksnim iznosom gornjeg limita SoC-a (vidi izraz (4-3)), koje proizlazi iz nerealistične pretpostavke da je ukupni kapacitet agregatne baterije dostupan cijelo vrijeme (cijelo vrijeme raspoloživ za punjenje). S druge strane, ograničenje vezano uz gornji limit snage punjenja $P_{c,agg,ref}$ zadovoljeno je u slučaju oba modela, jer se ograničenje (4-2) konzistentno primjenjuje kod oba modela. Ovdje su agregatni SoC i agregatna snaga punjenja označeni sa $SoC_{agg,ref}$ i $P_{c,agg,ref}$ jer će ti vremenski profili biti referentni kod raspodjele agregatne snage po pojedinačnim vozilima.



Slika 4-4: Detalji rezultata DP optimiranja punjenja temeljem dvaju agregatnih modela flote EV prikazani na tjednoj vremenskoj bazi i detalji istih razdioba na razini jednog radnog dana vezani uz agregatni SoC (a) i agregatnu snagu punjenja (b) (primijenjen je model cijene električne energije „Cijena 1“ sa slike 4-3).

Optimiranje punjenja EV flote predstavljene distribuiranim modelom. Optimiranje vremenskih profila snage punjenja pojedinačnih EV unutar flote također je provedeno DP algoritmom (vidi poglavlje 5). Ponovno je cilj minimizirati trošak električne energije uz zadovoljenje postavljenih ograničenja. Optimiranje punjenja pojedinog EV provedeno je uzastopno i budući da nije postavljen limit na maksimalnu snagu koja se može povući iz mreže, konačno rješenje predstavlja globalno optimalno rješenje (više detalja dano je u poglavlju 5). S jedne strane distribuirani model najbolje opisuje flotu EV jer obuhvaća različita ograničenja vezana uz pojedinačna EV, dok je s druge strane optimiranje punjenja temeljem takvog modela računalno znatno zahtjevnije od optimiranja punjenja temeljem agregatnih modela (zbog većeg broja upravljačkih varijabli i varijabli stanja).

4.3.2. Raspodjela agregatne snage punjenja po pojedinačnim vozilima

Osim DP optimiranja punjenja pojedinačnih EV, za potrebe validacije agregatnih modela flote EV predložen je i algoritam raspodjele prethodno optimirane agregatne snage $P_{c,agg,ref}$ po pojedinačnim vozilima, pri čemu se u obzir uzimaju sva realistična ograničenja koja ne mogu biti obuhvaćena agregatnim modelima. Potom se pojedinačni profili snage punjenja, SoC-a i troška električne energije, nakon raspodjele, ponovno agregiraju kako bi se mogli usporediti s polaznim pripadajućim agregatnim profilima. Osim za validaciju agregatnih modela flote, ovaj algoritam raspodjele agregatne snage može se pogodno iskoristiti kod vođenja/upravljanja punjenjem flote EV zbog znatno manje računalne složenosti od DP optimiranja punjenja svakog EV zasebno.

Formulacija problema optimiranja. Problem raspodjele referentne agregatne snage punjenja $P_{c,agg,ref}$ po pojedinačnim EV može biti formulirano kao problem optimiranja koji minimizira sljedeću ciljnu funkciju

$$J = \sum_{k=0}^{N_t-1} \left| P_{c,agg,ref}(k)\Delta T - \sum_{j=1}^{N_v} E_{c,j}(k) \right|, \quad (4-10)$$

gdje j označava indekse vozila koja su parkirana i dostupna za punjenje. U jednadžbi (4-10) energija punjenja pojedinačne baterije u trenutnom diskretnom vremenskom koraku (satu) k vezana je uz snagu punjenja

$$E_{c,j}(k) = t_{c1,j}(k)P_{c,j}(k),$$

gdje $t_{c1,j}$ predstavlja trajanje parkiranja u tom satu. Snaga punjenja $P_{c,j}$ limitirana je s obzirom na maksimalnu snagu punjača $P_{cmax,ind}$:

$$P_{c,j}(k) \leq P_{cmax,ind}. \quad (4-11)$$

Jedino ograničenje na pojedinačne baterije vozila koja se pune vezano je uz prethodno spomenuto ograničenje tipa jednakosti za vozila koja napuštaju distributivni centar (k_f označava vremenski trenutak odlaska j -tog vozila):

$$SoC_j(k_f) = 1. \quad (4-12)$$

Ovo ograničenje vezano je uz pretpostavku punih baterija odlazećih vozila, a koje se također

koristi i kod parametriranja (agregatnih) modela baterije.

Struktura algoritma raspodjele agregatne snage punjenja na pojedinačna vozila. Rješavanje problema optimiranja (4-10)-(4-12) za flotu od 10 vozila ($N_v = 10$) i period od tri mjeseca s vremenom diskretizacije od 1 sata može biti računalno vrlo zahtjevno. Ovo bi bilo posebno izraženo ako bi se flota sastojala od nekoliko stotina vozila i ako bi vremenski period preko kojeg se optimira bio još dulji, što je često i slučaj u raznim studijama energetske planiranja. Iz tih se razloga ovdje predlaže računalno jednostavniji i praktičniji, ali podoptimalan algoritam distribuiranja agregatne snage punjenja. Dijagram toka ovog algoritma prikazan je na slici 4-5, gdje je svaki označeni korak (blok) detaljno objašnjen u nastavku. Glavna ideja je iterativno raspoređivati prethodno optimiran, referentni vremenski profil agregatne energije $E_{c,ref}(k) = P_{c,agg,ref}(k) \cdot \Delta T$ po pojedinačnim baterijama u svakom diskretnom vremenskom trenutku k , a da se pritom zadovolje ograničenja (4-11) i (4-12), sve dok stvarna agregatna energija punjenja ne postane veća ili jednaka referentnoj. Pritom se raspodjela obavlja po prioritetima punjenja pojedinih vozila, koji su vezani uz trenutni SoC i preostalo vrijeme punjenja (parkiranosti) vozila.

Proračun prioriteta punjenja pojedinačnih EV u floti. Referentna agregatna energija punjenja može biti raspodijeljena samo po vozilima koja su parkirana u distributivnom centru (i spojena na mrežu). Zbog toga se prioriteti punjenja računaju samo za ova vozila, dok se prioriteti ostalih vozila (vozila na cesti i vozila parkirana negdje izvan distributivnog centra) postavljaju na vrijednost 0. Prioriteti punjenja su proporcionalni odstupanju SoC-a baterije od 100% vrijednosti ($1-SoC_j$) i obrnuto proporcionalni preostalome trajanju parkiranosti vozila, tj. prikopčanosti na mrežu ($t_{c2,j}$; vidi ilustraciju na slici 4-6):

$$p_j(k) = \frac{1 - SoC_j(k)}{t_{c2,j}(k)}, \quad k = 0, 1, \dots, N_t - 1, \quad j = 1, 2, \dots, N_v. \quad (4-13)$$


mreže i obrnuto (vidi sliku 4-1a te sliku 4-6). Kako bi se u tom slučaju ograničenje na maksimalnu snagu punjenja (4-11) moglo uzeti u obzir, referentna agregatna snaga $P_{c,agg}$ preračunava se u referentnu agregatnu energiju

$$E_{c,ref}(k) = P_{c,agg}(k) \cdot \Delta T, \quad (4-14)$$

koju je potom, umjesto referentne snage, potrebno raspodijeliti po pojedinačnim vozilima ($\Delta T = 1h$). Ograničenje na maksimalnu energiju koja se može pohraniti u j -to vozilo u k -tom koraku tada iznosi

$$E_{c_{max,1,j}}(k) = t_{c1,j}(k) P_{c_{max,ind}}, \quad (4-15)$$

gdje $P_{c_{max,ind}}$ predstavlja maksimalnu snagu punjača, a $t_{c1,j}$ trajanje spojenosti vozila na mrežu u trenutnom koraku k (vidi sliku 4-6 gdje je ta veličina grafički definirana; odgovara razdiobi $n_{dc,j}$ sa slike 4-1a).



Slika 4-6: Ilustracija karakterističnih intervala punjenja vozila vezanih uz računanje limita energije punjenja za j -to vozilo.

Osim ograničenja (4-11), potrebno je zadovoljiti i ograničenje vezano uz SoC na odlasku (4-12) iz kojeg se, na temelju jednadžbe stanja individualne baterije (4-6), izvodi i drugo ograničenje na maksimalnu energiju punjenja j -tog vozila u k -tom koraku (vidi izvod u prilogu C):

$$E_{c_{max,2,j}}(k) = \left(1 + \Delta SoC_j(k) - SoC_j(k)\right) \frac{E_{max,ind}}{\eta_{ch}}, \quad (4-16)$$

gdje ΔSoC_j predstavlja promjenu SoC-a zbog vožnje (vidi izraz (4-6b)), a $E_{max,ind}$ kapacitet pojedinačne baterije.

Za konačni gornji limit na energiju punjenja j -tog vozila uzet je manji od izračunata dva limita:

$$E_{c_{max,j}}(k) = \min(E_{c_{max,1,j}}(k), E_{c_{max,2,j}}(k)). \quad (4-17)$$

Donji limit na energiju punjenja računa se korištenjem sljedeće jednadžbe s ciljem zadovoljenja ograničenja na konačni SoC (4-12) i s minimalnim kršenjem ograničenja na maksimalnu snagu punjenja pojedinačnog vozila $P_{c\max,ind}$ (vidi detalje u prilogu C; za objašnjenje veličina $t_{c1,j}$ i $t_{c2,j}$ vidi sliku 4-6).

$$E_{c\min,j}(k) = \begin{cases} t_{c1,j}(k)P_{c\min,j}(k), & \text{za } P_{c\min,j}(k) \leq P_{c\max,ind} \\ \left[1 - SoC_j(k)\right] \frac{E_{\max,ind} t_{c1,j}(k)}{\eta_{ch} t_{c2,j}(k)}, & \text{za } P_{c\min,j}(k) > P_{c\max,ind} \end{cases}, \quad (4-18)$$

gdje je $P_{c\min,j}(k)$ dan izrazom

$$P_{c\min,j}(k) = \left\{ 1 + \Delta SoC_j(k) - SoC_j(k) - \eta_{ch} [t_{c2,j}(k) - t_{c1,j}(k)] \frac{P_{c\max,ind}}{E_{\max,ind}} \right\} \frac{E_{\max,ind}}{\eta_{ch} t_{c1,j}(k)} \quad (4-19)$$

Pritom se postavlja prioritet na donji limit energije punjenja nad gornjim limitom punjenja kako slijedi:

$$E_{c\max,j}(k) = E_{c\min,j}(k), \text{ za } E_{c\min,j}(k) > E_{c\max,j}(k) \quad (4-20)$$

Iterativna raspodjela referentnog agregatnog profila snage/energije po pojedinačnim baterijama. Referentna energija punjenja $E_{c,ref}(k)$ (4-14) raspodjeljuje se po pojedinačnim vozilima/baterijama iterativno, kako je prikazano na dijagramu toka na slici 4-5, sve dok ostvarivi agregatni iznos raspodijeljene energije punjenja $E_{c,f}(k)$ ne postane veći ili jednak referentnoj agregatnoj vrijednosti energije punjenja $E_{c,ref}(k)$, tj. sve dok se ne ispuni sljedeći uvjet:

$$\Delta E(k) = E_{c,ref}(k) - E_{c,f}(k) \leq 0, \quad (4-21)$$

gdje je $E_{c,f}(k)$ jednak

$$E_{c,f}(k) = \sum_{j=1}^{N_v} E_{c,j}(k). \quad (4-22)$$

Razdioba energije $\Delta E_{c,j}(k)$ računa se s obzirom na prioritete punjenja EV dobivene jednadžbom (4-13), te koristi za izračun iznosa potencijalne energije punjenja pojedinačnih baterija:

$$E_{c,j0}(k) = E_{c,j}(k) + \underbrace{\frac{P_j(k)}{\sum_{j=1}^{N_v} P_j(k)} \Delta E(k)}_{\Delta E_{c,j}}, \quad (4-23)$$

gdje $E_{c,j}(k)$ predstavlja već raspodijeljenu energiju punjenja j -tog vozila unutar k -tog diskretnog vremenskog trenutka (vidi sliku 4-5). Potom se „stvarna“ raspodijeljena energija punjenja j -tog vozila $E_{c,j}(k)$ dobiva ograničavanjem potencijalne energije punjenja $E_{c,j0}(k)$ donjim limitom (4-18) i gornjim limitom (4-17) kako slijedi:

$$E_{c,j}(k) = \begin{cases} E_{c,\min,j}(k), & \text{za } E_{c,j0}(k) < E_{c,\min,j}(k) \\ E_{c,\max,j}(k), & \text{za } E_{c,j0}(k) > E_{c,\max,j}(k) \\ E_{c,j0}(k), & \text{za } E_{c,\min,j}(k) \leq E_{c,j0}(k) \leq E_{c,\max,j}(k) \end{cases} \quad (4-24)$$

Gornji postupak razdiobe energije punjenja iterativno se ponavlja kako bi se preostala energija ΔE dana izrazom (4-21) raspodijelila na vozila spojena na mrežu, a čije baterije još nisu pune (vidi desnu petlju u dijagramu toka na slici 4-5). Na slici 4-5, indeksi vozila spojenih na mrežu sadržani su u skupu $J_0(k)$, a indeksi vozila spojenih na mrežu i čije baterije još nisu pune sadržani su u skupu $J(k)$. Iterativni proces završava kad je čitav iznos zahtijevane agregatne energije raspodijeljen ($\Delta E \leq 0$) ili ako su baterije svih vozila spojenih na mrežu pune. Prije početka nove iteracije u novom diskretnom vremenskom trenutku (vidi lijevu petlju na slici 4-5), nove vrijednosti SoC-a (tj. $SoC_j(k+1)$) svih pojedinačnih baterija računaju se u skladu s modelom (4-6) i snagom punjenja.

Nakon završetka raspodjele referentne energije punjenja po pojedinačnim vozilima u svakom diskretnom koraku k (Slika 4-5), trenutni $SoC_j(k)$ vozila spojenih na mrežu ($j \in J_0(k)$) upotrijebljen je za računanje ostvarivog agregatnog SoC-a koji se nadalje koristi kod validacije agregatnih modela baterije:

$$SoC_{agg,f}(k) = \frac{\sum_{j \in J_0(k)} SoC_j(k)}{N_v}. \quad (4-25)$$

Ista jednadžba koristi se i za dobivanje agregatnog SoC-a pojedinačnih vozila čije je punjenje optimirano DP algoritmom. S druge strane, izračunata ostvariva agregatna energija punjenja

$E_{c,f}(k)$ (vidi jednadžbu (4-22)) koristi se za određivanje agregatne snage punjenja na sljedeći način:

$$P_{c,agg}(k) = E_{c,f}(k) / \Delta T. \quad (4-26)$$

4.4. Validacija predloženih modela flote vozila

Kako bi se opisani agregatni modeli flote EV validirali, uvedeni su pokazatelji sličnosti referentne i ostvarive krivulje agregatne energije punjenja, $K_E(E_{c,ref}, E_{c,f})$ i krivulja agregatnog referentnog i ostvarivog SoC-a, $K_{soc}(SoC_{agg,ref}, SoC_{agg,f})$. Pokazatelj sličnosti zapravo predstavlja koeficijent korelacije dviju krivulja (tj. signala), njegova definicija dana je u prilogu D, a računa se korištenjem Matlab funkcije *corrcoef*. Pokazatelj poprima vrijednost 1 za potpunu korelaciju, tj. za potpuno jednake ulazne signale, 0 za slučaj da korelacija među ulaznim signalima ne postoji, te -1 za slučaj potpune antikorelacije ulaznih signala. Veća korelacija između karakterističnih varijabli agregatnog i distribuiranih modela flote (koji su realističniji od agregatnih jer uključuju ograničenja vezana uz pojedinačna vozila, a koja ne mogu biti obuhvaćena agregatnim modelima) podrazumijeva veću točnost agregatnog modela flote.

Sljedeće kratice uvedene su za označavanje rezultata dobivenih različitim modelima flote EV i pripadnim metodama punjenja:

- **DP-IND:** DP optimiranje punjenja temeljem distribuiranog modela flote (optimiranje punjenja svakog vozila razmatra se zasebno), koje rezultira globalno optimalnim rješenjima u slučaju da ne postoji limit na agregatnu snagu koja se može povući iz mreže,
- **DP-AGGR1 i DP-AGGR2:** DP optimiranje punjenja temeljem osnovnog, odnosno naprednog agregatnog modela flote EV,
- **DISTR1 i DISTR2:** Primjena algoritma raspodjele agregatne snage punjenja po pojedinačnim vozilima, temeljena na referentnoj agregatnoj snazi punjenja dobivenoj korištenjem DP-AGGR1, odnosno DP-AGGR2 pristupa.

4.4.1. Validacija modela temeljena na realističnim ulaznim razdiobama

Tablica 4-1 prikazuje podatke vezane uz ukupni zahtjev transporta za energijom na kotačima (E_{dem}) i agregatnu energiju punjenja (E_{ch}) za slučaj različitih modela flote EV i metoda punjenja

za period od tri mjeseca (period unutar kojeg su snimani podaci kojim su parametrirani modeli flote EV; vidi poglavlje 3). Pritom se agregatna energija punjenja E_{ch} , i za agregatne i za distribuirane modele flote EV (vidi izraz (4-26)), računa korištenjem izraza

$$E_{ch} = \sum_{k=0}^{N_t-1} P_{c,agg}(k) \Delta T. \quad (4-27)$$

Ukupni zahtjev transporta za energijom E_{dem} na kotačima za osnovni agregatni model flote EV (4-1) računa se izrazom:

$$E_{dem}(k) = \sum_{k=0}^{N_t-1} \eta_{dch} \left(\frac{1}{\eta_{dch}} P_{dem,agg}(k) - \eta_{ch} |P_{reg,agg}(k)| \right) \Delta T, \quad (4-28)$$

za distribuirani model (4-6) izrazom:

$$E_{dem}(k) = \sum_{j=1}^{N_v} \sum_{k=0}^{N_t-1} \eta_{dch} \left(\frac{1}{\eta_{dch}} P_{dem,j}(k) - \eta_{ch} |P_{reg,j}(k)| \right) \Delta T, \quad (4-29)$$

te za napredni agregatni model (4-4) izrazom:

$$E_{dem}(k) = \sum_{k=0}^{N_t-1} \eta_{dch} \left(SoC_{out,avg} \frac{\Delta n_{out,dc}(k)}{N_v} - SoC_{in,avg}(k) \frac{\Delta n_{in,dc}(k)}{N_v} \right) E_{max,agg}. \quad (4-30)$$

Ovi podaci pokazuju da je ukupan zahtjev za energijom punjenja gotovo identičan kod svih modela. Ova verifikacija provedena je kako bi se osiguralo da su razlike u korelacijskim pokazateljima i troškovima vezanim uz energiju punjenja uzrokovane inherentnim svojstvima modela, a ne razlikama u apsolutnim iznosima zahtijevane energije.

Tablica 4-1: Usporedba zahtijevane energije i energije punjenja za različite modele flote EV i pripadne metode punjenja.

Model	E_{dem} [kWh]	E_{ch} [kWh]
DP-IND	14191.4 (0.0%)	16766.8 (0.0%)
DP-AGGR1	14191.4 (+5.7·10 ⁻¹¹ %)	16766.8 (+5.7·10 ⁻¹¹ %)
DP-AGGR2	14191.4 (+2.2·10 ⁻¹⁰ %)	16766.8 (+2.2·10 ⁻¹⁰ %)
DISTR1	14191.4 (-1.8·10 ⁻⁷ %)	16766.8 (-1.8·10 ⁻⁷ %)
DISTR2	14191.4 (+2.2·10 ⁻¹⁰ %)	16766.8 (+2.2·10 ⁻¹⁰ %)

Legenda: E_{dem} – ukupna zahtijevana aktivna energija na kotačima, E_{ch} – ukupna energija punjenja.

Validacijski rezultati dani u tablici 4-2 za različite modele cijena električne energije (Slika 4-3) pokazuju da SoC korelacijski pokazatelji leže u rasponu od 0.34 do 0.65 za osnovni model, dok su za napredni model bitno veći (od 0.70 do 0.82). Sličan trend može se zamijetiti za korelacijske pokazatelje energije punjenja koji poprimaju vrijednosti u rasponu: [0.74, 0.82] za napredni model u odnosu na raspon [0.53, 0.65] za osnovni model. Ovi rezultati kvantitativno ilustriraju da je napredni model agregatne baterije točniji i realističniji u smislu punjenja. Drugim riječima, u slučaju naprednog modela, agregatna energija punjenja i pripadni SoC odzivi manje su modificirani kad su primijenjeni na distribuirani model, tj. u tom slučaju DP optimiranje na agregatnoj razini daje realističnije rezultate. Valja podsjetiti da se kod primjene osnovnog modela krši realistično ograničenje na SoC (4-5) (vidi sliku 4-4a).

Nadalje, ukupni trošak optimirane agregatne energije punjenja (vidi C_{bat} rezultate u tablici 4-3 za DP-AGGR pristupe) znatno je niži u slučaju osnovnog modela (DP-AGGR1) nego u slučaju naprednog modela (DP-AGGR2). Ovo se može objasniti manje zahtjevnim (ujedno i manje realističnim) ograničenjima postavljenima u slučaju problema optimiranja punjenja temeljem osnovnog modela (vidi sliku 4-4). Ovo se potvrđuje činjenicom da trošak energije punjenja u slučaju osnovnog modela značajno raste (do 40%) kad se rezultati optimiranja na agregatnoj razini primjene na distribuirani model flote (Tablica 4-4). Ovo je znatno manje izraženo u slučaju naprednog agregatnog modela flote (do 13% razlika u predviđanju troška punjenja). Drugim riječima, osnovni agregatni model predviđa izraženo nerealističan (preoptimističan) trošak energije punjenja, što nije slučaj s naprednim modelom.

Konačno, validacija agregatnih modela flote i odgovarajućih distribuiranih modela provedena je u odnosu na DP-IND rezultate koji su uzeti kao baza. Tablica 4-3 pokazuje usporedbu svih troškova punjenja u odnosu na DP-IND trošak punjenja (relativna odstupanja su dana u zagradama u postotcima). Ovi rezultati jasno potvrđuju da su troškovi punjenja temeljem osnovnog agregatnog modela preoptimistični (-7% do -28%) kad se usporede s DP-IND troškovima punjenja, dok je ova razlika manje naglašena u slučaju naprednog modela (+2% do -9%). Troškovi punjenja distribuiranih modela (DISTR1 i DISTR2 rezultati u tablici 4-3) veći su od 1% do 3% kad se usporede s DP-IND troškovima. Veća potrošnja može se objasniti činjenicom da je predložena metoda raspodjele agregatne snage (DISTR1 i DISTR2) po

pojedinačnim vozilima inherentno podoptimalna i ne može dati bolje rezultate od globalno optimalnog DP-IND pristupa. Međutim, vrlo male relativne razlike upućuju na točnost računalno-efikasnog algoritma raspodjele agregatne snage.

Tablica 4-5 predstavlja pokazatelje sličnosti za svaku metodu u usporedbi s DP-IND pristupom. Ovi rezultati potvrđuju trendove zamijećene u tablici 4-2, tako potvrđujući da je napredni model prikladniji za studije energetske planiranja nego što je to osnovni model. Međutim, valja zamijetiti da su pokazatelji sličnosti kod DISTR2 metode slični odgovarajućim pokazateljima za DISTR1 metodu. Ovaj rezultat sugerira da se osnovni model također može razmatrati za upotrebu kod hijerarhijskog vođenja punjenja flote EV. Pritom treba napomenuti da, osim „off-line“ optimiranja, kombinacija optimiranja punjenja na agregatnoj razini DP-AGGR1 ili DP-AGGR2 i algoritma raspodjele agregatna snage (DISTR1 ili DISTR2) može biti efikasno upotrijebljena za „on-line“ upravljanje punjenjem flote EV kao alat za optimiranje na pomičnom vremenskom prozoru (modelsko prediktivno upravljanje, engl. skrać. MPC) na sličan način kako je to realizirano u [88] gdje je korišteno linearno programiranje. Ovo bi naročito bilo primjenjivo za flote dostavnih EV gdje se raspoređuje dostava robe i pripadnih ruta tipično planiraju (dakle, unaprijed poznati) jedan dan unaprijed.

Tablica 4-2: Pokazatelji sličnosti vremenskih odziva agregatnih modela flote EV u odnosu na odgovarajuće odzive distribuiranih modela flote EV za različite modele cijene električne energije.

Usporedba	Cijena 1		Cijena 2		Cijena 3		Cijena 4	
	K_{soc}	K_E	K_{soc}	K_E	K_{soc}	K_E	K_{soc}	K_E
DP-AGGR1 vs DISTR1	0.65	0.59	0.34	0.62	0.60	0.53	0.64	0.65
DP-AGGR2 vs DISTR2	0.81	0.74	0.70	0.82	0.80	0.77	0.82	0.81

Tablica 4-3: Ukupni troškovi punjenja dobiveni korištenjem različitih modela flote EV i metoda punjenja te raznih modela cijene električne energije.

Metoda	C_{bat1} [EUR]	C_{bat2} [EUR]	C_{bat3} [EUR]	C_{bat4} [EUR]
DP-IND	1378.3 (+0.0%)	433.1 (+0.0%)	664.5 (+0.0%)	854.2 (+0.0%)
DP-AGGR1	996.7 (-27.7%)	328.9 (-24.1%)	617.6 (-7.1%)	789.5 (-7.6%)
DISTR1	1390.2 (+0.9%)	442.9 (+2.3%)	672.8 (+1.2%)	868.7 (+1.7%)
DP-AGGR2	1309.7 (-5.0%)	394.2 (-9.0%)	653.2 (-1.7%)	871.6 (+2.0%)
DISTR2	1416.5 (+2.8%)	445.2 (+2.8%)	673.7 (+1.4%)	876.3 (+2.6%)

* C_{bat1} , C_{bat2} , C_{bat3} , C_{bat4} odgovaraju troškovima punjenja agregatne baterije za slučaj kad su korišteni modeli cijene električne energije „Cijena 1“, „Cijena 2“, „Cijena 3“, „Cijena 4“ sa slike 4-3

Tablica 4-4: Usporedba troškova energije punjenja temeljem agregatnih modela flote s troškovima odgovarajućih distribuiranih modela za različite modele cijene električne energije.

Usporedba	Cijena 1	Cijena 2	Cijena 3	Cijena 4
DISTR1 vs DP-AGGR1	+39.5%	+34.7%	+8.9%	+10.0%
DISTR2 vs DP-AGGR2	+8.2%	+12.9%	+3.1%	+0.5%

Tablica 4-5: Pokazatelji sličnosti vremenskih odziva različitih modela flote EV uz primjenu različitih metoda punjenja, sve u odnosu na DP-IND metodu.

Metoda	Cijena 1		Cijena 2		Cijena 3		Cijena 4	
	K_{soc}	K_E	K_{soc}	K_E	K_{soc}	K_E	K_{soc}	K_E
DP-IND	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
DP-AGGR1	0.53	0.44	0.26	0.68	0.58	0.67	0.61	0.70
DISTR1	0.86	0.75	0.84	0.86	0.88	0.70	0.90	0.92
DP-AGGR2	0.81	0.51	0.76	0.80	0.85	0.77	0.86	0.79
DISTR2	0.85	0.73	0.84	0.93	0.87	0.82	0.88	0.90

4.4.2. Validacija modela temeljena na dodatnim ulaznim razdiobama


U prethodnom odjeljku, validacija izvedenih modela flote EV provedena je na temelju snimljenih ulaznih razdioba. Kako bi se potvrdilo da rezultati validacije ne ovise o korištenim ulaznim razdiobama, u ovom odjeljku provedena je dodatna validacija na temelju drugog skupa ulaznih razdioba. Kako bi i dalje bile realistične, nove ulazne razdiobe izvedene su iz snimljenih podataka korištenjem Monte Carlo metode i sintetičkih voznih ciklusa. Osim novih ulaznih razdioba modela flote EV, provedena je i validacija za različite nove modele cijena električne energije i za različita ograničenja na maksimalnu snagu punjača $P_{cmax,ind}$.

Dodatna validacija modela flote EV i optimiranja punjenja u smislu analize osjetljivosti na pogreške modeliranja (npr. korisnosti punjenja i dostupnost za punjenje EV tijekom perioda parkiranosti u distributivnom centru) dana je u poglavlju 6.

Generiranje dodatnih ulaznih razdioba modela flote EV za potrebe dodatne validacije. Nove vremenske sekvence dolazaka i odlazaka iz distributivnog centra generirane su za 10 vozila ($N_v = 10$) na temelju snimljenih podataka korištenjem Monte Carlo metode (detalji generiranja sekvence za jedno vozilo dani su u prilogu E). Na temelju generiranih sekvenci, izračunata je

sljedeća ulazna razdioba potrebna za parametriranje distribuiranog modela flote EV: udio vremena parkiranosti vozila j unutar svakog diskretnog vremenskog trenutka k ($n_{dc,j}$, $j = 1, 2, \dots, N_v$), te razdiobe potrebne za parametriranje osnovnog i naprednog agregatnog modela flote EV (Slika 4-7a): (i) broj vozila koja dolaze u distributivni centar ($\Delta n_{dc,in}$), (ii) broj vozila koja odlaze iz distributivnog centra ($\Delta n_{dc,out}$) i (iii) broj vozila spojenih na mrežu ($n_{dc,agg}$). Valja naglasiti da su razdiobe izračunate za 1-mjesečni vremenski period na satnoj vremenskoj bazi (na slici 4-7 su za potrebe ilustracije usrednjene na 24-satni period).


Nadalje, svaki par odlaska i dolaska (vidi $t_{out,DC,q}$, $t_{in,DC,q}$ na slici E-1) određuje vremenski period u kojem vozilo odrađuje vožni ciklus. Potom je, korištenjem metode Markovljevih lanaca i pristupa 2 (vidi poglavlje 3), za svaki par odlaska i dolaska generiran sintetički vožni ciklus čije trajanje odgovara duljini trajanja perioda ($t_{in,DC,q} - t_{out,DC,q}$). Pritom je korištena matrica prijelaznih vjerojatnosti dobivena iz svih snimljenih vožnih ciklusa (za ovu primjenu vožni ciklusi nisu klasterirani). Nadalje, simulacijom modela putničkog EREV vozila (danog u poglavlju 2) preko generiranih sintetičkih ciklusa dobivene su razdiobe vezane uz zahtjev transporta za energijom za vremenski period od 1 mjeseca (Slika 4-7b).



Slika 4-7: Generirane i snimljene ulazne razdiobe agregatnih modela flote EV vezane uz broj parkiranih vozila i broj odlazaka i dolazaka u distributivni centar (a) i zahtjev transporta (b) usrednjene na 24-satni period.

Generirane razdiobe (GEN), usrednjene na 24-satni period, prikazane su na slici 4-7 usporedno s usrednjenim razdiobama dobivenima na temelju snimljenih podataka (REC; originalnog trajanja od tri mjeseca). Mogu se zamijetiti slični trendovi među prikazanim razdiobama koji potvrđuju valjanost generiranih razdioba.


Generiranje dodatnih modela cijena električne energije. Generirani su i dodatni modeli cijena električne energije za vremenski period od 1 mjeseca, čiji su 24-satni detalji prikazani na slici 4-8. Rasponi vrijednosti u kojima se kreću cijene postavljeni su da budu blizu vrijednosti realističnih modela cijena prikazanih na slici 4-3. Model cijene C_{el1} je sinusna vremenska funkcija, dok je model cijene C_{el2} slučajno generiran u prethodno definiranom rasponu. Modeli cijena C_{el3} i C_{el4} generirani su iz sinusnih funkcija različitih frekvencija, a na koje su dodane slučajno generirane vrijednosti.



Slika 4-8: Različiti „umjetno“ generirani modeli cijena električne energije prikazani na dnevnoj vremenskoj bazi.

Usporedni optimizacijski rezultati. Agregatni modeli flote validirani su za slučaj ulaznih vremenskih razdioba prikazanih na slici 4-7, različite modele cijena električne energije (Slika 4-8) te različita ograničenja na maksimalnu snagu punjenja $P_{cmax,ind}$. Slika 4-9 prikazuje troškove punjenja i pokazatelje sličnosti dobivene za različite modele flota u odnosu na DP-IND rezultate. Na slici 4-9a, gdje je korišten dvotarifni model cijene električne energije „Cijena 1“ sa slike 4-3, rezultati validacijskog testa dani su za različite gornje limite na snagu punjenja pojedinačne baterije ($P_{cmax,ind}$) i za slučaj ulaznih razdioba generiranih Monte Carlo metodom (Slika 4-7). Ovi rezultati potvrđuju da DP-AGGR1 pristup konzistentno daje preoptimistične

rezultate vezane uz troškove punjenja (usporedi tablicu 4-3), tj. troškovi punjenja nerealistično su niži za oko 25% kad se usporede s referentnim DP-IND troškovima bez obzira na gornji limit $P_{cmax,ind}$. Ovo je, međutim, znatno manje izraženo za slučaj naprednog agregatnog modela (DP-AGGR2 slučaj), gdje su troškovi punjenja 6%-8% niži od DP-IND troškova. U slučaju distribuiranog punjenja, odstupanja troškova punjenja u odnosu na DP-IND pristup smanjeni su i iznose oko 2% neovisno o tome primjenjuje li se DISTR1 ili DISTR2 pristup. Pokazatelji sličnosti trajektorija SoC-a (K_{soc}) i snaga punjenja (K_E) (DP-IND je uzet kao referentni) značajno su veći u slučaju primjene naprednog agregatnog modela flote (DP-AGGR2) nego u slučaju primjene osnovnog modela (DP-AGGR1), te su vrlo blizu „ostvarivim“ DISTR1 i DISTR2 pokazateljima vezanim uz DISTR1:DISTR2 pristupe.



Slika 4-9: Validacija agregatnih modela flote i odgovarajućih distribuiranih modela u odnosu na DP-IND rezultate za slučaj različitih iznosa maksimalne snage punjenja $P_{cmax,ind}$ i osnovni (dvtarifni) model cijene električne energije i ulaznih vremenskih razdioba modela generiranih Monte Carlo metodom (a) i različite „umjetno“ generirane modele cijena el. energije uz $P_{cmax,ind} = 10$ kW i osnovne ulazne vremenske razdiobe modela (b).

U slučaju „umjetno“ generiranih modela cijene električne energije (Slika 4-8) i osnovnih vremenskih razdioba (dobivenih na temelju snimljenih podataka), dobivaju se rezultati prikazani na slici 4-9b. Prema ovim rezultatima, DP-AGGR1 troškovi punjenja niži su u odnosu na DP-IND troškove za 30%-36%, dok je u slučaju DP-AGGR2 troškova ovaj raspon reduciran na 15%-21%. Povećanje odstupanja troškova punjenja u odnosu na DP-IND posebno je naglašeno u slučaju cijena električne energije s većim amplitudama (C_{el3} i C_{el4} sa slike 4-8). Odstupanja DISTR1 i DISTR2 troškova punjenja od DP-IND troškova također su veća u odnosu na slučaj kad je upotrijebljen osnovni model cijene električne energije (usporedi slike 4-9a i 4-9b). Pokazatelji sličnosti prilično su ujednačeni neovisno o modelu cijene električne energije, sa sličnim trendovima koji potvrđuju inferiornost DP-AGGR1 pristupa u odnosu na DP-AGGR2 pristup.

5. Optimiranje punjenja flote električnih vozila


U ovom poglavlju predlažu se postupci optimiranja punjenja temeljem različitih modela flote EV opisanih u poglavlju 4. Model flote EV zajedno s optimalnim algoritmom punjenja predstavlja podlogu za ispitivanje isplativosti elektrifikacije flote vozila u kombinaciji s uvođenjem obnovljivih izvora energije (OIE), te za upravljanje punjenjem flote EV u realnom vremenu. Stoga se alati predstavljeni u ovom i prethodnom poglavlju koriste za tehnokoekonomsku analizu elektrifikacije konkretne flote dostavnih vozila u poglavlju 6. Osim navedenog, rezultati optimiranja punjenja mogu poslužiti za validiranje različitih modela flote EV, kako je dano u poglavlju 4.

5.1. Dodatne razdiobe potrebne kod optimiranja punjenja flote


5.1.1. Razdiobe vezane uz proizvodnju električne energije iz obnovljivih izvora energije (OIE)

Pretpostavlja se da se proizvodnja električne energije iz OIE temelji na solarnim panelima koji bi se postavili na krovu distributivnog centra u kojemu se pretpostavlja i punjenje flote hipotetskih električnih vozila. Vremenska razdioba globalne horizontalne sunčeve iradijacije (kW/m^2) generirana je korištenjem Meteonorm 5.1 softvera za egzaktnu lokaciju distributivnog centra i period godine tijekom kojeg su snimani podaci vezani uz dostavna vozila (od 1.9. do 30.11.). Razdioba za originalna tri mjeseca prikazana na slici 5-1c usrednjena je na jedan dan i jedan tjedan kako bi se dobile dnevne, odnosno tjedne razdiobe sunčeve iradijacije (slike 5-1a,b). Razdiobe sa slike 5-1 koriste se za računanje vremenskih razdioba proizvedene snage iz obnovljivih izvora energije (P_{OIE}) množenjem s različitim pretpostavljenim vrijednostima instalirane efektivne površine solarnih panela ($A_{eff,PV}$) i korisnošću solarnih panela η_{OIE} (ovdje je pretpostavljena korisnost od 0.15). Ovo je ilustrirano na slici 5-2 za slučaj dnevne razdiobe i dva scenarija instaliranih efektivnih površina solarnih panela: $A_{eff,PV1} = 6600 \text{ m}^2$ i $A_{eff,PV2} = 20100 \text{ m}^2$. Osim razdiobe proizvodnje električne energije P_{OIE} , na slici 5-2 prikazane su i procijenjene razdiobe potrošnje električne energije u distributivnom centru (detalji su dani u sljedećem odjeljku), na temelju kojih se može vidjeti

da u prvom scenariju ne postoji višak proizvedene energije iz OIE (Slika 5-2a), dok u drugom scenariju višak postoji (Slika 5-2b).




Slika 5-1: Razdioba globalne horizontalne Sunčeve iradijacije za lokaciju distributivnog centra i period od jednog dana (a), jednog tjedna (b) i tri mjeseca (c).



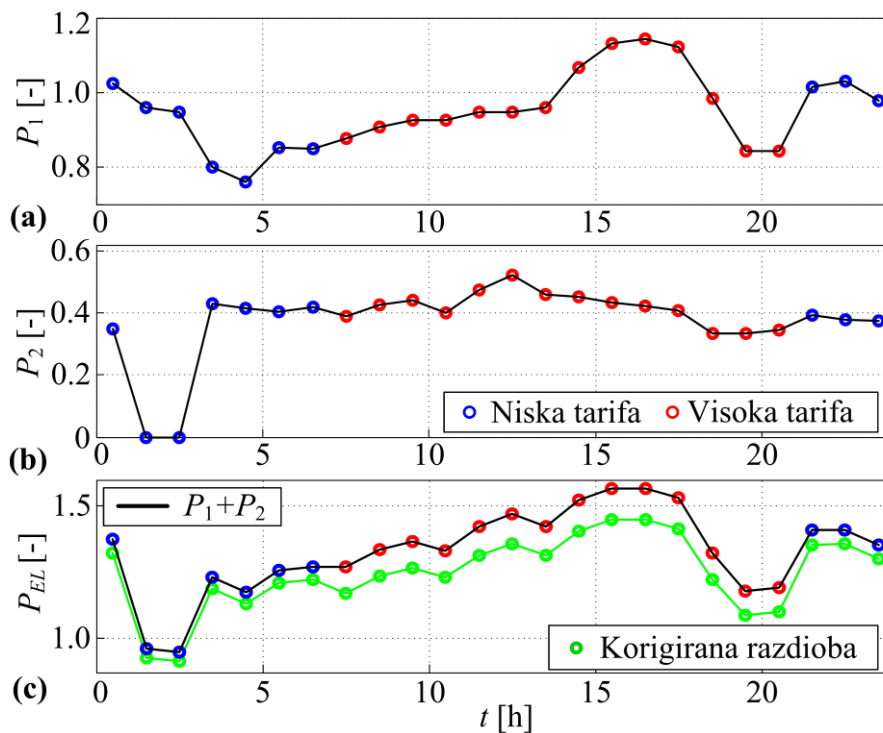
Slika 5-2: Procijenjene vremenske razdiobe potrošnje električne snage u distributivnom centru (P_{EL} , vidi sljedeći odjeljak) i proizvodnje snage iz solarnih panela (P_{OIE}) za dva scenarija: bez (a) i s viškom proizvedene energije iz OIE (b).

5.1.2. Razdioba potrošnje električne energije potrošača unutar distributivnog centra

Vremenska razdioba potrošnje električne energije u distributivnom centru (bez potrošnje vezane uz punjenje hipotetske flote EV) procijenjena je na temelju sljedećih raspoloživih podataka: (a) ukupna potrošnja „radne“ energije dane u kWh i (b) vršna snaga zajedno s vremenom u kojem je zabilježena, a koji su zabilježeni posebno za periode niske i visoke tarife za svaki dan tijekom perioda od jedne godine. Procijenjena dnevna razdioba snage potrošnje električne energije (slike 5-4a,b) dobivene su usrednjavanjem zabilježenih vršnih dnevnih vrijednosti snaga tijekom jednogodišnjeg razdoblja (Slika 5-3). Potom je konačna razdioba snage (Slika 5-4c) dobivena zbrajanjem razdioba potrošnje iz dva različita dijela distributivnog centra te korekcijom kojom se postiže jednakost između prosječne procijenjene i prosječne zabilježene dnevne potrošnje električne energije. Pritom se korekcija razdiobe provodi posebno za period niske tarife, te posebno za period visoke tarife na način da se originalna (dnevna) razdioba skalira tako da njena suma iznosi 1, a koja se nakon toga množi s prosječnom zabilježenom dnevnom potrošnjom. Procijenjena dnevna razdioba potrošnje P_{EL} potom je proširena (ponavljanjem) na tjedni te na tromjesečni vremenski period.



Slika 5-3: Razdioba vršnih radnih snaga potrošnje električne energije za nisku i visoku tarifu za dva dijela distributivnog centra tijekom 365 dana.



Slika 5-4: Razdiobe vršnih snaga potrošnje električne energije za nisku i visoku tarifu za dva dijela distributivnog centra (a,b), te ukupna razdioba usrednjenih vršnih snaga zajedno s korigiranom razdiobom (b).

5.2. Optimiranje punjenja temeljem distribuiranog modela flote

U ovom potpoglavlju opisano je optimiranje punjenja korištenjem distribuiranog modela flote EV, a temeljeno na algoritmu dinamičkog programiranja (DP) s ciljem minimiziranja troškova punjenja čitave flote. Pritom je punjenje svakog pojedinačnog vozila u floti spregnuto s punjenjem ostalih vozila preko zajedničkog ograničenja na maksimalnu snagu koja se može povući iz mreže. Stoga se optimiranje punjenja provodi sukcesivno (vozilo po vozilo) uz računanje ograničenja na maksimalnu snagu iz mreže za svako vozilo zasebno. Rezultati optimiranja dobiveni ovdje (uz izostavljanje ograničenja na maksimalnu snagu iz mreže) u poglavlju 4 se koriste za validiranje agregatnih modela flote EV.

5.2.1. DP optimiranje punjenja pojedinačnog električnog vozila

U nastavku se opisuje postupak optimiranja punjenja pojedinačnog vozila (j -tog) unutar flote

te se zbog preglednosti u narednim izrazima u ovom odjeljku izostavlja indeks j .

Vremenski diskretna ciljna funkcija koja se treba minimizirati za pojedinačno vozilo, formulira se kako slijedi

$$J = \sum_{k=0}^{N_t-1} F(P_c(k), k), \quad (5-1)$$

gdje funkcija $F(\cdot)$ poprima oblik

$$F(P_{c,j}(k), k) = C_{el}(k) \frac{P_c(k) \Delta T}{1000} + L(k), \quad k = 0, 1, \dots, N_t - 1, \quad (5-2)$$

i gdje $C_{el}(k)$ predstavlja razdiobu cijene električne energije po 1 kWh (vidi npr. sliku 4-3), a $L(k)$ predstavlja funkciju koja penalizira kršenje ograničenja vezanih uz snagu punjenja P_c i SoC baterije:

$$L(k) = L_{soc1}(k) + L_{soc2}(k) + L_{P1}(k) + L_{P2}(k) + L_{P_{cum}}(k). \quad (5-3)$$

Pritom je izraz L_{soc1} vezan uz donja i gornja ograničenja SoC-a:

$$L_{soc1}(k) = \begin{cases} K_{g1}, & \text{za } SoC(k+1) < SoC_{\min} \\ K_{g2}, & \text{za } SoC(k+1) > SoC_{\max} \\ 0, & \text{u protivnom} \end{cases}. \quad (5-4)$$

Izraz L_{P1} onemogućava punjenje ($P_c(k) > 0$) u slučaju kad vozilo nije spojeno na mrežu (tj. kada je $n_{dc}(k) = 0$, vidi poglavlje 4 i sliku 4-1a):

$$L_{P1}(k) = \begin{cases} K_{g3}, & \text{za } n_{dc}(k) = 0 \wedge P_c(k) > 0 \\ 0, & \text{u protivnom} \end{cases}. \quad (5-5)$$

Penalizacijska funkcija L_{soc2} definirana je kako slijedi

$$L_{soc2}(k) = \begin{cases} K_{g4} + K_{g5}(1 - SoC_{\text{mod}}(k+1)), & \text{za } n_{dc,o}(k) = 1 \wedge SoC_{\text{mod}}(k+1) < 1 \\ 0, & \text{u protivnom} \end{cases}, \quad (5-6)$$

gdje je $SoC_{\text{mod}}(k+1)$ dobiven kao $SoC_{\text{mod}}(k+1) = SoC(k) + \eta_{ch} P_c(k) \Delta T / E_{\max}$ i predstavlja vrijednost SoC-a u $k+1$ -om diskretnom vremenskom koraku bez uzimanja zahtjeva za snagom u k -tom koraku u obzir (vidi izraz (4-6)). Postavljanjem penalizacijske funkcije (5-6) postiže

se da vrijednost $SoC_{mod}(k+1)$ bude jednaka 1 ako se vozilo treba odspojiti s mreže u k -tom koraku ($n_{dc,o}(k) = 1$). Drugim riječima, vozilo treba biti potpuno puno u trenutku odspajanja s mreže.

Druga penalizacijska funkcija vezana uz snagu punjenja dana je izrazom

$$L_{P_2}(k) = \begin{cases} K_{g6} + K_{g7} \left(\frac{P_c(k) - n_{dc}(k)P_{cmax,ind}}{P_{cmax,ind}} \right), & \text{za } P_c(k) > n_{dc}(k)P_{cmax,ind}, \\ 0, & \text{u protivnom} \end{cases}, \quad (5-7)$$

gdje $P_{cmax,ind}(k)$ predstavlja gornji limit na individualnu snagu punjenja. Konačno, kršenje ograničenja na maksimalnu agregatnu snagu punjenja vozila iz mreže ($P_{cum,lim}$) penalizira se kako slijedi

$$L_{P_{cum}}(k) = \begin{cases} K_{g8} + K_{g9} \left(\frac{P_c(k) - P_{cum,lim}(k)}{P_{cum,lim}(k)} \right), & \text{za } P_c(k) > P_{cum,lim}(k), \\ 0, & \text{u protivnom} \end{cases}, \quad (5-8)$$

gdje se promjenjivi limit $P_{cum,lim}(k)$ računa iznova nakon optimiranja punjenja svakog EV pritom uzimajući u obzir prethodno optimirane profile snaga punjenja. Na ovaj način se osigurava zadovoljenje ograničenja na maksimalnu snagu koja se može povući iz mreže $P_{cmax,grid}$ (više detalja dano je u sljedećem odjeljku).

Penalizacijski članovi (5-4) i (5-5) imaju prioritete nad članovima (5-6)-(5-8), zato što SoC limiti i nemogućnost punjenja vozila odspojenih s mreže predstavljaju fizička ograničenja koja moraju biti nužno zadovoljena. Zbog toga se težinski faktori K_{gi} ($i = 1, 2, 3$) postavljaju na vrijednosti koje su dovoljno velike kako bi se strogo zadovoljila ta ograničenja. S druge strane, ograničenja penalizirana izrazima (5-6)-(5-8) implementirana su kao “meka” ograničenja, gdje je kršenje ograničenja penalizirano proporcionalno iznosu kršenja ograničenja.

Kao sažetak formulacije optimizacijskog problema (5-1)-(5-8), može se reći da je cilj DP optimiranja odrediti vremenski odziv snage punjenja pojedinog EV, $P_c(k)$, $k = 0, 1, \dots, N_t$, koji će minimizirati trošak punjenja:

$$C_{bat,ind} = \sum_{k=0}^{N_t-1} C_{el}(k) \frac{P_c(k) \Delta T}{1000}, \quad (5-9)$$

a da se pritom zadovolje postavljena ograničenja.

Važan aspekt DP optimiranja je mogućnost postavljanja konačne vrijednosti varijable stanja (SoC_{end}) proširivanjem funkcije $F(\cdot)$ ciljne funkcije (vidi izraz (2-21)) s dodatnim penalizacijskim članom

$$J_f = K_f | SoC(N_t) - SoC_{end} |, \quad (5-10)$$

gdje K_f predstavlja težinski faktor koji se postavlja u dovoljno visoku vrijednost koja garantira zadovoljenje uvjeta $SoC(N_t) = SoC_{end}$. Uobičajeno se vrijednost konačnog SoC-a baterije na kraju vremenskog horizonta optimiranja postavlja da bude jednaka početnoj vrijednosti kako slijedi:

$$SoC(N_t) = SoC_{end} = SoC_{init} = SoC(0). \quad (5-11)$$

Gornji problem optimiranja riješen je korištenjem DP algoritma, koja garantira globalno optimalno rješenje za danu rezoluciju upravljačkih varijabli i varijabli stanja [65, 69] (vidi poglavlje 2). Kako DP algoritam pretpostavlja diskretno vrijeme te diskretne upravljačke varijable i varijable stanja, prije optimiranja potrebno je odrediti/zadati konačan broj ovih varijabli (konstante N_t , N_{soc} i $N_{control}$). Horizont optimiranja N_t postavljen je da bude 2184, što odgovara 2184 sati preko perioda od tri mjeseca (91 dan) tijekom kojih su snimani podaci vezani uz flotu vozila i na temelju kojih su dobivene ulazne vremenske razdiobe (vidi poglavlje 3). Ostali DP optimizacijski parametri dani su u prilogu F.

5.2.2. DP optimiranje punjenja flote električnih vozila

Ukupna snaga koja se povlači iz mreže za punjenje flote od N_v vozila dana je s

$$P_{c,cum}(k) = \sum_{j=1}^{N_v} P_{c,j}(k), \quad k = 0, 1, \dots, N_t - 1, \quad (5-12)$$

gdje $P_{c,j}(k)$ predstavlja snagu punjenja j -tog vozila u k -tom diskretnom vremenskom intervalu. Ukupni trošak energije punjenja svih baterija unutar flote dani su izrazom

$$C_{bat} = \sum_{j=1}^{N_v} C_{bat,ind,j}, \quad (5-13)$$

gdje $C_{bat,ind,j}$ predstavlja trošak punjenja baterije j -tog vozila i računa se pomoću izraza (5-9). Optimiranje punjenja svih vozila unutar flote odvija se sukcesivno i gornje kumulativno ograničenje na snagu punjenja za $j+1$ vozilo određeno je iz prethodno optimirane snage punjenja j -tog vozila:

$$P_{cum,lim,j+1}(k) = P_{cum,lim,j}(k) - P_{c,j}(k), \quad j = 1, 2, \dots, N_v. \quad (5-14)$$

Iterativni process (5-14) inicijaliziran je kako slijedi

$$P_{cum,lim,1}(k) = P_{c,max,grid}, \quad k = 0, 1, \dots, N_t - 1, \quad (5-15)$$

što znači da vozila, koja su visoko na listi redoslijeda optimiranja punjenja, imaju više slobode kod optimiranja zbog viših limita na snagu punjenja. Iz ovog slijedi da će rezultati optimiranja ovisiti o redoslijedu optimiranja i da će zbog toga biti podoptimalni. Problem se može zaobići ako bi se punjenje cijele flote EV formuliralo kao cjelovit problem optimiranja koji bi se rješavao DP algoritmom. Međutim, time bi se znatno povećala računalna složenost zbog velikog broja upravljačkih varijabli i varijabli stanja. Procjena trajanja takvog (cjelovitog) optimiranja dana je izrazom $N_{soc}^{N_v-1} \cdot N_{control}^{N_v-1} \cdot T_{optim,ind}$, gdje $T_{optim,ind}$ označava trajanje optimiranja punjenja jednog vozila, dok je procjena sukcesivnog optimiranja punjenja dana izrazom $N_v \cdot T_{optim,ind}$. Zbog eksponencijalne ovisnosti trajanja optimiranja s brojem vozila N_v , cjelovito optimiranje punjenja flote EV bi postalo neizvedivo već za nekoliko EV unutar flote. Sukcesivno optimiranje (označeno kao DP-IND) provedivo je jer se vrijeme izvođenja povećava linearno s brojem vozila N_v i to je razlog zašto je nadalje korišteno sukcesivno optimiranje. Kako bi se odredila osjetljivost rezultata optimiranja na redoslijed optimiranja pojedinih vozila unutar flote, sukcesivno optimiranje punjenja čitave flote EV može se provesti za nekoliko slučajno generiranih redoslijeda optimiranja i ono rješenje koje rezultira minimalnim troškom punjenja (5-13) proglašeno je optimalnim (detalji ovog pristupa i odgovarajući rezultati dani su u odjeljku 5.4.1).

5.3. Optimiranje punjenja temeljem agregatnog modela flote EV

5.3.1. Heuristički postupak punjenja flote EV

Heuristički pristup punjenju flote EV korišten u ovom radu preuzet je iz [4, 89]. Glavni cilj ove metode je utvrditi vremenski odziv snage punjenja agregatne baterije $P_{c,agg}(k)$ koja maksimizira korištenje energije proizvedene iz OIE. Pritom se višak energije proizvedene iz OIE e_{ceep} definira kao energija koja nije iskorištena za opskrbu ostalih potrošača (čija je potrošnja snage označena s P_{EL} , vidi sliku 5-2), tako postajući dostupna za punjenje flote EV:

$$e_{ceep}(k) = \begin{cases} (P_{OIE}(k) - P_{EL}(k))\Delta T, & \text{za } P_{OIE}(k) \geq P_{EL}(k) \\ 0, & \text{za } P_{OIE}(k) < P_{EL}(k) \end{cases} \quad (5-16)$$

Agregatna baterija puni se s maksimalnim mogućim iznosom viška proizvedene energije iz OIE, pritom zadovoljavajući ograničenja na maksimalnu snagu punjenja i agregatni SoC (vidi izraze (4-2) i (4-3)). Električna energija iz mreže koristi se samo u slučajevima kada se kumulativni zahtjev transporta u sljedećih y diskretnih vremenskih koraka uključujući i trenutni ($y=2$ je korišten ovdje) ne može zadovoljiti s trenutnim viškom proizvedene energije iz OIE ($e_{ceep}(k)$) ili trenutnom energijom pohranjenoj u agregatnoj bateriji ($SoC_{agg}(k) \cdot E_{max,agg}$). Sažeti opis heurističkog postupka punjenja iz [4, 89], uz originalnu notaciju, dan je u prilogu G.

5.3.2. DP optimiranje punjenja temeljem agregatnog modela flote EV

DP optimiranje punjenja temeljem osnovnog agregatnog modela flote EV. Za primjenu DP algoritma za optimiranje punjenja temeljem agregatnog modela flote EV potrebno je definirati vektor varijabli stanja i vektor upravljačkih varijabli, odgovarajuća ograničenja, ciljnu funkciju i model procesa (vidi formulaciju općeg problema optimiranja i primjenu DP algoritma optimiranja u odjeljku 2.2.1). U slučaju agregatnog modela flote, varijabla stanja je agregatni SoC baterije ($x = SoC_{agg}$), a upravljačka varijabla je agregatna snaga punjenja baterije ($u = P_{c,agg}$). Varijabla stanja i upravljačka varijabla diskretiziraju se redom u $N_x = N_{soc}$ i $N_u = N_{control}$ diskretnih vrijednosti u odgovarajućim rasponima $[SoC_{agg,min}, SoC_{agg,max}]$ i $[P_{c,agg,min}, P_{c,agg,max}]$.

Za osnovni agregatni model flote EV, opća vremenski diskretna jednadžba stanja (2-10) dana je izrazom (4-1). Podintegralna funkcija unutar ciljne funkcije (2-9) definira se kao

$$\begin{aligned}
F(\text{SoC}_{agg}(k+1), P_{grid}(P_{c,agg}(k), k), k) = & C_{el}(k) \frac{P_{grid}(P_{c,agg}(k), k) \Delta T}{1000} \\
& + K_{g1} \left\{ H^-(\text{SoC}_{agg}(k+1) - \text{SoC}_{agg, \min}) + H^-(\text{SoC}_{agg, \max} - \text{SoC}_{agg}(k+1)) \right\} \\
& + K_{g1} \left\{ H^-(n_{dc,agg}(k) \cdot P_{c, \max, ind} - P_{c,agg}(k)) \right\}, \quad (5-17) \\
& + K_{g2} \left\{ H^-(P_{c, \max, grid} - P_{c,agg}(k)) \right\} \\
& + K_{g3} \left\{ |P_{c, \max, grid} - P_{c,agg}(k)| H^-(P_{c, \max, grid} - P_{c,agg}(k)) \right\}
\end{aligned}$$

gdje $C_{el}(k)$ predstavlja cijenu električne energije po 1 kWh, a $H^{-1}(z)$ invertiranu Heaviside-ovu funkciju definiranu izrazom

$$H^-(z) = \begin{cases} 0, & \text{za } z \geq 0 \\ 1, & \text{za } z < 0 \end{cases} \quad (5-18)$$

Pritom se snaga koja se povlači iz mreže P_{grid} [W] računa prema

$$P_{grid}(P_{c,agg}(k), k) = \begin{cases} P_{c,agg}(k) - P_{OIE}(k) + P_{EL}(k), & \text{za } P_{c,agg}(k) - P_{OIE}(k) + P_{EL}(k) \geq 0 \\ 0, & \text{za } P_{c,agg}(k) - P_{OIE}(k) + P_{EL}(k) < 0 \end{cases}, \quad (5-19)$$

gdje $P_{c,agg}(k) - P_{OIE}(k) + P_{EL}(k) < 0$ odgovara slučaju kad zahtjev snage za punjenje flote EV, $P_{c,agg}(k)$, te zahtjev snage od strane ostalih potrošača, $P_{EL}(k)$, može u potpunosti biti pokriven snagom proizvedenom iz OIE, $P_{OIE}(k)$. Pritom se razmatra samo jedan smjer energije (iz mreže prema EV i potrošačima), tj. podrazumijeva se da se višak proizvodnje iz OIE odbacuje (ne dobiva se novčana naknada za njega prilikom „punjenja“ mreže). Drugi i treći član s desne strane jednadžbe (5-17) penaliziraju redom ograničenja vezana uz agregatni SoC (4-3) i agregatnu snagu punjenja (4-2). Četvrti i peti član s desne strane jednadžbe (5-17) kažnjavaju kršenje ograničenja na maksimalnu snagu koja se može povući iz mreže $P_{c, \max, grid}$. Težinski faktori $K_{g1,2,3}$ trebaju biti postavljeni na dovoljno velike vrijednosti da se postavljena ograničenja zadovolje. Dodatno valja napomenuti da se u ciljnoj funkciji (5-17) ne uzima u obzir ograničenje SoC-a vezano uz pretpostavku da vozila napuštaju distributivni centar potpuno puna kao što je to bio slučaj u (5-2) (vidi također (5-6)). Ta pretpostavka je uzeta u obzir implicitno kroz razdiobe zahtjeva transporta za energijom (Slika 4-2) koje su korištene

za parametriranje osnovnog i naprednog agregatnog modela flote EV.

Sažeto, cilj DP optimiranja je odrediti vremenski odziv agregatne snage punjenja flote EV, koji minimizira trošak električne energije koja se uzima iz mreže:

$$C_{grid} = \sum_{k=0}^{N_t-1} C_{el}(k) \frac{P_{grid}(k)\Delta T}{1000}, \quad (5-20)$$

a da se pritom zadovolje postavljena ograničenja na varijable agregatne baterije i mreže.

Kao i kod distribuiranog modela flote EV, konačna vrijednost SoC-a tipično se postavlja da bude jednaka početnoj vrijednosti SoC-a (vidi npr. primjere optimiranja EV [16, 45]):

$$SoC_{agg}(N_t) = SoC_{agg,end} = SoC_{agg,init} = SoC_{agg}(0). \quad (5-21)$$

DP optimiranje punjenja temeljem naprednog agregatnog modela flote EV. Vremenski diskretna jednadžba stanja (2-10) za napredni agregatni model flote dana je izrazom (4-4). Podintegralna funkcija u izrazu (2-9) glasi

$$\begin{aligned} F(SoC_{agg}(k+1), P_{grid}(P_{c,agg}(k), k), k) = & C_{el}(k) \frac{P_{grid}(P_{c,agg}(k), k)}{1000} \Delta T \\ & + K_{g1} \left\{ H^-(SoC_{agg}(k) - SoC_{agg,min}) + H^-(1 - SoC_{agg}(k)) \right\} \\ & + K_{g2} \left\{ H^-(n_{dc,agg}(k) P_{c,max,ind} - P_{c,agg}(k)) \right\} \\ & + K_{g3} \left\{ \left| n_{dc,agg}(k) P_{c,max,ind} - P_{c,agg}(k) \right| H^-(n_{dc,agg}(k) P_{c,max,ind} - P_{c,agg}(k)) \right\}, \quad (5-22) \\ & + K_{g4} \left\{ H^-(n_{dc,agg}(k) / N_v - SoC_{agg}(k)) \right\} \\ & + K_{g5} \left\{ \left| n_{dc,agg}(k) / N_v - SoC_{agg}(k) \right| H^-(n_{dc,agg}(k) / N_v - SoC_{agg}(k)) \right\} \\ & + K_{g6} \left\{ H^-(P_{c,max,grid} - P_{c,agg}(k)) \right\} \\ & + K_{g7} \left\{ \left| P_{c,max,grid} - P_{c,agg}(k) \right| H^-(P_{c,max,grid} - P_{c,agg}(k)) \right\} \end{aligned}$$

gdje prvi član s desne strane predstavlja trošak energije koja se povlači iz mreže u intervalu ΔT , dok ostali članovi ponovno penaliziraju kršenje ograničenja vezanih uz SoC (4-5), maksimalnu snagu punjenja (4-2) i maksimalnu snagu koja se može povući iz mreže $P_{c,max,grid}$. Dio izraza (5-22) uz faktore K_{g4} i K_{g5} kažnjava kršenje ograničenja vezanog uz varijabilni gornji limit SoC-a (4-5) koji ovisi o broju vozila spojenih na mrežu $n_{dc,agg}$.

U jednadžbi (5-17) za osnovni model agregatne baterije podrazumijevaju se samo tvrda ograničenja, jer je model takav da će se za dane ulazne razdiobe optimiranjem sigurno pronaći rješenja koja ne krše niti jedno zadano ograničenje. S druge strane, u jednadžbi (5-22) za napredni model agregatne baterije, osim tvrdih ograničenja uključena su i meka ograničenja koja u slučaju nepostojanja kombinacije u kojoj se ne krši niti jedno ograničenje (za dane razdiobe) omogućava minimizaciju kršenja ograničenja ovisno o prioritetima ograničenja koja se postavljaju kroz težinske faktore K_{gi} , $i=1,2,\dots,7$ (numeričke vrijednosti navedenih parametara dane su u prilogu F). Pritom se najveći prioritet postavlja na zadovoljenje fizikalnog ograničenja vezanog uz SoC agregatne baterije $0 \leq SoC_{agg} \leq 1$ (dio uz faktor K_{g1}). Sljedeći prioritet postavljen je na varijabilni gornji limit SoC-a $n_{dc,agg}/N_v$ (dio uz faktore K_{g4} i K_{g5} ; vidi također izraz (4-5)), pa potom na ograničenje na maksimalnu snagu punjenja pojedinačnog vozila (dio uz faktore K_{g2} i K_{g3} ; vidi izraz (4-2)). Najmanji prioritet postavljen je na ograničenje maksimalne snage koja se može povući iz mreže (dio uz faktore K_{g6} i K_{g7}). Valja naglasiti da prioriteti ograničenja ovise o relativnim odnosima faktora koji penaliziraju ta ograničenja, a ne o apsolutnim iznosima tih faktora. Pritom veći relativni iznos nekog faktora daje veći prioritet pripadnom ograničenju (vidi prilog F).

Implementacijski aspekti. DP algoritam je temeljen na diskretiziranom prostoru vremenske varijable, varijabli stanja i upravljačkim varijablama. Iz tog razloga, glavni implementacijski aspekti DP algoritma vezani su uz [16]: (a) odabir broja diskretnih točaka za vrijeme (N_t), varijablu stanja (N_{soc}) i upravljačku varijablu ($N_{control}$) kao i definiranje odgovarajućih raspona ovih varijabli (t_f , $P_{c,agg,min}$, $P_{c,agg,max}$; $SoC_{agg,min}$, $SoC_{agg,max}$), (b) interpoliranje vrijednosti varijable stanja koje ne padaju na definirane diskretne vrijednosti, a koje su dobivene rješavanjem jednadžbe stanja (4-1) za osnovni model ili (4-4) za napredni model flote (vidi odjeljak 2.2.1) i (c) odabir težinskih faktora u ciljnoj funkciji (5-17) ili (5-22).

Broj diskretnih vremenskih točaka N_t određen je poznatim vremenskim horizontom optimiranja t_f i trajanjem jednog vremenskog koraka ΔT ($N_t = t_f / \Delta T$). S druge strane, parametri N_{soc} i $N_{control}$ podešeni su kao kompromis između računalne učinkovitosti i preciznosti rješenja optimiranja. Postavljeni su u dovoljno velike vrijednosti da se njihovim daljnjim povećanjem preciznost optimiranja više značajno ne poboljšava. Odabrani parametri DP algoritma optimiranja dani su u prilogu F.


DP algoritam optimiranja implementiran je u C programskom jeziku. Optimiranje za vremenski prozor od 3 mjeseca izvodi se u 34 sekunde na stolnom računalu s procesorom od 3.4 GHz i 8 GB instaliranog RAM-a.

5.3.3. Dvorazinsko optimiranje punjenja temeljem agregatnog modela flote

Motivacija. U prethodnim odjeljcima pretpostavlja se da vozila napuštaju distributivni centar s punom baterijom ($SoC_{out,avg} = 1$; vidi poglavlje 4 i objašnjenje jednadžbe (4-4)). Međutim, kod naprednog modela flote EV postoji mogućnost da zbog ove pretpostavke, koja se nastoji zadovoljiti, neka od zadanih ograničenja (npr. na maksimalnu snagu punjenja agregatne baterije (4-2)) budu prekršena jer su implementirana kao „meka“. Stoga je potrebno relaksirati uvjet $SoC_{out,avg} = 1$ kako bi se mogla zadovoljiti sva zadana ograničenja (vidi (5-22)), što bi naposljetku rezultiralo realističnijim rezultatima optimiranja. Osim toga, relaksacija zahtjeva $SoC_{out,avg} = 1$ omogućava otkrivanje punog potencijala upravljanja punjenjem flote EV.

Zbog navedenog, ovdje se predlaže dvorazinsko optimiranje, gdje se u nadređenoj petlji genetskim algoritmom optimiraju SoC vrijednosti vozila koja napuštaju distributivni centar, dok se u podređenoj petlji optimira snaga punjenja agregatne baterije DP algoritmom kako je opisano u prethodnom odjeljku. Prednost ovog pristupa je, osim upravljačkih varijabli (npr. $P_{c,agg}$), i mogućnost optimiranja strukturnih parametara sustava u nadređenoj petlji kao što su npr. maksimalna snaga punjača, površina instaliranih panela, itd.

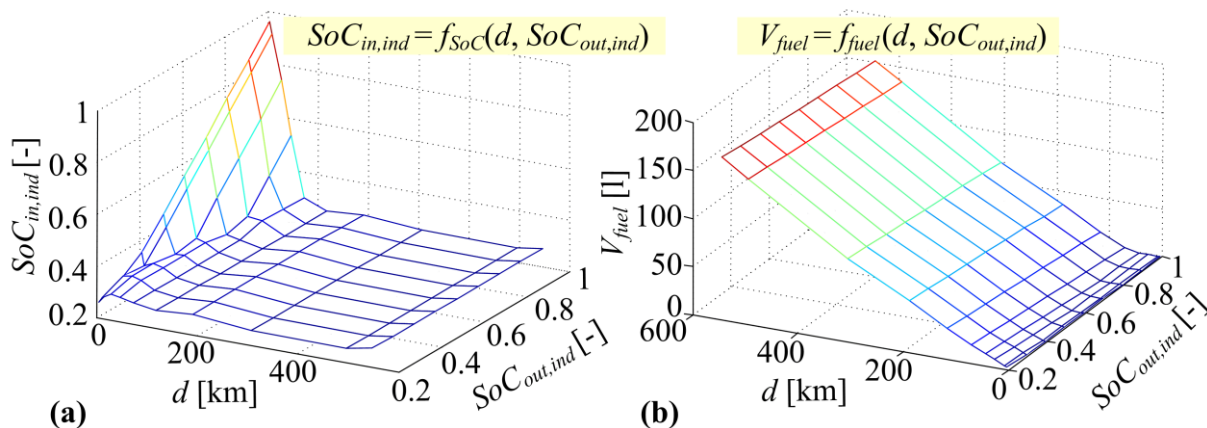
Modeliranje zahtjeva transporta temeljeno na odzivnim površinama. Zahtjev transporta modeliran je korištenjem odzivnih površina koje uspostavljaju funkcijsku ovisnost potrošnje goriva (V_{fuel}) i funkcijsku ovisnost SoC-a električnih vozila proširenog dometa (EREV) na dolasku u distributivni centar ($SoC_{in,ind}$; nazivan također i početni SoC iz perspektive procesa punjenja) o prijašnjoj udaljenosti (d) i SoC-u na odlasku ($SoC_{out,ind}$; nazivan konačni SoC sa stanovišta procesa pražnjenja) kako je ilustrirano na slici 5-5 [56].



Slika 5-5: Grafička ilustracija oznaka korištenih u modelu zahtjeva transporta temeljenog na odzivnim površinama.

Odzivne površine prikazane na slici 5-6 dobivene su na temelju simulacija modela EREV kamiona (vidi potpoglavlje 6.2 za detalje vezane uz model) za sve kombinacije konačnih vrijednosti SoC-a $SoC_{out,ind} \in [0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 0.1]$ i 10 reprezentativnih sintetičkih voznih ciklusa (vidi odjeljak 3.2.5 za detalje o sintezi i validaciji sintetičkih voznih ciklusa za potrebe modeliranja zahtjeva transporta za energijom), gdje 8 voznih ciklusa odgovaraju klasterima definiranim u tablici 3-2, dok dva dodatna ciklusa pokrivaju donju granicu ($d=4$ km s TP matricom iz klastera 1) i gornju granicu ($d=540$ km s TP matricom iz klastera 8). Pritom je u simulacijskom modelu masa EREV vozila (masa praznog vozila + masa tereta) postavljena u prosječnu vrijednost zabilježenu tijekom svih snimljenih voznih ciklusa koja iznosi 10.066 kg. Ukupno je provedeno 90 simulacija, što je bitno manje u odnosu na slučaj da su se provodile simulacije za svaku kombinaciju konačne vrijednosti SoC-a i svih snimljenih voznih ciklusa (oko 20.000 simulacija). 2D linearna interpolacija koristi se kako bi se dobili izlazi iz odzivnih površina $SoC_{in,ind}$ i V_{fuel} za proizvoljne vrijednosti ulaza d i $SoC_{out,ind}$.

Prema odzivnim površinama prikazanim na slici 5-6, samo vozni ciklusi s prijeđenom udaljenošću do približno 60 km mogu biti pokriveni potpuno električnom vožnjom (bez potrošnje goriva, $V_{fuel} = 0$), pod uvjetom da je baterija potpuno puna na početku voznog ciklusa ($SoC_{out,ind} = 1$). U slučaju relativno dugih voznih ciklusa (duljih od 60 km) ili u slučaju kraćih voznih ciklusa za koje vrijedi $SoC_{out,ind} < 1$, upravljačka strategija pogona će aktivirati CS režim rada s ciljem održanja SoC-a baterije, tako osiguravajući $SoC_{in,ind} \cong 0.3$, te trošeći gorivo ($V_{fuel} > 0$).



Slika 5-6: Model zahtjeva transporta EREV flote temeljen na odzivnim površinama, a vezan uz SoC na dolasku u distributivni centar $SoC_{in,ind}$ (a) i potrošnju goriva V_{fuel} (b).

Algoritam dvorazinskog optimiranja punjenja temeljem agregatnog modela flote EV.

Dvorazinsko optimiranje punjenja flote EV sastoji se od sljedećih koraka u svakoj iteraciji algoritma prikazanog funkcionalnim dijagramom toka na slici 5-7:

- 1) Generiranje inkremenata konačnih vrijednosti SoC-a ($\Delta SoC_{out,ind,i,j}$) za svaki snimljeni vozni ciklus ($i = 1, \dots, N_{dc,j}$) koji je definiran početnim i krajnjim trenutkom, te prijađenim putem za svako vozilo u floti ($j = 1, \dots, N_v$); te postavljanjem maksimalne snage punjenja pojedinačnih EV ($P_{cmax,ind}$); korištenjem višekriterijskog genetskog optimizacijskog algoritma NSGA-II (*engl. Nondominated sorting-based genetic algorithm*, [90]), s ciljem minimiziranja: (a) troška električne energije koja se koristi za punjenje i (b) maksimalne snage punjenja pojedinačnog EV preko punog vremenskog perioda.
- 2) Računanje vrijednosti $SoC_{out,ind,i,j}$ temeljem SoC inkremenata $\Delta SoC_{out,ind,i,j}$ i računanje potrošnje goriva ($V_{fuel,i,j}$) i početnih vrijednosti SoC-a ($SoC_{in,ind,i,j}$) iz modela zahtjeva transporta temeljenog na odzivnim površinama (vidi sliku 5-6).
- 3) Priprema ulaznih agregatnih vremenskih razdioba SoC-a ($SoC_{in,avg}$ i $SoC_{out,avg}$) temeljem $SoC_{out,ind,i,j}$ i $SoC_{in,ind,i,j}$ vrijednosti, a za potrebe DP optimiranja punjenja (vidi jednadžbu (4-4) i potpoglavlje 4.2 vezano uz parametrisiranje agregatnog modela flote).
- 4) Optimiranje agregatne snage punjenja korištenjem DP algoritma na podređenoj razini s ciljem minimiziranja troška energije punjenja i zadovoljenja postavljenih ograničenja

(vidi Odjeljak 5.3.2).

- 5) Proračun troška goriva (C_{fuel}), troška električne energije korištene za punjenje flote EV (C_{bat}) i kvantificiranog kršenja ograničenja vezanog uz snagu punjenja (4-2) ($P_{c,viol,total}$), te prosljeđivanje ovih pokazatelja NSGA-II algoritmu u nadređenoj petlji optimiranja.

Višekriterijski genetski algoritam NSGA-II koristi se u nadređenoj optimizacijskoj petlji jer rezultira Pareto optimalnim rješenjima po dva kriterija dana u točki 1 gore [90]. Pareto optimalna rješenja definiraju se kao rješenja koja su bolja (dominantna) u najmanje jednom kriteriju od bilo kojeg drugog rješenja. Opći genetski algoritam radi na principu sljedeće ideje. Postoji populacija jedinki od kojih svaka jedinka predstavlja jedno moguće rješenje zadanog problema. Za svaku jedinku se računa iznos ciljne funkcije koja može biti i višekriterijska. Što je iznos te ciljne funkcije veći, pripadna jedinka je lošija. Iz postojeće populacije operatorom *selekcije* odabiru se jedinke („roditelji“) iz kojih će se operatorom *križanja* generirati nove jedinke („djeca“). Nad novim jedinkama („djecom“) djeluje operator *mutacije* koji unosi dodatne slučajne varijacije u rješenja. U konačnici operatorom *zamjene* u populaciju ulaze nove jedinke. Posebnost NSGA-II algoritma je ta što se osim iznosa kriterijske funkcije za svako rješenje računa i CD mjera (*engl. Crowding-distance*), koja u obzir uzima Euklidsku udaljenost razmatranog rješenja od svih ostalih rješenja u smislu iznosa višekriterijske funkcije. Rješenje koje ima veći iznos CD mjere je udaljenije od ostalih rješenja i u tom smislu kvalitetnije jer daje veću raširenost Pareto optimalne fronte. Nakon generiranja novih rješenja operatorima *križanja* i *mutacije*, proširena se populacija sortira na temelju iznosa kriterijske funkcije i CD mjere te se odabire pred-definiran broj rješenja koji označava veličinu populacije, dok se ostala rješenja odbacuju. Ovaj postupak se ponavlja iterativno dok se ne zadovolje određeni uvjeti kao što je npr. maksimalan broj iteracija.

Krajnje i početne vrijednosti SoC-a (vidi sliku 5-5) računaju se iterativno za svako vozilo (korak 2 dvorazinskog optimiranja):

$$SoC_{out,ind,i,j} = SoC_{in,ind,i-1,j} + \Delta SoC_{out,ind,i,j}, \quad i=1,\dots,N_{dc,j}, \quad j=1,\dots,N_v, \quad (5-23a)$$

$$SoC_{in,ind,i,j} = f_{SoC}(d_{i,j}, SoC_{out,ind,i,j}), \quad i=1,\dots,N_{dc,j}, \quad j=1,\dots,N_v, \quad (5-23b)$$

gdje f_{SoC} označava funkciju definiranu s odzivnom površinom prikazanom na slici 5-6a.

Indeks i označava i -ti vozni ciklus odrađen j -tim vozilom čiji je ukupan broj odrađenih vozničkih ciklusa $N_{dc,j}$ (ukupan broj vozničkih ciklusa za sva vozila se tada može izračunati $N_{dc} = \sum_{j=1}^{N_v} N_{dc,j}$). Varijable $SoC_{out,ind,i,j}$ i $SoC_{in,ind,i,j}$ limitirane su na interval $[0, 1]$, dok je SoC inkrement limitiran na pozitivne vrijednosti $\Delta SoC_{out,ind,i,j} \geq 0$, jer je tok energije za punjenje vozila pretpostavljen samo u jednom smjeru (iz mreže u vozila, $P_{c,agg} \geq 0$). Jednosmjernan tok energije, te jednostavniji problem optimiranja, razlozi su zašto se inkreменти $\Delta SoC_{out,ind,i,j}$ optimiraju umjesto krajnjih vrijednosti SoC-a $SoC_{out,ind,i,j}$. Naime, ako bi se u slučaju jednosmjernog toka energije optimirale krajnje vrijednosti SoC-a $SoC_{out,ind,i,j}$, bilo bi potrebno postaviti dodatno ograničenje $SoC_{in,ind,i-1,j} \leq SoC_{out,ind,i,j}$ (za svaki i i j), koje se u slučaju optimiranja $\Delta SoC_{out,ind,i,j}$ eksplicitno izbjegava. Početna vrijednost SoC-a za iterativni proces dan jednadžbom (5-23a), $SoC_{in,ind,0,j}$, iznosi 1 za svako vozilo $j=1,2,\dots,N_v$.

Potom se ulazne razdiobe $SoC_{in,avg}(k)$ i $SoC_{out,avg}(k)$ agregatnog modela flote (4-4) dobivaju na način da se vrijednosti $SoC_{out,ind,i,j}$ i $SoC_{in,ind,i,j}$ mapiraju na vremensku os na temelju poznatih vremena o dolascima u i odlascima iz distributivnog centra, te se provodi usrednjavanje unutar istih vremenskih koraka k (sati) (korak 3 dvorazinskog optimiranja; vidi također odjeljak 4.2.2).

Nakon optimiranja agregatne snage punjenja na podređenoj razini (korak 4 algoritma), u sklopu koraka 5 algoritma, računa se trošak električne energije korištene za punjenje agregatne baterije (C_{bat}) uz primjenu jednadžbe (4-9), dok se trošak potrošenog goriva (C_{fuel}) računa kao

$$C_{fuel} = C_{fuel,unit} \sum_{j=1}^{N_v} \sum_{i=1}^{N_{dc,j}} V_{fuel,i,j} \cdot \quad (5-24)$$

Ovdje, $V_{fuel,i,j}$ označava volumen potrošenog goriva j -tog vozila tijekom i -tog voznog ciklusa (vidi sliku 5-6b), dok suma ovih volumena po svim voznim ciklusima i svim vozilima označava ukupnu potrošnju goriva čitave flote kroz vremenski period od tri mjeseca (izražen u litrama), dok $C_{fuel,unit}$ označava jediničnu cijenu (diesel) goriva za koju je uzeta vrijednost 1.25 EUR/l. Nadalje, kršenje ograničenja (4-2) vezanog uz snagu punjenja kvantificira se kako slijedi:

$$P_{c,viol}(k) = \begin{cases} 0, & \text{za } P_{c,agg}(k) \leq n_{dc}(k)P_{cmax,ind} \\ P_{c,agg}(k) - n_{dc}(k)P_{cmax,ind}, & \text{u protivnom} \end{cases} \quad (5-25)$$

Kumulativno kvantificirano kršenje tog ograničenja $\sum P_{c,viol}(k)\Delta T$ označava se relativno (u postotcima) u odnosu na ukupnu energiju punjenja agregatne baterije $\sum P_{c,agg}(k)\Delta T$:

$$P_{c,viol,total} = 100 \frac{\sum_{k=0}^{N_i-1} P_{c,viol}(k)\Delta T}{\sum_{k=0}^{N_i-1} P_{c,agg}(k)\Delta T} [\%] \quad (5-26)$$

i koristi se kao “meko” ograničenje kod optimiranja na nadređenoj razini kako je opisano u nastavku. Koeficijent kršenja ograničenja na snagu punjenja (5-26) uveden je zato što je ograničenje vezano uz $P_{c,agg}$ realizirano u jednadžbi (5-22) kao “meko” ograničenje i može biti prekršeno kako bi se SoC održao između donjeg i gornjeg limita.

Ukupni operativni troškovi (C_{total}) računaju se zbrajanjem troška punjenja agregatne baterije i troška goriva.

$$C_{total} = C_{bat} + C_{fuel} = \sum_{k=0}^{N_i-1} C_{el}(k) \frac{P_{c,agg}(k)\Delta T}{1000} + C_{fuel,unit} \sum_{j=1}^{N_v} \sum_{i=1}^{N_{dc,j}} V_{fuel,i,j} \quad (5-27)$$

Cilj NSGA-II algoritma je minimiziranje dvaju konfliktnih ciljeva: (a) ukupnih operativnih troškova C_{total} i (b) gornjeg limita snage punjenja pojedinačnih baterija $P_{cmax,ind}$. Ovo se postiže optimiranjem $\Delta SoC_{out,ind,i,j}$ i $P_{cmax,ind}$, pritom držeći koeficijent kršenja dan izrazom (5-26) blizu nule. Preciznije, dvokriterijska ciljna funkcija NSGA-II algoritma formulirana je kako slijedi:


$$C_1 = C_{total} + L, \quad (5-28a)$$

$$C_2 = P_{cmax,ind} + L, \quad (5-28b)$$

gdje je L definiran kao

$$L = \begin{cases} 0, & P_{c,viol,total} < 0.4\% \\ 10^8, & P_{c,viol,total} \geq 0.4\% \end{cases} \quad (5-29)$$

Na ovaj način, među rješenjima NSGA-II optimiranja održavaju se samo ona koja ne krše ograničenje vezano uz snagu punjenja, dok se ostala rješenja eliminiraju. Penalizacijska vrijednost postavljena je u proizvoljno veliku vrijednost 10^8 .



Slika 5-7: Dijagram toka dvorazinskog optimiranja punjenja flote EV ($\Delta SoC_{out,ind,i,j}$ – inkrement SoC-a baterije j -tog EV neposredno prije početka i -tog voznog ciklusa).

5.4. Rezultati optimiranja punjenja

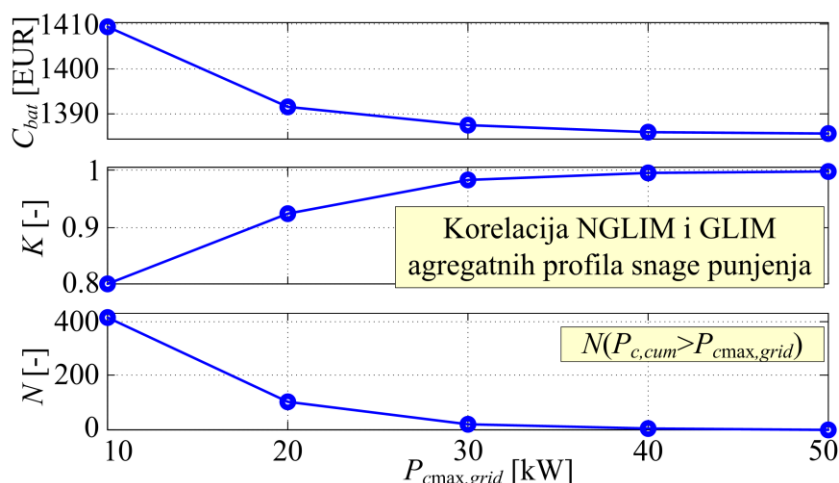
U ovom poglavlju prvo se daju DP rezultati optimiranja punjenja temeljenog na distribuiranom modelu flote EV bez proizvodnje iz OIE. Potom se daju usporedni rezultati DP optimiranja i heurističkog punjenja flote temeljenog na osnovnom agregatnom modelu flote EV za različite scenarije proizvodnje iz OIE. Naposljetku se daju rezultati vezani uz dvorazinsko optimiranje usporedno s rezultatima standardnog jednorazinskog DP optimiranja, gdje također nije uzeta u obzir proizvodnja iz OIE.

5.4.1. Rezultati optimiranja temeljenog na distribuiranom modelu flote EV

Sukcesivno DP optimiranje punjenja pojedinačnih vozila provedeno je za različite vrijednosti


gornjih ograničenja na snagu koja se može povući iz mreže ($P_{cmax,grid}$) i za dvotarifni model cijene električne energije (model "Cijena 1" prikazan na slici 4-3). Rezultati optimiranja prikazani na slici 5-8 uključuju: ukupne troškove punjenja flote EV (C_{bat}), pokazatelj korelacije (K) agregatnih profila snage punjenja ($P_{c,cum}(k)$ iz jednadžbe (5-12)) dobivenih za slučaj kad nije postavljen gornji limit na snagu iz mreže (NGLIM) i za slučaj kad je taj limit postavljen (GLIM; za slučajno generirane redosljede punjenja EV u floti), te broj diskretnih vremenskih trenutaka (sati) unutar kojih je gornji limit snage iz mreže prekoračen (N). Pokazatelj korelacije K upotrijebljen je kao mjera sličnosti dviju krivulja i poprima vrijednost 1 za slučaj potpune korelacije i 0 kad korelacija među ulaznim signalima ne postoji (vidi prilog D).

Rezultati prikazani na slici 5-8 ukazuju na to da je utjecaj gornjeg limita snage mreže $P_{cmax,grid}$ na rezultate optimiranja zanemariv u slučaju kad $P_{cmax,grid}$ poprima vrijednosti veće od 30 kW, dok primjetan utjecaj postoji u slučaju kad je $P_{cmax,grid}$ manji ili jednak 20 kW. To se posebno ogleda u broju intervala N gdje se krši ograničenje na $P_{cmax,grid}$, koji se povećava kako se $P_{cmax,grid}$ smanjuje, a čiji se trend odražava u razmjerno smanjenoj korelaciji GLIM profila snage punjenja s NGLIM profilom. Pritom, smanjenjem limita $P_{cmax,grid}$, relativni porast troška punjenja flote C_{bat} nije značajan i iznosi 1-2%.



Slika 5-8: Ovisnost troška punjenja i pokazatelja kršenja ograničenja vezanih uz snagu koja se povlači iz mreže o maksimalnoj snazi koja se može povući iz mreže (koristi se dvotarifni model „Cijena 1“).

Potom je provedeno sukcesivno DP optimiranje punjenja pojedinačnih vozila za slučajeve kad je gornji limit $P_{cmax,grid}$ postavljen na iznose 10 kW i 20 kW za različite rasporede punjenja pojedinačnih vozila unutar flote. Ti rezultati su uspoređeni s rezultatima za slučaj kad ograničenje na snagu koja se može povući iz mreže ne postoji ($P_{cmax,grid} = \infty$). Za potrebe ove analize upotrijebljena su dva modela cijene električne energije („Cijena 1” i „Cijena 4” sa slike 4-3). Minimizirani troškovi punjenja vezani uz distribuirani model EV flote, prikazani na slici 5-9, ponovno pokazuju da trošak punjenja raste kako se gornji limit $P_{cmax,grid}$ smanjuje. Može se uočiti da su troškovi punjenja za različite rasporede punjenja gusto raspoređeni, što ukazuje na to da redoslijed punjenja ne utječe značajnije na rezultate optimiranja (vidi $C_{bat,std1,4}$ u tablici 5-1). Pune linije na slici 5-9 označavaju troškove punjenja flote za slučaj kad limit na snagu koja se može povući iz mreže ne postoji ($P_{cmax,grid} = \infty$) i predstavljaju minimalne moguće troškove punjenja te daju uvid koliko su troškovi punjenja u prisustvu ograničenja $P_{cmax,grid}$ udaljeni od minimalnih mogućih.



Slika 5-9: Optimalni troškovi punjenja za različite rasporede punjenja pojedinačnih EV unutar flote (crveni kružići i crveni križići označavaju minimalne/optimalne troškove punjenja; ravne linije označavaju troškove punjenja flote kad gornji limit na snagu iz mreže ne postoji).

Tablica 5-1: Minimalni i maksimalni troškovi punjenja flote EV i pripadne standardne devijacije (izražene u EUR) za 10 različitih rasporeda punjenja EV unutar flote i dva modela cijene električne energije („Cijena 1” i „Cijena 4” sa slike 4-3).

Metoda	$P_{cmax,grid} = 10 \text{ kW}$			$P_{cmax,grid} = 20 \text{ kW}$		
	$C_{bat,min1}$	$C_{bat,max1}$	$C_{bat,std1}$	$C_{bat,min1}$	$C_{bat,max1}$	$C_{bat,std1}$
DP-IND	1408.5	1415.4	2.34	1390.1	1397.9	2.33
	$C_{bat,min4}$	$C_{bat,max4}$	$C_{bat,std4}$	$C_{bat,min4}$	$C_{bat,max4}$	$C_{bat,std4}$
DP-IND	886.4	893.5	2.45	863.6	864.6	0.31

Tablica 5-2 prikazuje potencijal smanjenja troškova punjenja flote EV ukoliko bi se uklonila neka od ograničenja postavljena u sklopu optimiranja. Od 10 različitih rasporeda punjenja EV kod DP-IND metode, kod kojih je $P_{cmax,grid}$ postavljen u 20 kW, odabran je onaj rezultat kojim je postignut minimalni trošak punjenja flote EV (crveni kružići na slici 5-9) i taj rezultat je označen s DP-IND0. Potom se uklanja ograničenje na SoC pojedinačne baterije da bude 1 pri odspajanju EV s mreže (izraz (5-6)) i dobiveni rezultati optimiranja u tom slučaju označavaju se s DP-IND1. U ovom slučaju, zbog više fleksibilnosti kod optimiranja, trošak punjenja manji je oko 10% u slučaju modela “Cijena 1” i 4% u slučaju modela “Cijena 4” u odnosu na rezultate dobivene kad su sva ograničenja uključena. Izostavljanjem ograničenja na maksimalnu snagu koja se može povući iz mreže (5-8), smanjenje troška punjenja bitno je manje i iznosi oko 0.5% (DP-IND2 rezultati; vidi ilustraciju vezanu uz pune linije na slici 5-9). Prema rezultatima u tablici 5-2, u skladu s očekivanjem, veća razlika u trošku punjenja flote rezultira i manjom korelacijom agregatnih profila snage punjenja.

Tablica 5-2: Usporedba troškova punjenja distribuiranih modela flote EV za slučaj različitih ograničenja postavljenih u sklopu optimiranja.

Metoda	C_{bat1} [EUR]	K_1 [-]	C_{bat4} [EUR]	K_4 [-]
DP-IND0	1390.1 (0.0%)	1.00	863.6 (0.0%)	1.00
DP-IND1	1258.3 (-9.5%)	0.81	829.6 (-3.9%)	0.76
DP-IND2	1385.5 (-0.3%)	0.92	858.6 (-0.6%)	0.70

DP-IND0 – regularno DP-IND optimiranje uz $P_{cmax,grid} = 20$ kW


DP-IND1 – u ovom slučaju izostavljeno je ograničenje (5-6) vezano uz punu bateriju vozila na odlasku

DP-IND2 – u ovom slučaju izostavljen je gornji limit (5-8) na snagu iz mreže $P_{cmax,grid}$

$K_{1,4}$ – korelacija agregatnih profila snage punjenja s DP-IND0 profilom snage punjenja.

Slika 5-10 prikazuje kumulativno ograničenje na maksimalnu snagu punjenja iz mreže za različita DP optimiranja punjenja pojedinačnih EV unutar sukcesivne procedure optimiranja. Ovi rezultati ilustriraju kako se gornje ograničenje na snagu iz mreže smanjuje temeljem iterativnog procesa (5-14) krećući od optimiranja punjenja prvog EV, kad gornje ograničenje ima maksimalnu vrijednosti, prema optimiranju posljednjeg (10.) EV, kad ovo ograničenje pokatkad može biti i prekršeno ($P_{cum,lim} < 0$). Ovo se može dogoditi zato što je ograničenje (5-8) implementirano kao “meko” ograničenje koje može biti prekršeno kako bi se zadovoljila druga ograničenja koja imaju veći prioritet.

Tablica 5-3 kvantificira kršenje ograničenja (5-8) na maksimalnu snagu koja se može povući iz mreže za DP-IND0 i DP-IND2 pristupe iz tablice 5-2, te za pristupe kod kojih je optimiranje punjenja provedeno na temelju agregatnih modela baterije (DP-AGGR1 za osnovni model te DP-AGGR2 za napredni model) čiji su agregatni profili snage raspoređeni po pojedinačnim vozilima (DISTR1 za osnovni model te DISTR2 za napredni model). Pritom je kod svakog pristupa gornji limit na snagu koja se može povući iz mreže postavljen na iznos 20 kW. Broj diskretnih vremenskih koraka N (sati) u kojima je prekršeno ograničenje (5-8), srednja vrijednost snage punjenja $P_{c,cum,mean}$ u satima u kojima su se prekršenja dogodila i maksimalna snaga punjenja $P_{c,cum,max}$ uzeti su kao mjere kršenja ograničenja. Rezultati ukazuju da svi pristupi optimiranju i modeliranju, osim DP-AGGR1 (zbog manje ograničenja i veće fleksibilnosti), krše ograničenje (5-8). Međutim, ovo kršenje je znatno smanjeno (npr. N je oko 52% niži) kad je gornje ograničenje na snagu iz mreže (5-8) uključeno u DP-IND optimiranje (DP-IND0 slučaj). U tom slučaju DP-IND optimiranje je manje osjetljivo na kršenje ograničenja kad se uspoređi s preostale dvije metode DISTR1 i DISTR2 temeljene na distribuiranom modelu flote.



Slika 5-10: Odzivi kumulativnog gornjeg limita snage punjenja iz mreže za slučaj sukcesivnog DP optimiranja pojedinačnih vozila ($P_{cmax,grid} = 20 \text{ kW}$).

Tablica 5-3: Kvantifikacija kršenja ograničenja vezanog uz maksimalnu snagu mreže (postavljenu na iznos 20 kW) koja se može povući iz mreže i usporedba različitih pristupa modeliranju i optimiranju flote EV (koristi se model „Cijena 1“).

Metoda	N [-]	$P_{c,cum,mean}$ ($P_{c,cum} > P_{cmax,grid}$) [kW]	$P_{c,cum,max}$ [kW]
DP-IND2	186 (0.0%)	28.5 (0.0%)	58.6 (0.0%)
DP-IND0	89 (-52.2%)	25.6 (-10.2%)	46.8 (-20.1%)
DP-AGGR1	0 (-100.0%)	N/A	20.0 (-65.9%)
DISTR 1	156 (-16.1%)	25.0 (-12.3%)	49.9 (-14.9%)
DP-AGGR2	26 (-86.0%)	39.1 (+37.2%)	80.0 (+36.5%)
DISTR2	129 (-30.7%)	26.2 (-8.1%)	55.5 (-5.3%)

DP-IND0 – regularno DP-IND optimiranje uz $P_{cmax,grid} = 20$ kW

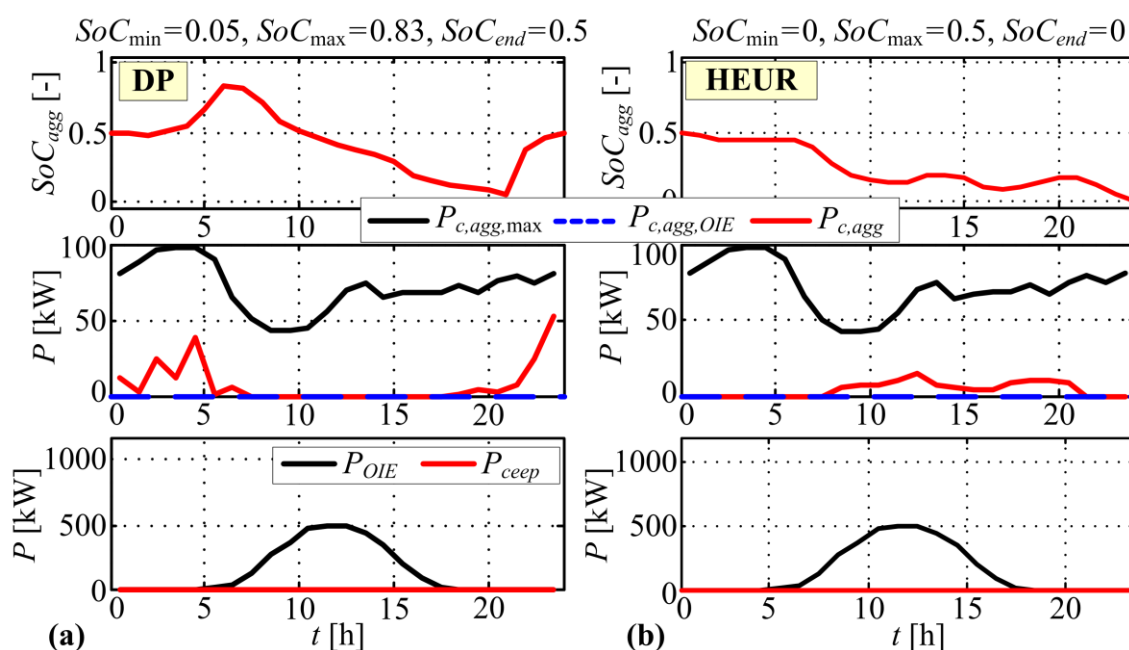
DP-IND2 – u ovom slučaju izostavljen je gornji limit (5-8) na snagu iz mreže

5.4.2. Usporedba rezultata heurističkog načina punjenja i DP optimalnog punjenja dobivenih korištenjem agregatnog modela flote

Za potrebe verifikacije i usporedbe, metode punjenja temeljene na DP algoritmu i heurističkom algoritmu (vidi odjeljak 5.3.1) implementirane su na PC računalu kako slijedi (zajedno s energetske i transportnim agregatnim modelima): (a) heuristički algoritam, izvorno korišten u EnergyPLAN softveru [89], implementiran je u Matlab programskom okruženju (vidi prilog G) i (b) računalno zahtjevan DP algoritam implementiran je u C programskom jeziku kako bi se povećala brzina izvođenja. Valja napomenuti da je za usporedbu ovih dvaju pristupa punjenju flote EV korišten osnovni agregatni model flote. Analizirana su dva scenarija proizvodnje iz OIE (vidi sliku 5-2): (a) bez viška proizvedene energije iz OIE ($A_{eff,PV} = 6600$ m²) i (b) uz višak proizvodnje energije iz OIE oko solarnog podneva ($A_{eff,PV} = 20100$ m²). Optimiranje punjenja provedeno je za oba scenarija, za različite modele cijena električne energije, te za razne vremenske baze ulaznih razdioba (tromjesečna, te usrednjena: tjedna i dnevna baza). Analize su potom proširene na širi raspon efektivnih instaliranih površina solarnih panela $A_{eff,PV}$.

Scenarij 1 – Nema viška proizvodnje energije iz OIE. Slika 5-11 prikazuje rezultate punjenja flote EV dobivene DP optimiranjem i heurističkom metodom punjenja na dnevnoj vremenskoj bazi za slučaj dvotarifnog modela cijene električne energije („Cijena 1“ sa slike 4-3). Budući

da nema viška proizvedene energije iz OIE, agregatna baterija se puni energijom uzetom iz mreže (tj. OIE snaga se ne koristi za punjenje EV, $P_{c,agg,OIE}=0$). DP optimiranje daje globalno optimalne rezultate, prema kojima bi se punjenje potpuno trebalo obaviti tijekom noćnih i ranojutarnjih sati kad je cijena električne energije niska (vidi model „Cijena 1“ na slici 4-3). S druge strane, heuristička metoda puni agregatnu bateriju (ponovno isključivo energijom iz mreže) kako bi se spriječilo kršenje donjeg SoC ograničenja (vidi izraz (4-3)) bez uzimanja u obzir cijene punjenja agregatne baterije. Iako ovo rezultira zadržavanjem SoC-a unutar željenog raspona od 0 do 1, ograničenje na održivost SoC-a ne može se smatrati zadovoljenim jer konačni SoC poprima vrijednost 0, dok je u slučaju DP metode konačni SoC jednak početnom poštujući tako ograničenje na održivost SoC-a.



Slika 5-11: Usporedni odzivi dani na 24-satnoj vremenskoj bazi dobiveni DP optimiranjem i heurističkom metodom punjenja za slučaj kad ne postoji višak proizvedene energije iz OIE (koristi se model cijene električne energije „Cijena 1“).

Tablica 5-4 usporedno prikazuje troškove energije iz mreže koja je korištena za punjenje flote EV za slučaj DP optimiranja i heurističke metode punjenja, te različitih horizonata optimiranja (dan, tjedan i puna tri mjeseca). Jedina razlika u odnosu na rezultate prikazane na slici 5-11 je ta što je konačna vrijednost SoC-a kod DP optimiranja postavljena u vrijednost na kojoj je završila heuristička metoda, kako bi se mogla provesti izravna usporedba troškova punjenja.

Pri tom je konačni SoC kod heurističkog punjenja u svakom slučaju jednak 0 što se može objasniti činjenicom da heuristički pristup nastoji minimizirati punjenje ako ne postoji proizvodnja iz OIE. Očito, DP optimiranje može ponuditi značajne uštede, tj. troškovi energije punjenja su od 10% do 45% niži kad se usporede s troškovima dobivenima heurističkom metodom punjenja. To je najviše izraženo za dvotarifni model cijene električne energije („Cijena 1“) i u nešto manjoj mjeri za slučaj „Cijena 2“ modela, što se može objasniti činjenicom da su ovi modeli cijena električne energije karakterizirani jeftinom energijom tijekom noći kad su vozila tipično dostupna za punjenja (vidi slike 3-5, 3-6 i 4-3).

Tablica 5-4: Usporedni troškovi punjenja uz primjenu osnovnog agregatnog modela baterije za slučaj DP optimiranja i heurističke metode punjenja i za slučaj kad ne postoji višak proizvedene energije iz OIE ($A_{eff,PV} = 6600 \text{ m}^2$) i 4 modela cijena električne energije (Slika 4-3).

DAN	$SoC_{agg} [-]$		Cijena 1	Cijena 2	Cijena 3	Cijena 4
	SoC_{init}	SoC_{end}	C_{bat}	C_{bat}	C_{bat}	C_{bat}
HEUR	0.5	0	10.3	3.1	4.2	5.3
DP	0.5	0	5.8	2.1	3.6	4.7
DP vs. HEUR	-	-	-43.7%	-32.3%	-14.3%	-11.3
TJEDAN	$SoC_{agg} [-]$		Cijena 1	Cijena 2	Cijena 3	Cijena 4
	SoC_{init}	SoC_{end}	C_{bat}	C_{bat}	C_{bat}	C_{bat}
HEUR	0.5	0	110.2	33.1	50.0	70.9
DP	0.5	0	69.5	23.9	44.1	56.5
DP vs. HEUR	-	-	-36.9%	-27.8%	-11.8%	-20.3%
3 MJESECA	$SoC_{agg} [-]$		Cijena 1	Cijena 2	Cijena 3	Cijena 4
	SoC_{init}	SoC_{end}	C_{bat}	C_{bat}	C_{bat}	C_{bat}
HEUR	0.5	0	1501.9	453.6	690.6	983.5
DP	0.5	0	987.1	324.0	611.2	780.9
DP vs. HEUR	-	-	-34.3%	-28.6%	-11.5%	-20.6%

Legenda: SoC_{init} – vrijednost SoC-a agregatne baterije u početnom trenutku, SoC_{end} – vrijednost SoC-a agregatne baterije u krajnjem trenutku, C_{bat} – trošak punjenja agregatne baterije dan u eurima.

U idealnom slučaju, ulazne razdiobe agregatnih modela bile bi potpuno ponovljive na dnevnoj bazi tijekom perioda od tjedan dana i trošak punjenja flote EV kroz tjedan dana $C_{bat, WEEK}$ bi tada približno bio sedam puta veći nego trošak punjenja za jedan dan $C_{bat, DAY}$. Međutim, usporedba podataka danih u tablici 5-5 pokazuje da je procijenjeni trošak punjenja tijekom tjedan dana 7 x

$C_{bat,DAY}$ oko 40% niži nego stvarni (optimirani) trošak $C_{bat,WEEK}$. Sličan zaključak također vrijedi i kod usporedbe procijenjenog troška punjenja $91 \times C_{bat,DAY}$ sa stvarnim troškom $C_{bat,FULL}$ za puni tromjesečni period. Ovo odstupanje značajno je manje (od 4% do 10%) kad se procjena troška punjenja za tromjesečni period računa iz stvarnih tjednih troškova punjenja ($13 \times C_{bat,WEEK}$ u odnosu na $C_{bat,FULL}$). Razlike procijenjenih i stvarnih troškova punjenja mogu se objasniti varijacijama u vremenskim razdiobama vezanima uz transport tijekom tjedna i punog perioda od tri mjeseca (vidi slike 3-5 i 3-6). Pritom su razlike bitno veće kad se trošak punjenja dobiven za jedan dan koristi kao osnova za procjenu troška punjenja za tjedni ili tromjesečni period, nego kada se rezultati optimiranja za tjedni period koriste za procjenu tromjesečnog troška. Ovo je zbog toga što razdiobe vezane uz transport dane na razini jednog dana ne mogu potpuno obuhvatiti sve karakteristike transporta kroz dulji vremenski period, prije svega zbog razlika u razdiobama za radne i vikend dane. Zaključno, optimiranje punjenja temeljeno na usrednjenim ulaznim razdiobama, posebno na dnevnoj vremenskoj bazi, može rezultirati značajno nižim procijenjenim troškovima punjenja. Drugim riječima, za dani vremenski period bi trebalo koristiti stvarne, a ne usrednjene razdiobe kako bi se dobili realistični rezultati optimiranja (primjerice za potrebe energetskog planiranja).

Tablica 5-5: Usporedba stvarnih tjednih troškova punjenja i stvarnih tromjesečnih troškova punjenja dobivenih DP optimiranjem s procijenjenim troškovima punjenja temeljenima na dnevnim i tjednim troškovima punjenja (postotne vrijednosti označavaju odnose troškova iz retka u odnosu na troškove iz stupca).


DP	Cijena 1	Cijena 2	Cijena 3	Cijena 4
	$C_{bat,WEEK}$	$C_{bat,WEEK}$	$C_{bat,WEEK}$	$C_{bat,WEEK}$
$7 \times C_{bat,DAY}$	-41.6%	-38.5%	-42.9%	-41.8%
DP	Cijena 1	Cijena 2	Cijena 3	Cijena 4
	$C_{bat,FULL}$	$C_{bat,FULL}$	$C_{bat,FULL}$	$C_{bat,FULL}$
$91 \times C_{bat,DAY}$	-46.5%	-41.0%	-46.4%	-45.2%
DP	Cijena 1	Cijena 2	Cijena 3	Cijena 4
	$C_{bat,FULL}$	$C_{bat,FULL}$	$C_{bat,FULL}$	$C_{bat,FULL}$
$13 \times C_{bat,WEEK}$	-8.5%	-4.1%	-6.2%	-5.9%

Legenda: $C_{bat,DAY}$ – trošak punjenja za jedan dan iz tablice 5-4, $C_{bat,WEEK}$ – trošak punjenja za jedan tjedan iz tablice 5-4, $C_{bat,FULL}$ – trošak punjenja za tri mjeseca iz tablice 5-4, $7 \times C_{bat,DAY}$ – procjena tjednog troška punjenja temeljenog na trošku punjenja za jedan dan, $91 \times C_{bat,DAY}$ – procjena tromjesečnog troška punjenja temeljenog na trošku punjenja za jedan dan, $13 \times C_{bat,WEEK}$ – procjena tromjesečnog troška punjenja temeljenog na trošku punjenja za tjedan dana.

Scenarij 2 – Postoji višak proizvedene energije iz OIE. Rezultati prikazani na slici 5-12 za slučaj kad postoji višak proizvedene energije iz OIE (Slika 5-2b) i za slučaj dvotarifne cijene električne energije pokazuju da heuristička metoda punjenja teži punjenju agregatne baterije s maksimalnom snagom kad postoji višak energije iz OIE, pritom zadovoljavajući SoC ograničenja. DP optimiranje daje slične rezultate, s glavnom razlikom da se u slučaju DP optimiranja nije uspio povući maksimalan iznos energije iz OIE (kao kod HEUR), te se stoga dio energije povlači iz mreže kako bi se postigao zadan konačni iznos SoC-a.

Tablica 5-6 prikazuje usporedne podatke za dva pristupa punjenju flote EV, gdje je naglasak na udjelu energije punjenja iz OIE u ukupnoj energiji punjenja. Kao što je objašnjeno kod tablice 5-4, konačna vrijednost SoC-a kod DP optimiranja postavljena je da bude jednaka onoj vrijednosti koja je dobivena korištenjem heurističke metode. U slučaju optimiranja punjenja za jedan dan (rezultati prikazani na slici 5-12), heuristička metoda koristi 98% energije punjenja iz OIE. S druge strane, DP optimiranje rezultira znatno manjim udjelom energije iz OIE (83%) i većim troškom punjenja jer DP povlači više energije iz mreže. Ovo je u suprotnosti s činjenicom da DP metoda daje globalni optimum, tj. minimalni trošak punjenja. Odstupanje od globalnog optimuma može se objasniti utjecajem diskretizacije varijable stanja i upravljačke varijable kod DP optimiranja. Doista, kad se rezolucija ovih varijabli poveća na $N_{soc} = 1000$ i $N_{control} = 100000$ (s početnih vrijednosti $N_{soc} = 100$ i $N_{control} = 1000$), DP optimiranje (označeno kao DP2 u tablici 5-6) daje bolje rezultate od heurističke metode (udio energije iz OIE sad je povećan na 98% i trošak punjenja pada ispod vrijednosti dobivene heurističkom metodom punjenja).

Rezultati DP optimiranja su bolji kad se usporede s rezultatima heurističke metode u smislu većeg udjela energije punjenja iz OIE i manjeg troška punjenja (bez obzira na rezoluciju varijable stanja i upravljačke varijable) u slučaju vremenskog horizonta od tri mjeseca. Ovo se može objasniti činjenicom da DP optimiranje bolje planira punjenje na duljim vremenskim horizontima tj. kada postoji više slobode u optimiranju. Druga prednost DP metode je da može garantirati održivost SoC-a (ako se krajnji iznos SoC-a postavi da bude jednak početnom, kao na slici 5-12), dok rezultati dobiveni heurističkom metodom u tablici 5-6 ukazuju da postoji tendencija potpunog ispražnjenja baterije na dugim vremenskim horizontima.




Slika 5-12: Usporedni odzivi dani na 24-satnoj vremenskoj bazi dobiveni DP optimiranjem (a) i heurističkom metodom punjenja (b) za slučaj kad postoji višak proizvedene energije iz OIE (koristi se model cijene električne energije „Cijena 1“).

Tablica 5-6: Usporedni rezultati vezani uz udio energije punjenja iz OIE u ukupnoj energiji punjenja agregatne baterije i troškove punjenja agregatne baterije za slučaj kad postoji višak proizvedene energije iz OIE (koristi se model cijene električne energije „Cijena 1“ i $A_{eff,PV} = 20100 \text{ m}^2$).

DAN	$SoC_{agg} [-]$		Energija [kWh]			Trošak
	SoC_{init}	SoC_{end}	$E_{ch,OIE}$	$E_{ch,total}$	$E_{ch,OIE}/E_{ch,total}$	C_{bat}
HEUR	0.5	0.5	180.2	184.8	0.98	0.5 (0.0%)
DP	0.5	0.5	152.9	184.3	0.83	2.0 (+300.0%)
DP2	0.5	0.5	181.3	184.3	0.98	0.2 (-60.0%)
TJEDAN	$SoC_{agg} [-]$		Energija [kWh]			Trošak
	SoC_{init}	SoC_{end}	$E_{ch,OIE}$	$E_{ch,total}$	$E_{ch,OIE}/E_{ch,total}$	C_{bat}
HEUR	0.5	0.76	775.7	1334.8	0.58	45.2 (0.0%)
DP	0.5	0.76	728.0	1335.0	0.55	33.7 (-25.4%)
3 MJESECA	$SoC_{agg} [-]$		Energija [kWh]			Trošak
	SoC_{init}	SoC_{end}	$E_{ch,OIE}$	$E_{ch,total}$	$E_{ch,OIE}/E_{ch,total}$	C_{bat}
HEUR	0.5	0	8072.2	16679.8	0.48	732.9 (0.0%)
DP	0.5	0	8534.7	16679.9	0.51	463.2 (-36.8%)

Legenda: SoC_{init} – početna vrijednost SoC-a agregatne baterije, SoC_{end} – krajnja vrijednost SoC-a agregatne baterije, $E_{ch,OIE}$ – energija iz OIE korištena za punjenje agregatne baterije, $E_{ch,total}$ – ukupna energija korištena za punjenje agregatne baterije, $E_{ch,OIE}/E_{ch,total}$ – udio energije punjenja iz OIE u ukupnoj energiji punjenja, C_{bat} – trošak energije iz mreže korišten za punjenje agregatne baterije, DP2 – rezultati optimiranja u slučaju kad se koristi veća rezolucija varijable stanja $N_{soc} = 1000$ te upravljačke varijable $N_{control} = 100000$ (inače se koriste $N_{soc} = 100$ i $N_{control} = 1000$).

Usporedni rezultati za različite razine proizvodnje energije iz OIE. Analize iz prethodnog dijela ovog odjeljka proširuju se za slučaj širokog raspona instalirane efektivne površine solarnih panela $A_{eff,PV}$. U ovom slučaju su optimiranja provedena za dvotarifnu cijenu električne energije (model „Cijena 1“) i puni tromjesečni vremenski period. Pripadni rezultati optimiranja prikazani su na slici 5-13. Udio energije iz OIE raste od 25% za $A_{eff,PV} = 13200 \text{ m}^2$ do 85% za $A_{eff,PV} = 51300 \text{ m}^2$ (Slika 5-13d). Pritom, DP optimiranje rezultira u 3-8% većem iskorištenju energije iz OIE nego heuristička metoda punjenja iako je potonja projektirana isključivo za maksimizaciju iskorištenja OIE. Također, troškovi punjenja manji su u slučaju DP optimiranja u odnosu na slučaj heurističke metode, gdje se pripadne uštede kreću između 35% i 49% za dani raspon instalirane površine solarnih panela (slike 5-13a i 5-13b). Na slici 5-13 dodatno su dani i krajnji iznosi SoC-a za različite vrijednosti $A_{eff,PV}$ (Slika 5-13c). Može se vidjeti da je konačni iznos SoC-a u slučaju DP optimiranja namješten da bude jednak konačnom SoC-u dobivenom heurističkom metodom punjenja kako bi se troškovi punjenja i ostale veličine dviju metoda mogle izravno usporediti.



Slika 5-13: Usporedni rezultati dobiveni DP optimiranjem i heurističkom metodom za različite površine instaliranih solarnih panela $A_{eff,PV}$.

Neki aspekti primjene predložene DP metode optimiranja punjenja flote EV. Predložena metoda DP optimiranja može se koristiti za različite primjene. Jedna od mogućnosti je korištenje ove metode kod hijerarhijskog vođenja punjenja flote vozila, gdje se profil snage prvo određuje na agregatnoj razini, te se potom raspoređuje na pojedinačna vozila (vidi odjeljak 4.3.2). Osim toga, ova metoda optimiranja može se koristiti u različitim studijama energetskog planiranja koje u obzir uzimaju flote EV. Posebno se može koristiti kao temelj za tehno-ekonomske analize vezane uz elektrifikaciju postojećih flota konvencionalnih vozila. Za ove analize, optimiranja se često provode na vrlo dugim vremenskim periodima (npr. nekoliko mjeseci ili godina), zato što zahtjev transporta i proizvodnja iz OIE mogu značajno varirati tijekom godine. S druge strane, hijerarhijsko punjenje flote EV bi se tipično provodilo za jedan dan te bi se temeljilo na unaprijed poznatim rasporedima i rutama vozila i predikciji proizvodnje iz OIE. Optimirana agregatna snaga punjenja može biti točno raspodijeljena na pojedinačna EV korištenjem jednostavnog i približno optimalnog heurističkog algoritma (vidi odjeljak 4.3.2), koji u obzir uzima ograničenja vezana uz pojedinačna EV, kao i pogreške predviđanja vezana uz proizvodnju iz OIE i trošak električne energije.


5.4.3. Rezultati optimiranja dobiveni korištenjem dvorazinskog optimiranja

Za svrhu početnih analiza, predloženo dvorazinsko optimiranje iskorišteno je prvo za minimiziranje sljedećih konfliktnih ciljnih funkcija (u vanjskoj optimizacijskoj petlji): (a) C_{bat} , (b) C_{fuel} i (c) $P_{c,viol,total}$, pritom zadržavajući limit snage punjenja pojedinačnih vozila $P_{cmax,ind}$ konstantnim i jednakim 10 kW. U ovom su slučaju samo konačni SoC inkrementi $\Delta SoC_{out,ind,i,j}$ optimirani u nadređenoj petlji (bez $P_{cmax,ind}$). Broj rješenja NSGA-II algoritma unutar jedne populacije rješenja postavljen je na vrijednost 60, faktor križanja (omjer broja rješenja dobivenih križanjem i ukupnog broja rješenja koja se zadržavaju unutar populacije) postavljen je na iznos 0.8 i faktor mutacije postavljen je u 0.3 (omjer broja rješenja dobivenih mutiranjem i ukupnog broja rješenja koja se zadržavaju unutar populacije; vidi [90] za detalje vezane uz NSGA-II algoritam). Početne vrijednosti konačnih SoC inkremenata $\Delta SoC_{out,ind,i,j}$ postavljene su u konstantne i jednake vrijednosti za svaki vozni ciklus i ($\Delta SoC_{out,ind,i,j} = konst.$ za svaki i, j) u sklopu jednog rješenja NSGA-II algoritma. Potom, početne vrijednosti za 60 rješenja NSGA-II algoritma odabrane su iz ekvidistantno raspodijeljenog intervala $[0, 0.8]$, gdje svako rješenje $\Delta SoC_{out,ind,i,j}$ (za svaki i, j) poprima jednu vrijednost iz tog skupa početnih

rješenja.

Rezultati optimiranja prikazani na slici 5-14a ukazuju na to da samo dio rješenja optimiranja (crveni kružići) zadovoljava ograničenje na maksimalnu snagu punjenja za konkretan slučaj kad je to ograničenje postavljeno na relativno nizak iznos od 10 kW. Pritom je ovdje korištena tolerancija od 0.4% na $P_{c,viol,total}$, zato što minorna kršenja ograničenja koja se nalaze ispod ovog praga mogu biti uzrokovana diskretizacijom varijable stanja i upravljačke varijable unutar DP algoritma optimiranja, kao i preračunavanjem (korištenjem usrednjavanja) ulaznih vremenskih razdioba agregatnog modela baterije sa sekundne na satnu vremensku bazu. Kršenja ograničenja na snagu punjenja koja prekorače gore postavljen prag (plavi kružići na slici 5-14a), mogu se objasniti time da maksimalna dostupna snaga nije dovoljna da pokrije zahtjeve transporta u slučaju kad se naglasak stavlja na minimiziranje potrošnje goriva (tj. na maksimiziranje korištenja energije iz baterije odnosno iz mreže; vidi sliku 5-14b).

Slika 5-14b nadalje pokazuje da se ukupni operativni troškovi $C_{total} = C_{bat} + C_{fuel}$ mogu smanjiti za 15% u odnosu na slučaj kad se energija iz baterije odnosno iz mreže ne koristi za vožnju ($C_{bat} = 0$: referentni scenarij), a da se pritom ne krši ograničenje na snagu punjenja. Konačno, prikazani rezultati ukazuju da jednorazinsko optimiranje, kod kojeg su SoC vrijednosti vozila koja napuštaju distributivni centar postavljena u 1 (crni kružići na slici 5-14), rezultira u značajnom kršenju ograničenja na maksimalnu snagu punjenja ($P_{c,viol,total} = 7.9\%$, Slika 5-14a).



Slika 5-14: Kvantifikacija kršenja ograničenja vezanog uz agregatnu snagu punjenja u odnosu na normirani trošak potrošenog goriva (a) i normirani ukupni operativni troškovi (ukupni trošak električne energije za punjenje i goriva) u odnosu na normirani trošak punjenja agregatne baterije (b) ($P_{c,max,ind} = 10$ kW).

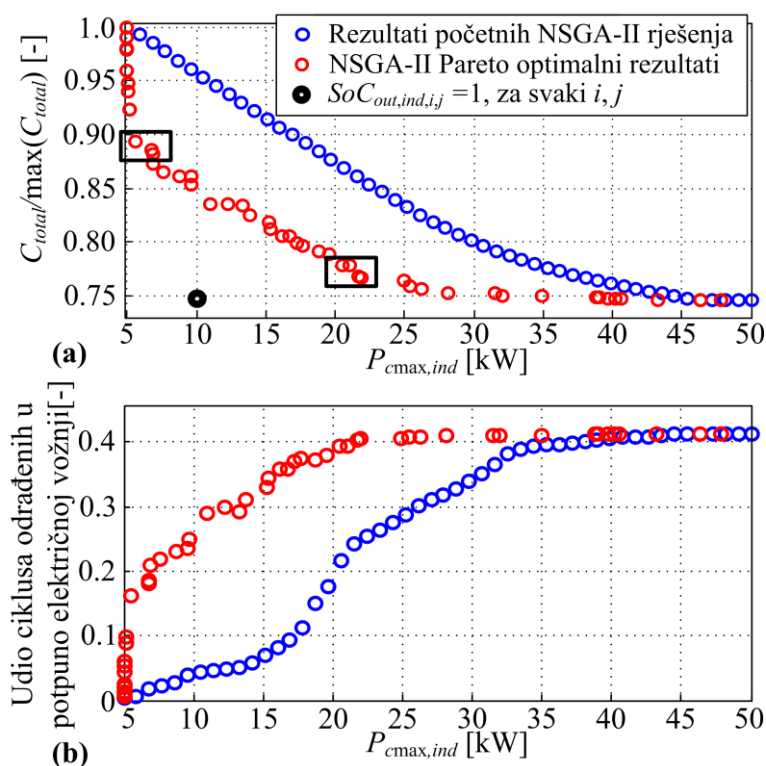
U isto vrijeme, jednorazinskim optimiranjem predviđa se nerealistično smanjenje operativnih troškova (oko 26%) u odnosu na referentni scenarij gdje se samo energija iz goriva koristi za vožnju (za slučaj $P_{cmax,ind} = 10$ kW).

Konačno, NSGA-II algoritam je prema originalnom konceptu opisanom u odjeljku 5.3.3 upotrijebljen za minimiziranje ciljne funkcije definirane s (5-28), s ciljem pronalaženja minimalnog limita na snagu punjenja $P_{cmax,ind}$ i minimalnog iznosa operativnih troškova. U ovom slučaju broj rješenja unutar populacije NSGA-II algoritma postavljen je na 50 (faktor križanja ponovno je postavljen u 0.8 i faktor mutacije postavljen je u 0.3). Početna rješenja $\Delta SoC_{out,ind,i,j}$ postavljaju se na sličan način kao i u prethodnim slučajevima, tj. odabrani su iz raspona [0.05, 0.8] s bitnom razlikom što je sad slučajan šum, generiran iz jednolike razdiobe $U(-0.01, 0.01)$, dodan na početna rješenja ($\Delta SoC_{out,ind,i,j} + \varepsilon_{i,j}$). Početne vrijednosti za $P_{cmax,ind}$ unutar 50 početnih rješenja NSGA-II algoritma ekvidistantno su distribuirana u rasponu [5000, 50000]. Valja naglasiti da se Pareto fronta optimalnih rješenja kod NSGA-II algoritma optimiranja automatski generira kroz jednu optimizaciju.

Rezultati prikazani na slici 5-15a ukazuju da korištenje nadređene razine optimiranja (NSGA-II) smanjuje ukupne operativne troškove C_{total} za oko 10% (za $6\text{kW} \leq P_{cmax,ind} \leq 20\text{kW}$) kad se uspoređi s rezultatima dobivenima korištenjem samo DP optimiranja temeljenog na početnim rješenjima za $P_{cmax,ind}$ i $\Delta SoC_{out,ind,i,j}$. NSGA-II rješenja optimiranja formiraju Pareto optimalnu frontu, koja bi u ovom konkretnom slučaju značila da se ukupni operativni troškovi ne mogu više smanjiti za dane vrijednosti $P_{cmax,ind}$. Temeljem ove Pareto fronte, može se zaključiti da su dobri kandidati za maksimalnu snagu punjača $P_{cmax,ind}$ oni označeni crnim pravokutnicima na slici 5-15a. Oni se smatraju dobrim kandidatima jer se primjerice u slučaju prvog pravokutnika ($P_{cmax,ind} \approx 5.6$ kW), neznatnim povećanjem $P_{cmax,ind}$ (krećući od minimalne vrijednosti) značajno smanjuju ukupni troškovi ($\approx 11\%$), dok se u slučaju drugog pravokutnika ($P_{cmax,ind} \approx 22$ kW) gotovo puni potencijal smanjenja ukupnih operativnih troškova ($\approx 23\%$ u odnosu na $\approx 25\%$) dobiva za relativno nisku maksimalnu snagu punjača (≈ 22 kW u odnosu na ≈ 40 kW). Tako, praktična vrijednost rezultata dvorazinskog optimiranja prikazanih na slici 5-15 je ta da mogu poslužiti kao polazna točka za određivanje optimalno dimenzioniranih i ekonomski najisplativijih punjača baterija za konkretnu flotu vozila. U svrhu usporedbe, neostvarivo smanjenje ukupnih operativnih troškova dobiveno jednorazinskim DP

optimiranjem ($SoC_{out,ind,i,j} = 1$ i $P_{cmax,ind} = 10kW$; crni kružići na slici 5-14) također je prikazano na slici 5-15a (crni kružić).

Slika 5-15b prikazuje udio voznih ciklusa koji su odrađeni u potpuno električnom režimu rada (CD) u ovisnosti o snazi punjača $P_{cmax,ind}$. Udio potpuno električnih voznih ciklusa postupno raste s rastom snage punjača i dostiže maksimum ($\approx 41\%$) za vrijednosti $P_{cmax,ind}$ jednake ili veće od 22 kW. Na slici 5-15b se također vidi da početna rješenja NSGA-II optimiranja (plavi kružići) značajno podcjenjuju udio potpuno električnih vožnji kad se usporede s Pareto optimalnim rezultatima (crveni kružići) za dane iznose snage punjača $P_{cmax,ind}$. Ovaj rezultat ima drugi praktični značaj budući da može poslužiti kao indikator za određivanje optimalnog udjela potpuno električnih vozila i električnih vozila s proširenim dometom unutar razmatrane flote za danu snagu punjača. U tom slučaju se pretpostavlja da bi potpuno električna vozila odrađivala samo električne vozne cikluse, dok bi EREV-i odrađivali duge vozne cikluse gdje bi se hibridni režim rada uključivao radi održanja SoC-a baterije.



Slika 5-15: Normirani ukupni operativni troškovi (C_{total}) (a) i udio voznih ciklusa odrađenih u potpuno električnoj vožnji (b) u ovisnosti o gornjem limitu snage punjenja pojedinačnog EV ($P_{cmax,ind}$).

6. Analiza tehno-ekonomskih aspekata elektrifikacije flote dostavnih vozila

U ovom poglavlju prikazana je pilot studija vezana uz elektrifikaciju flote dostavnih vozila predstavljene u poglavlju 3, u kombinaciji s hipotetskom proizvodnjom električne energije iz solarnih panela čija je instalacija predviđena na krovu distributivnog centra. Pritom se za modeliranje flote električnih dostavnih vozila koristi napredni model agregatne baterije predložen u poglavlju 4, dok se za optimiranje punjenja koristi DP algoritam predložen u poglavlju 5. Za potrebe parametriranja modela agregatne baterije razvijen je kvazistatički model električnog dostavnog kamiona proširenog dometa sličnih karakteristika (snaga, moment) kao i konvencionalni kamion na kojem su snimani vozni ciklusi (poglavlje 3), a čiji je kvazistatički model također razvijen za potrebe usporednih analiza.

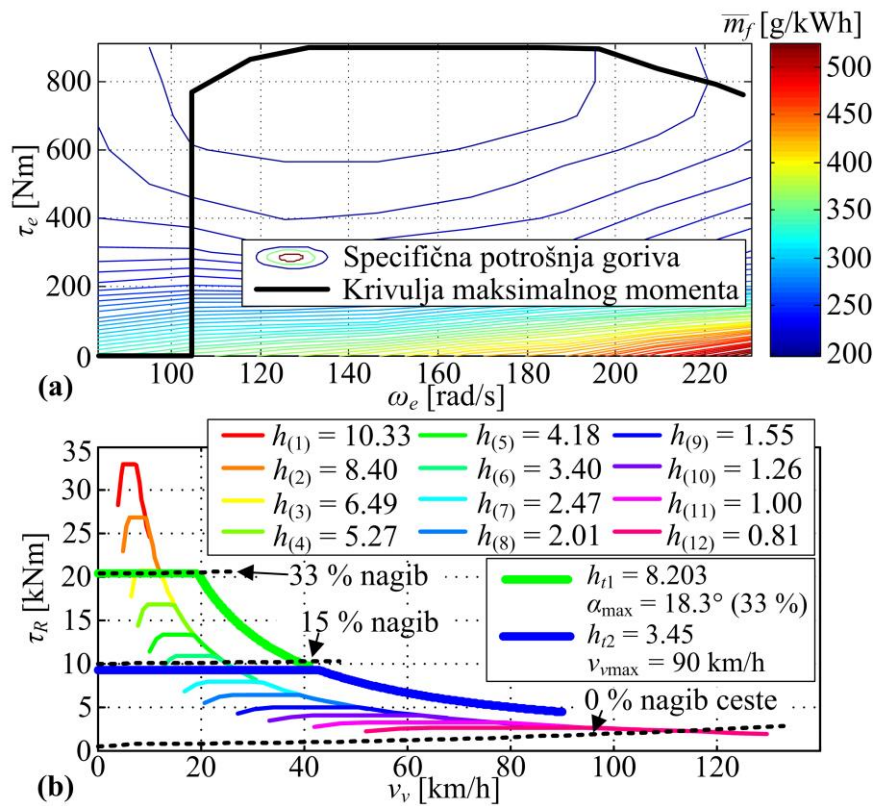
6.1. Konvencionalno dostavno vozilo

6.1.1. Model konvencionalnog dostavnog vozila

Razmatrano dostavno vozilo na kojem su snimani podaci opisani u poglavlju 3 je MAN – TGM 15.240 (vidi sliku 6-1) nosivosti 7460 kg i mase 7860 kg (prazno vozilo). Brzina vozila limitirana je na 90 km/h. Vozilo je pogonjeno Diesellovim motorom maksimalne snage od 176 kW. Motor se opisuje mapom specifične potrošnje goriva (g/kWh) i krivuljom maksimalnog momenta prikazanim na slici 6-2a. Krivulja maksimalnog momenta preuzeta je iz kataloga [91] i mapa specifične potrošnje goriva preuzeta je od sličnog Diesel motora iz [92]. Korištenjem kataloških podataka za 12-brzinsku automatiziranu manualnu transmisiju i uključujući vrijednosti stupnjeva prijenosa h_i , $i = 1, 2, \dots, 12$, može se rekonstruirati maksimalni izlazni okretni moment na kotaču u ovisnosti o brzini vozila (Slika 6-2b).



Slika 6-1: Dostavni kamion MAN TGM 15.240.



Slika 6-2: Mapa specifične potrošnje goriva SUI motora i krivulja maksimalnog momenta (a), te odgovarajući maksimalni izlazni moment na kotaču u ovisnosti o brzini vozila za različite stupnjeve prijenosa h_i , $i = 1, 2, \dots, 12$ (dana i karakteristika izlaznog momenta za EREV pogon)

(b).

Model uzdužne longitudinalne dinamike vozila izvodi se korištenjem poznatih ili procijenjenih vrijednosti osnovnih parametara kamiona kao što su: masa vozila (m_v), efektivni radijus gume (r), koeficijent aerodinamičkog otpora zraka (C_d), koeficijent otpora kotrljanja (R_o) i korisnost pogona (η_t) (Tablica 6-1). Pritom se izlazni okretni moment pogona τ_R i okretna brzina ω_L računaju korištenjem izraza (2-7) i (2-8) [80].

Tablica 6-1: Parametri transmisije [80, 91, 93].

A_f [m ²]	C_d [-]	R_o [-]	η_t [-]	i_o [-]
9.63	0.63	0.012	0.96	3.7

Brzina vrtnje SUI motora ω_e i okretni moment τ_e povezani su redom sa snimljenim (GPS) podatkom o brzini vozila v_v i modeliranim momentom otpora τ_R preko prijenosnog omjera diferencijala i_o i prijenosnog omjera odabranog stupnja transmisije h :


$$\omega_e = i_o h \omega_L = i_o h \frac{v_v}{r}, \quad (6-1)$$

$$\tau_e = \frac{\tau_R}{\eta_t i_o h} = \frac{r}{\eta_t i_o h} \left(m_v \dot{v}_v + m_v g \sin \alpha + R_o m_v g \cos \alpha + 0.5 \rho_{air} C_d A_f v_v^2 \right). \quad (6-2)$$

Budući da vremenski profili prijenosnih omjera transmisije h nisu snimani, provedena je njihova rekonstrukcija korištenjem snimljenih vrijednosti brzine vozila v_v , brzine vrtnje SUI motora ω_e , te jednadžbe (6-1). Rekonstruirane vrijednosti prijenosnih omjera, prikazane na slici 6-3a, formiraju razdiobe slične normalnim razdiobama. Srednje vrijednosti ovih razdioba poravnate su s nominalnim diskretnim vrijednostima prijenosnih omjera transmisije korigiranjem vrijednosti radijusa gume r . Prema katalogu, radijus opterećene gume je 0.413 m [93], dok korigirani (efektivni) radijus iznosi 0.388 m. Činjenica da se rekonstruirani prijenosni omjeri transmisije ponešto rasipaju oko nominalnih (diskretnih) vrijednosti (danih na slici 6-2b) može biti objašnjena: utjecajem klizanja spojki tijekom promjena prijenosnog omjera, promjenjivim radijusom gume uzrokovanim promjenjivim opterećenjem gume kod zaleta i kočenja vozila, promjenjivim tlakom u gumi, te kašnjenjem GPS mjernih signala brzine vozila.

Na slici 6-3b dan je primjer rekonstruiranog vremenskog profila mase vozila m_v za slučaj

jednog snimljenog voznog ciklusa, a koja uključuje masu praznog vozila i masu tereta. Vremenski profil mase tereta rekonstruiran je iz podataka o masi tereta te odredištu na koji se taj teret prevozi, a koji su zabilježeni za veliku većinu snimljenih voznih ciklusa. Masa vozila se smanjuje u trenutku kada se iz snimljenih geografskih koordinata vozila detektira da je vozilo došlo na odredište i to za vrijednost mase tereta koji je bio namijenjen za dostavu na to odredište. Za one vozne cikluse za koje nisu bili dostupni podaci, uzima se konstantni iznos mase tereta od 2206.1 kg, a koji odgovara prosječnoj masi tereta tijekom svih voznih ciklusa.



Slika 6-3: Razdioba prijenosnih omjera automatske transmisije rekonstruiranih iz snimljenih podataka i nominalnih diskretnih vrijednosti prijenosnih omjera (y os je skraćena radi bolje vidljivosti cjelokupnog grafa) (a), te primjer rekonstruiranog vremenskog profila mase vozila m_v tijekom jednog voznog ciklusa (b).

U modelu vozila koji se simulira preko snimljenih voznih ciklusa, prijenosni omjer transmisije h (kao varijabla modela) dobiven je zaokruživanjem varijable $\omega_e/(i_o \cdot v/r)$ na najbližu vrijednost nominalnog prijenosnog omjera transmisije. Protok goriva SUI motora (izražen u g/s) dobiva se korištenjem jednadžbe (2-1) na temelju okretnog momenta i brzine

vrtnje SUI motora (dobivenih pomoću jednadžbi (6-1) i (6-2)) te mape specifične potrošnje goriva prikazane na slici 6-2a (u g/kWh). Kumulativna potrošnja goriva (u litrama) tada se računa kako slijedi:

$$V_f = \frac{1}{850} \int_0^{t_f} \dot{m}_f dt, \quad (6-3)$$

gdje skalirajući faktor predstavlja gustoću Diesel goriva izraženu u g/l.

6.1.2. Validacija modela konvencionalnog dostavnog vozila

U svrhu validacije postavljenog modela provedene su simulacije modela preko svih snimljenih voznih ciklusa. Poznata (zabilježena) informacija o varijabilnoj masi tereta također je uključena u simulacije kako bi se dobile točnije procjene potrošnje goriva. Validacija razvijenog modela temelji se na usporedbi procijenjene potrošnje goriva (dobivene na temelju simulacija) i stvarne potrošnje (snimljene preko CAN sabirnice). Tablica 6-2 prikazuje rezultate validacije modela za 10 odabranih voznih ciklusa (po dva iz svakog klastera snimljenih voznih ciklusa prikazanih na slici 3-9). Slika 6-4 prikazuje razdiobu odstupanja


Tablica 6-2: Snimljena kumulativna potrošnja goriva dana usporedno s potrošnjom goriva procijenjenom na temelju simulacije razvijenog modela vozila za deset snimljenih voznih ciklusa (po dva iz svakog klastera ciklusa prikazanih na slici 3-9).

Klaster	s_{dc}^1 [km]	$V_{f,real}$ [l]	$V_{f,sim}$ [l]	ΔV_f^2 [%]
1	20.85	4.5	3.8	-15.8%
	22.47	5.5	4.7	-14.3%
2	53.11	11.0	10.6	-3.9%
	60.53	14.0	14.0	0.0%
3	129.44	29.5	29.3	-0.6%
	147.47	30.5	30.5	0.0%
4	192.67	41.0	43.0	+5.4%
	214.73	42	41.9	-0.4%
5	340.09	82.5	81.4	-1.4%
	419.59	86.0	95.0	+10.5%

¹ s_{dc} - prijedena udaljenost tijekom voznog ciklusa

² ΔV_f - odstupanje između procijenjene potrošnje goriva $V_{f,sim}$ i snimljene potrošnje $V_{f,real}$

procijenjene potrošnje goriva od snimljene potrošnje, $\varepsilon = 100 \cdot (V_{f, sim} - V_{f, real}) / V_{f, real}$ za sve snimljene vozne cikluse osim onih čija je potrošnja manja od 10 litara. Ovi vozni ciklusi su isključeni iz analize kako ne bi pogoršali kvalitetu validacije uslijed ograničene rezolucije snimljene potrošnje goriva od 0.5 litara, a koja posebno dolazi do izražaja za kraće cikluse s manjom potrošnjom goriva (vidi klaster gradskih ciklusa u tablici 6-2). Rezultati na slici 6-4 ukazuju da je procijenjena potrošnja goriva dobivena simulacijama unutar 10% odstupanja od stvarne potrošnje goriva za većinu vozničkih ciklusa što potvrđuje dobru točnost razvijenog modela vozila. Pogreške modeliranja prvenstveno nastaju zbog nedostupnosti precizne mape potrošnje goriva SUI motora, te neraspodivnosti podataka o opterećenju SUI motora zbog tereta koje proizvode pomoćni strojevi (što posebno dolazi do izražaja u praznom hodu).




Slika 6-4: Razdioba relativnih odstupanja simulacijom procijenjene potrošnje goriva u odnosu na snimljenu kumulativnu potrošnju goriva za sve snimljene vozne cikluse (osim onih kod kojih je potrošnja bila manja od 10 litara).

6.2. Dostavno električno vozilo proširenog dometa

U poglavljima 4 i 5, za potrebe demonstracije i validacije modela flote EV, određivanje zahtjeva transporta za energijom temeljilo se na simulacijama modela putničkog električnog vozila s proširenim dometom. Međutim, kako bi rezultati pilot studije bili čim realističniji, za parametriranje modela flote EV, ovdje se koristi model električnog vozila proširenog dometa sličnih karakteristika kao i konvencionalno dostavno vozilo na kojem su snimani podaci (parametri vezani uz model vozila i upravljačku strategiju pogona dani su u prilogu A).

6.2.1. Modeliranje i dimenzioniranje pogona

Model konvencionalnog dostavnog vozila danog u prošlom potpoglavlju konvertiran je u model potpuno električnog vozila s usporedivim karakteristikama snage i momenta [67]. Međutim, kako bi se zadovoljio domet za sve snimljene vozne cikluse, pogon EV je ovdje proširen SUI motorom i električnim strojem (generatorom), čime se dobiva električno vozilo proširenog dometa (EREV) u serijskoj konfiguraciji. Blokovski dijagram kvazistatičkog modela EREV-a (uključujući i upravljački dio) prikazan je na slici 6-5a. Kako bi se zadovoljili pogonski zahtjevi na transmisiju, odabran je pogonski elektromotor nominalne



Slika 6-5: Blokovski dijagram kvazistatičkog modela EREV tipa kamiona (a), mapa korisnosti i krivulja maksimalnog momenta pogonskog elektromotora (b), te mapa specifične potrošnje goriva i krivulja maksimalnog momenta SUI motora (c).

snage 128 kW i vršne snage 280 kW [94]. Pogonski elektromotor opisan je krivuljom maksimalnog momenta, te mapom korisnosti prikazanima na slici 6-5b za prvi kvadrant ($\omega_m > 0, \tau_m > 0$) [94]. Ista mapa se primjenjuje i za ostale kvadrante. Generator je opisan krivuljom maksimalnog momenta i mapom korisnosti koje su dobivene skaliranjem krivulje i mape pogonskog elektromotora prikazanih na slici 6-5b korištenjem Willansovog pravila aproksimacije [74]. Pritom je korišten faktor skaliranja 0.5, što bi značilo da je vršna snaga generatora 140 kW. SUI motor je opisan krivuljom maksimalnog momenta i mapom specifične potrošnje goriva prikazanih na slici 6-5c (protok goriva se iz specifične potrošnje goriva dobiva primjenom izraza (2-1)). Originalna krivulja i mapa preuzete su iz *Autonomie* programskog paketa, te su opisane Willans pravilom aproksimacije i preskalirane faktorom 1.3 (uzet je ovaj faktor skaliranja kako bi se postigla tražena maksimalna snaga SUI motora; više o traženoj snazi SUI motora dano je u nastavku).

Brzina vrtnje ω_m i okretni moment τ_m pogonskog elektromotora određuju se kako slijedi (usporedi izraze (6-1) i (6-2)):

$$\omega_m = i_o h \omega_L = i_o h \frac{v_v}{r}, \quad (6-4)$$

$$\tau_m = \frac{\tau_R}{\eta_t i_o h}, \quad (6-5)$$

Generator i SUI motor povezani su mehanički preko mehaničkog prijenosnika koji prilagođava pripadne radne raspone brzina, a čiji je prijenosni omjer $1/h_G$ ($h_G = 1.8217$). Pritom su brzine vrtnje i momenti povezani kako slijedi: $\tau_g = -1/h_G \cdot \tau_e$, $\omega_g = h_G \cdot \omega_e$ (vidi sliku 6-5a). Negativan predznak momenta generatora τ_g ukazuje da ovaj stroj radi u generatorskom načinu rada kad je moment SUI motora pozitivan.

Kako bi se svladao zahtijevani maksimalni nagib ceste od 33% pri približno nultoj brzini i akceleraciji (vidi sliku 6-2b), električni pogon vozila bi pod punim opterećenjem trebao generirati sljedeći izlazni moment (vidi jednadžbu (6-2)):

$$\tau_{R,\max} = r m_v g (\sin \alpha_{\max} + R_o \cos \alpha_{\max}). \quad (6-6)$$

Kako bi se ovaj izlazni moment generirao iz maksimalnog momenta elektromotora $\tau_{m,\max} =$

700 Nm (6-5b), potreban je mjenjač sa sljedećim prijenosnim omjerom:

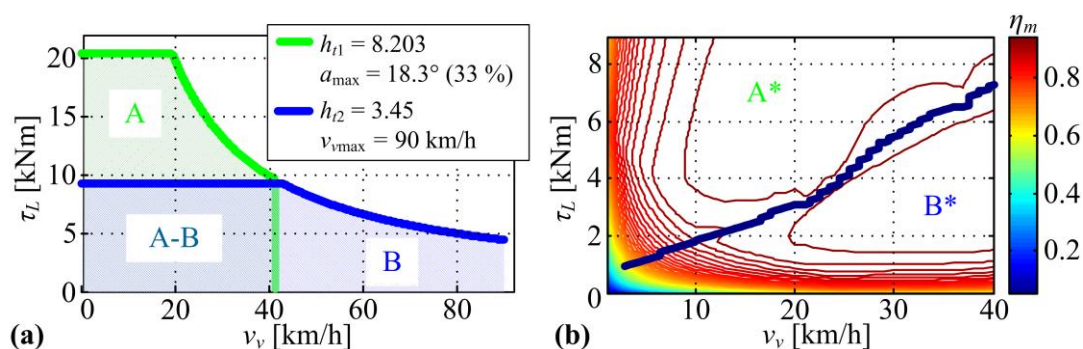
$$h_t \geq h_{t1} = \frac{\tau_{R,\max}}{\eta_i i_o \tau_{m,\max}}. \quad (6-7)$$

Nadalje, kako bi se zadovoljio limit brzine vozila ($v_{v,\max} = 90$ km/h; vidi sliku 6-2b) koji je ograničen maksimalnom okretnom brzinom elektromotora $\omega_{m,\max}$, prijenosni omjer h_t bi trebao zadovoljiti drugi uvjet:

$$h_t \leq h_{t2} = \frac{r \omega_{m,\max}}{i_o v_{v,\max}}. \quad (6-8)$$

Kako ne postoji jedna vrijednost prijenosnog omjera h_t koja zadovoljava uvjete (6-7) i (6-8) ($h_{t1} = 8.2$ i $h_{t2} = 3.45$), odabran je dvobrzinski mjenjač s prijenosnim omjerima h_{t1} i h_{t2} . Pritom je za izračun prijenosnog omjera h_{t2} korištena korigirana vrijednost radijusa gume (konzervativno postavljena na nešto nižu vrijednost od 0.388).

Odabir stupnja prijenosa transmisije. Odabir stupnja prijenosa EREV transmisije provodi se na temelju sljedećeg elementarnog algoritma. Prvi prijenosni omjer ($h_t = 8.2$) odabire se uvijek za niže brzine vozila i veće momente (područje A na slici 6-6a). Drugi prijenosni omjer ($h_t = 3.45$) odabire se s ciljem da se pokriju veće brzine vozila (područje B). Za područje preklapanja A-B, tj. za brzine niže od 40 km/h i momente niže od 9 kNm (vidi sliku 6-6a), algoritam odabire



Slika 6-6: Područja izbora dvaju stupnjeva prijenosa EREV pogona u izlaznoj mapi pogona (a) i granična krivulja između dva stupnja prijenosa u presjeku područja A i B (označenog kao A-B na slici (a)) (b).


prijenosni omjer koji daje veću korisnost elektromotora. Preciznije, prvi prijenosni omjer odabire se u području A*, dok se drugi prijenosni omjer odabire u području B*, kako je prikazano na slici 6-6b. Algoritam se na isti način koristi i kod regenerativnog kočenja ($\tau_R < 0$).

Model baterije. Model dinamike baterije proizlazi iz nadomjesnog električnog kruga prikazanog na slici 2-6a i opisan je jednadžbom stanja (2-3). Varijabla stanja je ponovno stanje napunjenosti baterije koje se označava kraticom SoC.

Napon otvorenog kruga U_{oc} i unutarnji otpor R modelirani su u ovisnosti o SoC-u, dok je unutarnji otpor R također ovisan i o predznaku struje. Ove karakteristike preuzete su iz Autonomie softvera, te su prikazane na slici 6-7 za jednu Li-Ion ćeliju. Snaga baterije iz jednadžbe (2-3) računa se prema sljedećem izrazu (vidi sliku 6-5):

$$P_{batt} = P_m - P_g = \eta_m^{k_{efm}} \omega_m \tau_m - \eta_g^{k_{efg}} \omega_g \tau_g, \quad (6-9)$$

gdje η_m predstavlja korisnost pogonskog elektromotora, a η_g predstavlja korisnost električnog generatora. Pritom je k_{efm} (i također k_{efg}) jednak -1 u slučaju kad električni stroj radi u motorskom načinu rada, dok je jednak +1 u slučaju kad stroj radi u generatorskom načinu rada.



Slika 6-7: Napon otvorenog kruga (a) i unutarnji otpor punjenja i pražnjenja za jednu ćeliju u ovisnosti o SoC-u (prikazano za jednu ćeliju Li-Ion baterije prema [67]).

Snaga SUI motora i generatora te dimenzioniranje baterije. Za potpuno električni kamion, dimenzioniranje baterije ima glavni utjecaj na domet vozila [67]. Međutim, u slučaju EREV vozila, domet vozila također ovisi i o SUI motoru i generatoru. Energija koja se može pohraniti u jednu ćeliju ($E_{cell} = 0.06$ kWh), kapacitet ($Q_{cell} = 0.16$ Ah) i masa ($m_{cell} = 0.63$ kg) preuzeti su od

Li-Ion baterije korištene u [95] dijeljenjem parametara baterije s brojem ćelija N . Potom se prikladan broj ćelija baterije može odrediti dijeljenjem potrebne energije baterije s energijom jedne ćelije ($N = E_{batt}/E_{cell}$). Ukupna masa i kapacitet baterije potom su izračunati množenjem mase odnosno kapaciteta jedne ćelije s ukupnim brojem ćelija baterije.

U slučaju razmatranog serijskog EREV vozila, snaga SUI motora i generatora izračunata je temeljem zahtjeva za električnom snagom P_{dv} pri punom opterećenju vozila, konstantnoj maksimalnoj brzini vozila (90 km/h) i cesti bez nagiba (duga vožnja na autoputu):

$$P_{dv} = m_v g R_o v_v + 0.5 \rho_{air} C_d A_f v_v^3. \quad (6-10)$$


Za brzinu vozila od 90 km/h i puni teret vozila, dobiva se izlazna snaga pogona od 102.1 kW. Zahtijevana snaga SUI motora P_{ee} postavljena je na veću vrijednost od 124.4 kW kako bi se u obzir uzele korisnosti električnih strojeva i transmisije. Masa baterije od približno 800 kg odabrana je kako bi ukupna masa EREV pogona bila oko 1.2 t (zajedno s masom SUI motora i generatora), što približno nadomješta kombiniranu masu polaznog SUI motora, automatske transmisije i spremnika s gorivom konvencionalnog vozila (temeljeno na podacima iz [91, 96, 97]). Ovo rezultira s približno 1300 ćelija i ukupnim kapacitetom baterije od 78 kWh.

6.2.2. Upravljanje pogonom

Upravljačka strategija. Za upravljanje serijskim hibridnim pogonom prilagođena je RB+ECMS upravljačka strategija predstavljena u poglavlju 2, koja kombinira regulator zasnovan na bazi pravila (RB) s trenutnim optimiranjem nadomjesne potrošnje goriva (ECMS). Prilagodba strategije odnosi se na činjenicu da je u poglavlju 2 bio korišten EREV pogon serijsko-paralelne konfiguracije, dok se u ovom poglavlju koristi serijska EREV konfiguracija. Pretpostavlja se da pogon radi u CD/CS režimu rada, pri čemu CD režim rada predstavlja potpuno električnu vožnju i aktivan je dok se baterija ne isprazni do neke određene razine (ovdje SoC = 0.3), nakon čega se uključuje hibridni CS režim rada u kojem se SoC održava na razini od 0.3.

U svrhu provjere RB+ECMS upravljačke strategije, dodatno je razvijeno nekoliko jednostavnih heurističkih upravljačkih metoda za hibridni CS režim rada. Prva je tzv. termostatska upravljačka strategija bez histereze (TERM-WOH), koja uključuje SUI motor i postavlja njegovu radnu točku u optimalnu vrijednost (vidi sliku 6-8) za slučaj ako SoC baterije padne ispod vrijednosti


od 30% i isključuje SUI motor ako SoC baterije prijeđe 30%. Ova je upravljačka strategija potom proširena kako bi uključila histerezu SoC-a (TERM-WH), gdje se SUI motor uključuje kad SoC padne ispod vrijednosti od 28% i isključuje kad SoC prijeđe vrijednost od 32%. Također, u obzir je uzeta i RB upravljačka strategija (RB1), koja postavlja radne točke SUI motora na optimalnu radnu liniju (Slika 6-8) u ovisnosti o zahtjevu vozača za snagom i vrijednosti SoC-a baterije. Ova upravljačka strategija također sadrži i logiku uključivanja/isključivanja SUI motora. Konačno, upravljačka strategija koja kombinira 1D-ECMS optimiranje i RB, bez 2D-ECMS-a, označena je s RB+1D-ECMS.



Slika 6-8: Optimalna radna linija i optimalna radna točka SUI motora.

Simulacijska provjera upravljačke strategije. U svrhu usporedne provjere upravljačke strategije, razvijeni kvazistatički model EREV-a (Slika 6-5a) simuliran je zajedno s predstavljenim upravljačkim strategijama za slučaj kamionskog UDDS voznog ciklusa (Slika 6-9a) i CS režima rada (početni SoC je postavljen na ciljani SoC i iznosi 0.3). Pritom je originalni kamionski UDDS vozni ciklus, s maksimalnom brzinom od 91 km/h, neznatno skaliran kako bi se omogućile simulacije EREV modela čija je maksimalna brzina fiksirana na 90 km/h. Dodatno, EREV upravljačke varijable optimirane su za isti UDDS vozni ciklus korištenjem DP algoritma (vidi potpoglavlje 2.2) s ciljem minimiziranja potrošnje goriva za različite krajnje iznose SoC-a, kako bi se dobio okvir za verifikaciju različitih realističnih upravljačkih strategija čiji se krajnji SoC tipično razlikuje od ciljanog SoC-a od 30%. Rezultati DP optimiranja interpolirani su ravnom linijom kako je prikazano na slici 6-9b (metodologija je detaljnije opisana u poglavlju 2).

Rezultati na slici 6-9b pokazuju da je potrošnja goriva realistične upravljačke strategije RB+ECMS veća za 7.5% od globalno optimalne potrošnje goriva dobivene DP optimiranjem. Ovo je značajno bolje u odnosu na potrošnje goriva dobivene ostalim realističnim upravljačkim strategijama. Samo se upravljačka strategija TERM-WOH približava RB+ECMS rezultatima, međutim ti se rezultati smatraju nerealističnima zbog prečestog uključivanja i isključivanja SUI motora koje je uzrokovano nedostatkom histereze. RB+ECMS rezultati bi mogli biti nadalje unaprijeđeni optimiranjem parametara upravljačke strategije za dani ciklus. Međutim, i bez takvog unaprijeđenja RB+ECMS rezultati bi se trebali smatrati povoljnim zbog toga što DP optimiranje ne uključuje nikakva ograničenja na učestalost uključivanja i isključivanja SUI motora i stupnjeva prijenosa, te zbog toga što DP optimiranje ima kompletan pregled ceste odnosno voznog ciklusa za razliku od kauzalnih realističnih upravljačkih strategija koje provode neki vid trenutnog optimiranja.



Slika 6-9: Kamionski UDDS vozni ciklus [98] (a) i grafički prikaz rezultata simulacije u CS režimu rada za različite upravljačke strategije u odnosu na globalno optimalne DP rezultate (b).

6.3. Rezultati simulacija i optimiranja punjenja flote električnih dostavnih vozila


U ovom potpoglavlju prvo se provode usporedbe potrošnje goriva konvencionalne flote i EREV flote temeljene na simulacijama modela pojedinačnih vozila preko svih snimljenih voznih ciklusa (opisanih u poglavlju 3). Potom se, na temelju rezultata o potrošnji goriva te DP optimiranja punjenja EREV flote opisane naprednim agregatnim modelom, provode

analize operativnih troškova i CO₂ emisija dviju flota.

6.3.1. Usporedna analiza rezultata simulacije pojedinačnih modela vozila

Kako bi se dobili precizni zahtjevi transporta za snagom i podaci o potrošnji goriva, provedene su simulacije EREV modela zajedno s RB+ECMS upravljačkom strategijom preko cjelokupnog skupa snimljenih voznih ciklusa (≈ 2400 ciklusa). Pretpostavljeno je da svako EREV vozilo počinje vožnju s potpuno punom baterijom ($SoC = 1$). Kako je navedeno u potpoglavlju 6.2, svako EREV vozilo radi u CD režimu dok njegov SoC ne padne na vrijednost 0.3, nakon čega se uključuje CS režim rada s ciljem održanja SoC-a na 0.3.


Slika 6-10a prikazuje razdiobu prijeđenog puta do uključivanja CS režima rada. Ovi rezultati pokazuju da se potpuno električna vožnja može realizirati ako je prijeđeni put tijekom voznog ciklusa do oko 40-60 km ovisno o voznom ciklusu. Slika 6-10b prikazuje razdiobu vrijednosti SoC-a na kraju svakog voznog ciklusa u ovisnosti o prijeđenom putu, koja potvrđuje da se SoC može uspješno održati korištenjem SUI motora i generatora u CS režimu rada.



Slika 6-10: Razdioba prijeđenog puta do uključivanja CS režima rada (a) i konačni SoC u odnosu na prijeđeni put tijekom voznog ciklusa (b).


Slika 6-11a prikazuje normirane potrošnje goriva za sve snimljene vozne cikluse u ovisnosti o prijeđenom putu ciklusa. Na slici 6-11b prikazane su interpolacije ovih potrošnji goriva pravcima. Pritom su potrošnje goriva dobivene simulacijama EREV modela i modela konvencionalnog vozila (KONV) označene s ekstenzijom „sim“, dok su snimljene potrošnje goriva u slučaju konvencionalnih vozila označene ekstenzijom „rec“. EREV daje nižu potrošnju goriva od konvencionalnog vozila kad je prijeđeni put manji od 250 km, dok

konvencionalno vozilo ima manju potrošnju goriva tj. veću korisnost pogona za veći prijeđeni put (vidi slike 6-11b i 6-12). Ovo se može objasniti činjenicom da dulji vožni ciklusi uključuju značajan udio vožnje na autocesti pri konstantnoj brzini i posljedično Diesel motor u konvencionalnim vozilima u ovom slučaju radi kontinuirano blizu optimalne radne brzine vrtnje, što je za te radne uvjete slično i kod EREV-a (baterija se praktički ne koristi), ali se dodaju gubici zbog višestruke pretvorbe energije (generator-elektronički pretvarač-motor). Budući da vožni ciklusi kraći od 250 km predstavljaju veliku većinu vožnih ciklusa (90%), EREV flota rezultira s 26% nižom ukupnom potrošnjom goriva kad se uspoređi s flotom konvencionalnih vozila kroz period od tri mjeseca. Posljedično, emisije CO₂ (vezane uz potrošnju goriva) i trošak goriva također su niži za 26% u slučaju elektrificirane flote. Temeljem simulacija dobiveno je da prosječna potrošnja na 100 km iznosi 22.3 l u slučaju konvencionalnih vozila, što pada na 16.5 l za slučaj EREV vozila.



Slika 6-11: Normirana potrošnja goriva u ovisnosti o prijeđenom putu tijekom voznog ciklusa (a) i interpolacija istih potrošnja goriva pravcima (b).

Slika 6-12 prikazuje ukupnu potrošnju goriva za različite klasterne vožne cikluse. Ovi rezultati ukazuju da EREV flota smanjuje potrošnju goriva za 41% u odnosu na konvencionalnu flotu za slučaj vožnih ciklusa kraćih od 250 km, dok u slučaju vožnih ciklusa duljih od 250 km, EREV flota rezultira 10% većom potrošnjom goriva (Slika 6-12b). Potrošnja goriva je za čak 88.3% niža u slučaju EREV flote za vožne cikluse kraće od 100 km (Slika 6-12a). Ovi rezultati mogu poslužiti kao početni indikator optimalnog udjela EV (ili EREV-a) u floti dostavnih vozila za danu primjenu.



Slika 6-12: Normirane potrošnje goriva dobivene simulacijama razvijenih modela konvencionalnog i EREV kamiona za različite klustere voznih ciklusa.

6.3.2. Usporedna analiza operativnih troškova te emisija štetnih plinova na razini flote vozila

Parametriranje agregatnog modela flote EV temeljeno je na simulacijama modela EREV kamiona preko snimljenih voznih ciklusa kako je to opisano u poglavlju 4.2 za slučaj parametriranja EREV modela putničkog vozila i pretpostavku da svako vozilo napušta distributivni centar s punom baterijom (nadalje se koristi opća skraćenica EV). Ova se pilot studija bavi ispitivanjem mogućnosti smanjenja: (a) operativnih troškova EV flote vezanih uz potrošnju energije, (b) smanjenje troškova vezanih uz potrošnju električne energije ostalih potrošača u distributivnom centru i (c) CO₂ emisija EV flote; sve u usporedbi s flotom konvencionalnih vozila za različite razine uvođenja proizvodnje električne energije iz OIE u vidu solarnih panela (od 0 m² do 57600 m²). Pritom je maksimalna površina od 57600 m² dobivena na temelju procijenjene površine krovova skladišta distributivnog centra gdje je pretpostavljeno da će se instalirati solarni paneli. Pretpostavlja se da se energija iz OIE koja se vraća u mrežu ne naplaćuje, tj. smatra se odbačenom energijom. Pretpostavljena cijena Diesel goriva je 1.091 EUR/L, dok je cijena električne energije $E_{LT} = 0.06$ EUR/kWh u periode niske tarife tijekom dana i $E_{HT} = 0.11$ EUR/kWh u periodu visoke tarife („Cijena 1“ na slici 4-3;


ove cijene su bile na snazi u siječnju 2014. na hrvatskom tržištu električne energije).

Rezultati optimiranja. Tablica 6-3 prikazuje udjele energije punjenja flote EV tijekom perioda niže (jeftine) tarife električne energije (LT) i tijekom perioda više skuplje tarife (HT) za slučaj kad ne postoji proizvodnja energije iz OIE ($A_{eff,PV} = 0 \text{ m}^2$). Povećavanjem maksimalne snage punjenja pojedinačnog vozila ($P_{cmax,ind}$) s iznosa 10 kW na 30 kW, veći udio punjenja se obavlja tijekom perioda niske (noćne) tarife (58.3% u usporedbi s 54.7%), što se odražava u smanjenju ukupnog troška punjenja C_{bat} za 2.5%.

Tablica 6-3: Udjeli punjenja flote EV tijekom perioda jeftine električne energije (LT) i tijekom perioda skupe električne energije (HT) za slučaj kad ne postoji višak proizvedene energije iz OIE.


	E_{LT} [%]	E_{HT} [%]	E_{TOTAL} [%]	C_{bat} [%]
$P_{cmax,ind} = 10 \text{ kW}$	54.7%	45.3%	100.0%	0.0%
$P_{cmax,ind} = 30 \text{ kW}$	58.3%	41.7%	100.0%	-2.5%

Slika 6-13 prikazuje ukupni trošak punjenja EV flote za različite scenarije instaliranih efektivnih površina solarnih panela. Ovi rezultati ukazuju da u slučaju maksimalne površine instaliranih solarnih panela, trošak punjenja EV flote može biti smanjen za više od 40% kad se uspoređi sa slučajem bez proizvodnje energije iz OIE i primjene punjača maksimalne snage 10 kW. Trošak punjenja može se nadalje smanjiti (i za više od 60%) ako bi se maksimalna




Slika 6-13: Ovisnost (normiranog) troška punjenja flote EV (C_{bat}) o površini instaliranih solarnih panela ($A_{eff,PV}$) za dvije vrijednosti maksimalne snage punjača ($P_{cmax,ind}$).

snaga punjača povećala na 30 kW (crvena linija na slici 6-13). Udio energije punjenja iz OIE u ukupnoj energiji punjenja dostiže 35% za snagu punjača od 10 kW odnosno 55% za snagu punjača 30 kW (Slika 6-14).




Slika 6-14: Ovisnost udjela energije punjenja flote EV koja dolazi iz OIE ($E_{ch,OIE}$) u ukupnoj energiji punjenja flote ($E_{ch,TOTAL}$) o površini instaliranih solarnih panela ($A_{eff,PV}$) za dvije vrijednosti maksimalne snage punjača ($P_{cmax,ind}$).

Uzimanjem u obzir troška goriva zajedno s troškom električne enerije, ukupni operativni troškovi EV flote smanjuju se za oko 13% u odnosu na flotu konvencionalnih vozila za slučaj kad nema proizvodnje energije iz OIE (vidi sliku 6-15 za $A_{eff,PV} = 0$ m²). Za slučaj instalacije



Slika 6-15: Normirani ukupni troškovi vezani uz flotu EV ($C_{total} = C_{bat} + C_{fuel}$) i flotu konvencionalnih vozila (C_{fuel}) u ovisnosti o površini instaliranih solarnih panela.


maksimalne površine solarnih panela, smanjenje ukupnih operativnih troškova EV flote u odnosu na konvencionalnu flotu je izraženije i iznosi oko 20% (Slika 6-15). Također, u ovom slučaju, troškovi električne energije korištene od strane ostalih potrošača unutar distributivnog centra mogu biti smanjeni za 45% na račun (besplatne, u smislu operativnih troškova) proizvodnje iz OIE (Slika 6-16).




Slika 6-16: Ovisnost troškova električne energije korištene od strane ostalih potrošača u distributivnom centru ($C_{el,total}$) o površini instaliranih solarnih panela ($A_{eff,PV}$).

Slika 6-17 prikazuje normirani višak proizvedene energije E_{ceep} iz solarnih panela, tj. neiskorišten potencijal solarne energije, u ovisnosti o površini instaliranih solarnih panela. Drugim riječima, E_{ceep} predstavlja proizvedenu električnu energiju iz OIE koja nije iskorištena ni za opskrbu ostalih potrošača u distributivnom centru, ni za punjenje EV već se odbacuje (uz pretpostavku da se povrat energije u mrežu ne može naplatiti; prethodno korištena oznaka e_{ceep} , definirana u odjeljku 5.3.1, predstavlja višak OIE energije koji nije iskorišten za opskrbu ostalih potrošača). Temeljeno na rezultatima prikazanim na slikama 6-13, 6-16 i 6-17, može se približno odrediti optimalan raspon površine instaliranih solarnih panela. Optimalan odabir temelji se na kompromisu dvaju konfliktnih ciljeva: (a) minimiziranje ukupnih troškova električne energije (Slika 6-13 i 6-16; vezano uz operativne troškove), te (b) minimiziranje viška proizvedene energije iz OIE (Slika 6-17; vezano uz troškove instalacije solarnih panela). Prema kombiniranom prikazu danom na slici 6-18, optimalna površina instaliranih solarnih panela za odgovarajuću flotu EV vozila i energetski sustav bi trebala biti približno između 15% i 30% od ukupne potencijalne površine na kojoj mogu biti instalirani solarni paneli. Instalacija veće površine solarnih panela (ili instalacija punog potencijala solarnih panela) bi

bila smisljena u slučaju veće penetracije EV (veći broj EV unutar flote).



Slika 6-17: Ovisnost (normiranog) viška proizvedene električne energije iz OIE (E_{cep}) o površini instaliranih solarnih panela ($A_{eff,PV}$).



Slika 6-18: Ukupni troškovi električne energije vezani uz flotu EV i ostale potrošače ($C_{bat} + C_{el,total}$) u ovisnosti o višku proizvedene energije iz OIE (crni trokuti pokrivaju optimalan raspon površine solarnih panela).


Konačno, slika 6-19 prikazuje CO₂ emisije (od bušotine do kotača, *engl. well-to-wheel* [99]), vezane uz potrošeno Diesel gorivo i proizvodnju električne energije korištene za punjenje EV flote za različite tehnologije proizvodnje električne energije, te za dvije vrijednosti maksimalne snage punjača $P_{max,ind}$, u ovisnosti o površini instaliranih solarnih panela. Proračuni su temeljeni na pretpostavci da izgaranje jedne litre Diesel goriva u vozilu generira 3.16 kg CO₂, dok se pri proizvodnji električne energije može emitirati oko 1 kg CO₂/kWh za

slučaj da se električna energija dobiva sagorijevanjem ugljena (EL1), 0.45 kg CO₂/kWh za slučaj izgaranja prirodnog plina (EL2) i 0.1 kg CO₂/kWh u slučaju dobivanja električne energije iz kombinacije nuklearnih elektrana i obnovljivih izvora (EL3) [99]. Rezultati na slici 6-19a ukazuju da emisije CO₂ iz goriva koje se odnose samo na EV flotu (konstantni su zbog toga što ne ovise o proizvodnji energije iz OIE) dominiraju nad emisijama CO₂ iz ostalih izvora. Ovo je posebno naglašeno u slučaju maksimalne površine instaliranih solarnih panela gdje su već EL1 emisije 38% (u slučaju $P_{cmax,ind} = 10$ kW) odnosno 50% (u slučaju $P_{cmax,ind} = 30$ kW) niže nego emisije CO₂ proizašle iz potrošenog goriva (sve emisije CO₂ su normirane u odnosu na emisiju CO₂ flote konvencionalnih vozila).

Ukupne emisije CO₂ (i dalje za EV flotu, ali sada uključujući emisije CO₂ iz goriva i emisije CO₂ pri proizvodnji električne energije za punjenje baterija) prikazane su na slici 6-19b. U scenariju kada nema proizvodnje električne energije iz solarnih panela u distributivnom centru ($A_{eff,PV} = 0$ m²) i kada je električna energija iz mreže dobivena sagorijevanjem ugljena (EV-EL1), EV flota generira 30% više CO₂ emisija (od bušotine do kotača) nego flota konvencionalnih vozila. U slučaju proizvodnje električne energije iz prirodnog plina (EV-EL2 rezultati), CO₂ emisije EV flote su približno iste kao i emisije flote koje generira flota konvencionalnih vozila. U ovom scenariju, EV flota ima oko 20% niže CO₂ emisije u odnosu na konvencionalnu flotu jedino ako energija iz mreže potječe iz nuklearnih elektrana ili elektrana pogonjenih OIE. Povećavanjem površine instaliranih solarnih panela u distributivnom centru, emisije CO₂ EV flote snižavaju se za do 10-15% (ovisno o $P_{cmax,ind}$) ispod emisija flote konvencionalnih vozila u slučaju kad električna energija iz mreže potječe od prirodnog plina. U slučaju kad električna energija iz mreže potječe od ugljena, emisije CO₂ EV flote su čak i uvođenjem solarnih panela u distributivni centar veće (ili približno jednake za $P_{cmax,ind} = 30$ kW) od emisija flote konvencionalnih vozila. Smanjenje emisije CO₂ povećavanjem površine instaliranih solarnih panela nešto je manje izraženo u slučaju kad električna energija iz mreže potječe iz nuklearnih elektrana ili iz OIE, jer su emisije CO₂ niske u oba slučaja.

Relativno smanjenje emisije CO₂ bi bilo još izraženije ako bi se flota EV razmatrala samo za odrađivanje kraćih voznih ciklusa (npr. do 100 km, vidi sliku 6-12a). Međutim, kod elektrifikacije flote bi, osim emisije CO₂ i operativnih troškova, trebalo uzeti u obzir i druge

bitne aspekte kao što su manja razina buke kod EV, te regulative koje određuju naplaćivanje ili čak zabranu vožnje konvencionalnim vozilima u posebno definiranim zonama (*engl. Low emission zone, LEZ*).




Slika 6-19: Emisije CO₂ vezane uz EV flotu (posebno dane za gorivo, te posebno za proizvodnju električne energije) (a) i ukupne emisije CO₂ (gorivo + proizvodnja električne energije) (b) (normirane u odnosu na ukupne emisije CO₂ vezane uz flotu konvencionalnih vozila, KONV) u ovisnosti o površini instaliranih solarnih panela ($A_{eff,PV}$) i za dva iznosa maksimalne snage punjača.

Analiza osjetljivosti. Pretpostavljene vrijednosti parametara modela transportno-energetskog sustava mogu se razlikovati od stvarnih vrijednosti te je stoga provedena analiza osjetljivosti rezultata optimiranja punjenja u ovisnosti o perturbacijama tih parametara. Ovdje su perturbirani sljedeći parametri modela: (a) korisnost solarnih panela (η_{OIE}), (b) korisnost punjenja baterije EV vozila (η_{ch} u izrazu (4-4)) i (c) maksimalna snaga punjenja pojedinačnog EV-a ($P_{cmax,ind}$). Slika 6-20a prikazuje osjetljivost troška punjenja flote u odnosu na referentni trošak (dobiven u slučaju referentnih/nominalnih vrijednosti ulaznih parametara) za različite perturbacije spomenutih ulaznih parametara (varijacije parametara dane su u legendi na slici 6-20b). Pri perturbaciji jednog parametra, ostali parametri se fiksiraju na referentne vrijednosti. Referentni slučaj pretpostavlja površinu instaliranih solarnih panela od 14400 m^2 (25% od ukupne potencijalne površine na kojoj se mogu instalirati solarni paneli). Rezultati na slici 6-20 pokazuju da perturbacija maksimalne snage punjenja pojedinačnog vozila $P_{cmax,ind}$ najviše utječe na trošak punjenja flote, dok najmanji utjecaj ima perturbacija korisnosti punjenja baterije η_{ch} . Međutim,

ova osjetljivost ovisi o rasponu unutar kojih se određeni parametar perturbira i moguće je da bi se za odabir nekih drugih vrijednosti raspona pokazalo da neki drugi parametar ima najveći utjecaj na trošak punjenja.

U referentnom slučaju, ukupni operativni troškovi (trošak punjenja baterija + trošak goriva) EV flote su za 14.8% niži nego operativni troškovi (trošak goriva) konvencionalne flote vozila (usporedi sliku 6-15 za slučaj $A_{eff,PV} = 14400 \text{ m}^2$). U najgorem slučaju, operativni troškovi EV flote još su uvijek 12.6% niži nego operativni troškovi konvencionalne flote, dok su u najboljem slučaju ti operativni troškovi niži za 15.9% (Slika 6-20b). Male varijacije ukupnih operativnih troškova ukazuju na nisku osjetljivost na perturbirane parametre i na taj način potvrđuju vjerodostojnost dobivenih procjena smanjenja operativnih troškova EV flote u odnosu na flotu konvencionalnih vozila.

Za cjelovito ispitivanje isplativosti elektrifikacije flote konvencionalnih vozila, u analizu bi osim operativnih troškova trebalo uključiti i investicijske troškove vezane uz kupnju EV i kupnju te instalaciju solarnih panela, troškove operativnog održavanja, amortizacije i sl. Međutim, takva analiza nadilazi obim ovog rada.



Slika 6-20: Analiza osjetljivosti troška punjenja EV flote (a) i operativnih troškova (gorivo + punjenje) EV flote u odnosu na operativne troškove (gorivo) konvencionalne flote (b) u ovisnosti o perturbaciji parametara vezanih uz energetski sustav (referentne vrijednosti parametara su $\eta_{OIE} = 0.15$, $\eta_{ch} = 0.92$, $P_{cmax,ind} = 10 \text{ kW}$; površina solarnih panela postavljena je na $A_{eff,PV} = 14400 \text{ m}^2$).

7. Zaključak

U doktorskom radu prvo je predložena strategija upravljanja serijsko-paralelnim pogonima hibridnih električnih vozila (HEV) i električnih vozila proširenog dometa (EREV - *engl. Extended Range Electric Vehicle*), koja je temeljena na kombiniranju regulatora zasnovanog na bazi pravila (RB – *engl. Rule-based*) i trenutačnog optimiranja nadomjesne potrošnje goriva (ECMS – *engl. Equivalent Consumption Minimisation Strategy*). Glavna karakteristika predložene strategije upravljanja ogleda se u očuvanju praktičnosti RB regulatora (uključujući regulaciju stanja napunjenosti baterije, SoC – *engl. State-of-Charge*), uz smanjenje potrošnje goriva temeljeno na egzaktnom optimiranju radne točke pogona. U EREV slučaju, upravljačka strategija uključuje i algoritme postavljanja optimalnog načina rada pogona (tj. stanja uključenosti spojki pogona), te preciznog slijeđenja referentne SoC trajektorije. Osnovni režim rada EREV pogona (CD/CS režim – *engl. Charge Depleting/Charge Sustaining*) pretpostavlja prvo električnu vožnju do trenutka ispražnjenja baterije na neku pred-definiranu razinu, te potom hibridnu vožnju temeljenu na uključivanju motora s unutarnjim izgaranjem (SUI motora) s ciljem produljenja dometa vozila i održanja SoC-a baterije. K tome, razmatran je kombinirani režim rada kod kojeg se SUI motor koristi preko cijele trajektorije referentnog SoC-a (BLND režim – *engl. Blended*) i na taj način postiže bolja cjelokupna korisnost pogona vozila. U kombiniranom režimu rada posebna pažnja posvećena je formuliranju optimalne SoC trajektorije, te sintezi sustava njenog slijeđenja s naglaskom na optimiranje parametara vezanih uz razine snage uključivanja i isključivanja SUI motora.

Predložena RB+ECMS upravljačka strategija implementirana je u programskom jeziku C, te simulacijski provjerena za slučaj modela putničkog EREV-a u okviru programskog paketa Matlab-Simulink. Također je vrednovana usporedbom s globalno-optimalnim rezultatima dobivenima optimiranjem upravljačkih varijabli EREV pogona primjenom algoritma dinamičkog programiranja (DP), koji je zbog računalne složenosti implementiran u programskom jeziku C. Uvidom u rezultate simulacije i optimiranja može se zaključiti da je RB+ECMS strategija u CD režimu rada tek neznatno lošija od DP rezultata (potrošnja električne energije je veća za samo 1% za NEDC, HWFET i US06 certifikacijske vozne cikluse, te za oko 7% za UDSS ciklus). Za slučaj CS režima rada, potrošnja goriva uz

primjenu RB+ECMS strategije veća je u odnosu na DP rezultate za oko 1.5% za NEDC i UDDS vozne cikluse, za samo 0.2% u slučaju US06 voznog ciklusa, te za 4.6% kod HWFET voznog ciklusa. Nadalje, rezultati DP optimiranja pokazuju da se u kombiniranom režimu rada može postići dodatno smanjenje potrošnje goriva u odnosu na CD/CS režim rada, posebno u slučaju približno jednakog trajanja CD i CS intervala, i to za 4-5% za NEDC, UDDS i US06 vozne cikluse, te za 2.6% za HWFET vozni ciklus. K tome, DP rezultati optimiranja za slučaj kombiniranog režima rada ukazuju da optimalne SoC trajektorije imaju približno linearni oblik za dani slučaj ceste bez nagiba te završavaju na minimalnoj vrijednosti tek na kraju voznog ciklusa. Ovo je iskorišteno u profiliranju referentne SoC trajektorije kod RB+ECMS upravljačke strategije u kombiniranom režimu rada. Rezultati simulacije pokazuju da RB+ECMS upravljačka strategija s optimiranim parametrima vezanima uz uključivanje i isključivanje SUI motora rezultira u 5-7% nižoj potrošnji goriva u usporedbi s osnovnom RB+ECMS strategijom u CD/CS režimu rada. Kad se ti rezultati usporede s globalno optimalnim DP rezultatima u kombiniranom režimu rada, RB+EMCS upravljačka strategija ima za oko 2% veću potrošnju goriva u slučaju HWFET voznog ciklusa, oko 5% za NEDC i US06 vozne cikluse i oko 10% za UDDS ciklus. Navedena bliskost RB+ECMS i DP rezultata, kako za CD/CS tako i za kombinirani režim rada, upućuje na kvalitetu predložene upravljačke strategije, imajući pritom u vidu da DP metoda ne uključuje nikakva ograničenja na učestalost uključivanja/isključivanja SUI motora i spojki te ima potpuni pregled voznog ciklusa (u budućnost) što nije slučaj s RB+ECMS upravljanjem. Dodatna važna karakteristika RB+ECMS upravljačke strategije odnosi se na robusnu održivost SoC-a, što je osim simulacijom preko jednostrukih certifikacijskih voznih ciklusa, dodatno potvrđeno simulacijom preko različitih višestruko ponavljanih voznih ciklusa.

U radu je nadalje prikazano snimanje, obrada i analiza podataka vezanih uz flotu dostavnih vozila vodećeg regionalnog maloprodajnog lanca. Podaci su snimani tijekom vremenskog perioda od tri mjeseca na deset karakterističnih dostavnih vozila korištenjem GPS/GPRS uređaja i vremena uzorkovanja od jedne sekunde. Osim GPS podataka od kojih su najvažniji: brzina vozila, geografske koordinate te nadmorska visina, snimani su i podaci s CAN sabirnice, a koji su vezani uz potrošnju goriva i brzinu vrtnje pogonskog motora. Obradom snimljenih podataka dobivene su razne statističke razdiobe vezane uz vremena dolazaka i odlazaka u i iz distributivnog centra, trajanje stanja parkiranosti vozila, prijeđene udaljenosti,

broj vozila u distributivnom centru, te procijenjenu potrošnju goriva. Provedene analize pokazale su da bi razmatrana flota mogla biti dobar kandidat za elektrifikaciju tj. zamjenu s odgovarajućom flotom električnih vozila (EV), zbog sljedećih svojstava:

- 1) Velika većina vozila parkirana je u glavnom distributivnom centru preko noći s prosječnim trajanjem parkiranja od oko šest sati, te također preko vikenda. Ovo otvara mogućnost jeftinog i učinkovitog sporog punjenja baterija EV preko noći i vikenda, koje također rezultira i poravnanjem opterećenja mreže.
- 2) Više od polovica razmatranih vozila iz flote parkirana su u distributivnom centru u poslijepodnevnim satima s očekivanim trajanjem parkiranja od oko 1 do 2 sata, gdje se potencijalno može primijeniti brzo punjenje u kombinaciji s obnovljivim izvorima energije (OIE) kao što su npr. solarni paneli.
- 3) Trajanje parkiranosti vozila (tijekom iskrcaja tereta) u prodajnim centrima je uglavnom kraće od 40 minuta, a najčešće iznosi oko 20 minuta. Ovo otvara mogućnost za brzo punjenje baterija vozila prilikom svakog stajanja u većim prodajnim centrima.
- 4) Gotovo pola voznih misija su unutar 50 km prijeđene udaljenosti (najčešće oko 20 km) i više od 90% njih su unutar 250 km, što ukazuje na mogućnost korištenja potpuno električnih vozila za glavninu voznih ciklusa.

Predstavljen je također i postupak sinteze malog skupa naturalističkih reprezentativnih voznih ciklusa iz velikog skupa snimljenih voznih ciklusa, koji se temelji na metodi Markovljevih lanaca. Prije sinteze, snimljeni vozni ciklusi klasterirani su po kriteriju ukupnog prijeđenog puta i geografskih koordinata na polovini prijeđene udaljenosti, kako bi pojedini klasteri obuhvatili i karakteristike cesta u različitim geografskim područjima. Pritom se svaki klaster reprezentira jednim sintetičkim voznim ciklusom. Predstavljena su i međusobno uspoređena dva pristupa sintezi voznih ciklusa. Validacija sintetičkih voznih ciklusa pokazala je da pristup temeljen na Markovljevom lancu koji u svoja stanja osim brzine vozila uključuje i akceleraciju vozila daje statistički reprezentativnije vozne cikluse u odnosu na pristup gdje se u stanja Markovljevog lanca uključuje samo brzina vozila. Drugim riječima, u pristupu u kojem se kao stanja koriste brzina i akceleracija vozila, potrebno je generirati značajno manji broj sintetičkih voznih ciklusa kako bi se dobio reprezentativni vozni ciklus tj. onaj koji

zadovoljava različite validacijske kriterije.

U radu je potom predložena nova formulacija analitičkog agregatnog modela baterije flote EV, koja u obzir uzima činjenicu da kapacitet i SoC agregatne baterije ovise o (promjenjivom) broju EV spojenih na mrežu. Pored toga prikazan je i osnovni model agregatne baterije preuzet iz literature kako bi se dobio uvid u unaprijeđenje točnosti novopredloženog agregatnog modela. Konačno, za potrebe validacije agregatnih modela razvijen je distribuirani model flote EV koji je najsloženiji, ali ujedno i najrealističniji jer inherentno uključuje sva ograničenja vezana uz pojedinačna vozila. Svi modeli su parametrirani na temelju snimljenih voznih ciklusa flote dostavnih vozila i odgovarajućih simulacija modela pojedinačnih EREV-a uključujući njihovu upravljačku strategiju. Neovisno o modelu flote, predloženo je optimiranje punjenja EV korištenjem DP algoritma, čime se dobivaju globalno-optimalni rezultati punjenja za opći problem nelinearnog modela flote EV i nelinearnih ograničenja. Rezultati optimiranja dobiveni korištenjem agregatnih modela flote, a koji se odnose na krivulje agregatne snage punjenja i agregatnog SoC-a, uspoređeni su i validirani u odnosu na rezultate dobivene korištenjem realističnog distribuiranog modela flote. Osim optimiranja punjenja uz primjenu DP algoritma, predložen je i računalno učinkovit, heuristički algoritam raspodjele agregatne snage punjenja (dobivene DP optimiranjem punjenja temeljem nekog od agregatnih modela flote) po pojedinačnim EV. Raspodjela po pojedinačnim vozilima u obzir uzima realistična ograničenja pojedinačnih EV, pa su stoga polazni agregatni profili snage punjenja ponešto modificirani (samim algoritmom raspodjele agregatne snage) kako bi se zadovoljila ta ograničenja. Korigirani agregatni profili koji manje odstupaju od polaznih profila impliciraju veću točnost agregatnog modela flote kojim se dobio polazni agregatni profil snage punjenja. Zbog toga se algoritam raspodjele agregatne snage po pojedinačnim EV koristio pri validaciji predloženih agregatnih modela. Međutim, osim za validaciju, ovaj algoritam bi se mogao koristiti i kod hijerarhijskog upravljanja punjenjem flote vozila, gdje bi se na nadređenoj razini optimirala agregatna snaga punjenja flote, dok bi se na podređenoj ta agregatna snaga raspoređivala po pojedinačnim EV korištenjem ovog algoritma.

Usporedni validacijski rezultati pokazuju da je u slučaju novopredloženog agregatnog modela flote značajno unaprijeđena točnost modeliranja u odnosu na osnovni model u smislu: a) zadovoljenja postavljenih ograničenja na agregatni SoC, b) postizanja boljeg poklapanja

ostvarenog agregatnog profila snage punjenja raspoređene po pojedinačnim EV i polaznog agregatnog profila snage dobivenog DP optimiranjem, c) postizanja bolje korelacije između profila agregiranog SoC-a distribuiranog modela flote i SoC-a agregatnog modela i d) realističnijih vrijednosti ukupnog troška električne energije pri punjenju čitave flote EV.

Nabrojane prednosti predloženog agregatnog modela flote EV čine ga boljim kandidatom za razne studije energetskeg planiranja u odnosu na osnovni agregatni model. Pritom treba imati na umu da predloženi model zahtijeva veći broj ulaznih razdioba u odnosu na osnovni model, tj. za njegovo parametrisiranje je potrebno raspolagati detaljnijim skupom snimljenih podataka vezanih uz flotu koja se modelira. S druge strane, jednostavniji osnovni agregatni model može se, prema rezultatima analiza, pogodno koristiti kod hijerarhijskog vođenja punjenja flote EV, jer se raspodjelom pripadne agregatne snage po pojedinačnim EV u tom slučaju dobiju marginalno lošiji rezultati nego u slučaju novog agregatnog modela (u smislu korelacije s DP rezultatima optimiranja punjenja distribuiranog modela flote).

Osim spomenutog DP optimiranja snage punjenja temeljem agregatnog modela flote EV, gdje je pretpostavljeno da je baterija svakog EV (a samim tim i agregatna baterija) potpuno puna pri odspajanju s mreže (tj. na početku svakog voznog ciklusa) odnosno da je SoC u tom trenutku jednak 1, razmotren je i pristup gdje bi se SoC svakog pojedinačnog EV na odlasku optimirao umjesto držao fiksnim. Kako bi se to omogućilo, zahtjev transporta za energijom modeliran je korištenjem računalno učinkovitih odzivnih površina koje su dobivene simulacijama modela vozila preko posebno odabranih i validiranih sintetičkih voznih ciklusa. Tada je uspostavljeno dvorazinsko optimiranje, kod kojeg se na nadređenoj razini optimira SoC pojedinačnih EV na odlasku i snaga punjača (tj. maksimalna snaga punjenja EV) korištenjem genetskog algoritma NSGA-II, a na podređenoj razini se provodi DP optimiranje punjenja agregatnog modela flote. Pritom se minimizira dvokriterijska ciljna funkcija koja uključuje operativne troškove flote (ukupni troškovi koji uključuju gorivo i električnu energiju za punjenje flote EV) i snagu punjača. Konačni rezultat optimiranja je Pareto optimalna fronta koja daje minimalne iznose operativnih troškova za dane iznose snaga punjača. Usporedbom s jednorazinskim pristupom gdje se obavlja samo DP optimiranje punjenja, pokazano je da je ovaj pristup osim širih praktičnih aspekata (poput nižih troškova električne energije za punjenje) bolji i u smislu izbjegavanja kršenja ograničenja vezanih uz

maksimalnu snagu punjenja pojedinačnih EV.

U završnom dijelu rada prikazana je pilot studija vezana uz ispitivanje mogućnosti elektrifikacije razmatrane flote dostavnih vozila u kombinaciji s uvođenjem obnovljivih izvora energije u vidu solarnih panela u pripadni distributivni centar. Za potrebe pilot studije, izrađen je simulacijski model konvencionalnog dostavnog vozila na kojem su snimani podaci, te model EREV vozila serijske konfiguracije pogona, sličnih karakteristika momenta i snage kao i polazno konvencionalno vozilo. Oba modela vozila simulirana su preko svih snimljenih voznih ciklusa uz pretpostavku da je kod EREV-a baterija na početku svakog voznog ciklusa potpuno puna. Na temelju rezultata simulacija, pokazano je da se vozni ciklusi od približno 40-60 km mogu zadovoljiti u potpuno električnoj vožnji (oko 50% ciklusa u najgorem slučaju kada se EV pune samo u distributivnom centru), dok se za dulje vozne cikluse mora uključiti hibridna vožnja. Smanjenje ukupne potrošnje goriva, kao i emisije CO₂ plinova, u slučaju EREV flote je oko 40% u usporedbi s konvencionalnom flotom za vozne cikluse do 250 km. U slučaju voznih ciklusa duljih od 250 km, EREV-i imaju 10% veću potrošnju goriva i CO₂ emisija u odnosu na konvencionalna vozila, što se objašnjava nižom korisnošću kod višestruke pretvorbe energije karakteristične za serijske konfiguracije pogona. Stoga bi za trenutni stupanj razvoja baterija (u smislu cijene i mase) bilo razumno elektrificirati samo ona vozila koja pokrivaju kraće i srednje duge vozne cikluse (npr. gradske i prigradske vozne cikluse). Dugi vozni ciklusi bi mogli eventualno biti pokriveni samo u slučaju ako bi postojala mogućnost brzih punjenja baterije tijekom voznog ciklusa (npr. u prodajnim centrima ili na javnim stanicama).

Za ispitivanje operativnih troškova EREV flote, koji osim troška goriva uključuju i trošak električne energije za punjenje baterija, korišten je novopredloženi agregatni model flote čije je punjenje optimirano korištenjem DP algoritma. Pored toga, izrađen je i model proizvodnje električne energije iz solarnih panela, te model potrošnje ostalih električnih potrošača u distributivnom centru na satnoj razini. Valja napomenuti da je agregatni model flote parametriran korištenjem snimljenih podataka vezanih uz razmatranu flotu i simulacijskih rezultata dostavnog EREV vozila. Optimiranje punjenja provedeno je za različite scenarije instalirane površine solarnih panela. Rezultati optimiranja pokazuju da se uvođenjem EREV vozila umjesto postojećih konvencionalnih vozila, operativni troškovi smanjuju za 13% kad

nema instaliranih solarnih panela, odnosno za 20% u slučaju pretpostavljenog punog kapaciteta instaliranih solarnih panela. Konačno, usporedno su ispitane i emisije CO₂ (od bušotine do kotača) dviju flota vozila za različite izvore električne energije koja se povlači iz mreže, koji obuhvaćaju elektrane koje kao gorivo koriste: a) ugljen, b) prirodni plin te c) nuklearnu energiju ili obnovljive izvore energije. U slučaju a), EREV flota generira 10-30% više CO₂ nego konvencionalna flota za $P_{cmax,ind} = 10$ kW. Povećavanjem površine instaliranih solarnih panela do maksimalnog kapaciteta, CO₂ emisije EREV flote smanjuju se i postaju usporedive s CO₂ emisijama konvencionalne flote u slučaju veće razmatrane maksimalne snage punjenja pojedinačnih vozila. U slučaju b), CO₂ emisije EREV flote smanjuju se u rasponu od 0-15% u odnosu na konvencionalnu flotu za čitav raspon instalirane površine solarnih panela, dok to smanjenje u slučaju c) iznosi oko 20%. Ovo bi dodatno bilo poboljšano ako bi se samo kraći ciklusi odrađivali s EREV vozilima, a ostali s konvencionalnim vozilima. Osim smanjenja CO₂ emisija, uvođenje EREV vozila bi imalo i povoljan efekt na smanjenje buke, te emisije ostalih štetnih plinova i čestica.

Na temelju izloženog, mogu se izdvojiti sljedeći znanstveni doprinosi doktorskog rada:

- Strategija upravljanja HEV/EREV pogonima temeljena na kombiniranju upravljanja zasnovanog na bazi pravila (RB) i trenutne minimizacije ekvivalentne potrošnje goriva (ECMS).
- Agregatni model flote EV koji vjerno opisuje dinamiku spajanja vozila na mrežu, te koji se parametrira korištenjem značajki voznih ciklusa.
- Algoritam optimiranja punjenja temeljen na agregatnom modelu flote EV te primjeni dinamičkog programiranja, te heuristički algoritam raspodjele agregatne snage punjenja na pojedinačne EV.

Literatura

1. R. Garcia-Valle and J. A. Pecas Lopes, “Electric Vehicle Integration into Modern Power Networks”, Springer, ISBN 978-1-4614-0134-6, 2013.
2. W. Kempton, J. Tomić, “Vehicle-to-grid power implementation: From stabilizing the grid to supporting large-scale renewable energy”, *Journal of Power Sources*, Vol. 144, No. 1, pp. 280-294, 2005.
3. O. Sundström, C. Binding, “Flexible Charging Optimization for Electric Vehicles Considering Distribution Grid Constraints”, *IEEE Transaction on Smart Grid*, Vol. 3, No. 1, pp. 26-37, 2012.
4. H. Lund, W. Kempton, “Integration of renewable energy into the transport and electricity sectors through V2G”, *Energy Policy*, Vol. 36, No. 9, pp. 3578-3587, 2008.
5. W. Kempton, J. Tomić, “Vehicle-to-grid power fundamentals: Calculating capacity and net revenue”, *Journal of Power Sources*, Vol. 144, No. 1, pp. 268–279, 2005.
6. J. Tomić, W. Kempton, “Using fleets of electric-drive vehicles for grid support”, *Journal of Power Sources*, Vol. 168, No. 2, pp. 459–468, 2007.
7. B. A. Davis, M. A. Figliozzi, “A Methodology to Evaluate the Competitiveness of Electric Delivery Trucks”, *Transportation Research Part E*, Vol. 49, No. 1, pp. 8–23, 2013.
8. S. Han, H. H. Soo, K. Sezaki, “Design of an optimal aggregator for vehicle-to-grid regulation service”, *Innovative Smart Grid Technologies Conference (ISGT 2010)*, Gaithersburg, MD, United States, 2010.
9. T. Lan, J. Hu, Q. Kang, C. Si, L. Wang, Q. Wu, “Optimal control of an electric vehicle's charging schedule under electricity markets”, *Neural Computing and Applications*, Vol. 23, No. 7-8, pp. 1865-1872, 2013.
10. J. Xu, V. W. S. Wong, “An approximate dynamic programming approach for coordinated charging control at vehicle-to-grid aggregator”, *IEEE 2nd International Conference on Smart Grid Communications, SmartGridComm 2011*, Brussels, Belgium, pp. 279-284, 2011.
11. G. Cardoso, M. Stadler, M. C. Bozchalui, R. Sharma, C. Marnay, A. Barbosa-Póvoa, P. Ferrão, “Optimal investment and scheduling of distributed energy resources with uncertainty in electric vehicle driving schedules”, *Energy*, Vol. 64, pp. 17-30, 2014.
12. N. Rotering, M. Ilic, “Optimal Charge Control of Plug-In Hybrid Electric Vehicles in Deregulated Electricity Markets”, *IEEE Transactions on Power Systems*, Vol. 26, No. 3, pp. 1021-1029, 2011.
13. P. Finn, C. Fitzpatrick, D. Connolly, “Demand side management of electric car charging: Benefits for consumer and grid”, *Energy*, Vol. 42, No. 1, pp. 358-363, 2012.

14. E. Sortomme, M. A. El-Sharkawi, "Optimal Scheduling of Vehicle-to-Grid Energy and Ancillary Services", *IEEE Transactions on Smart Grid*, Vol. 3, No. 1, pp. 351-359, 2012.
15. M. Pantoš, "Stochastic optimal charging of electric-drive vehicles with renewable energy", *Energy*, Vol. 36, No. 11, pp. 6567-6576, 2011.
16. L. Guzzella, Sciarretta A., "Vehicle Propulsion Systems - Introduction to Modeling and Optimization 2nd ed.", Berlin Heidelberg: Springer-Verlag, 2007.
17. A. Sciarretta, L. Guzzella, "Control of Hybrid Electric Vehicles", *IEEE Control Systems Magazine*, Vol. 27, No. 2, pp. 60-70, 2007.
18. Y. Gao, M. Ehsani, J. M. Miller, "Hybrid Electric Vehicle: Overview and state of the Art", *Proc. of IEEE Int. Symp. on Industrial Electronics*, pp. 307-315, Dubrovnik, Croatia, 2005.
19. A. Emadi, "Handbook of Automotive Power Electronics and Motor Drives", Illinois Institute of Technology Chicago, ISBN 0-8247-2361-9, 2005.
20. W. Liu, "Introduction to Hybrid Vehicle System Modeling and Control", John Wiley & Sons, Inc., Hoboken, NY, USA, 2013.
21. R. H. Staunton, C. W. Ayers, L. D. Marlino, J. N. Chiasson, T. A. Burrell, "Evaluation of 2004 Toyota Prius Hybrid Electric Drive System", Oak Ridge National Laboratory Report, #ORNL/TM-2006/423, 2005.
22. M. Duoba, H. Luhse-Busch, R. Carlson, T. Bohn, Gurski S., "Analysis of Power-Split Control Strategies Using Data from Several Vehicles", *SAE World Congress; Detroit, Michigan, United States; SAE paper 2007-01-0291*, 2007.
23. N. A. Windarko, J. Choi, "SOC estimation based on OCV for NiMH batteries using an improved takacs model", *Journal of Power Electronics*, Vol. 10, No. 2, pp. 181-186, 2010.
24. Y. Bin, Y. Li, N. Feng, "Nonlinear dynamic battery model with boundary and scanning hysteresis", *Proceedings of the ASME 2009 Dynamic Systems and Control Conference*, No. DSCC2009; Hollywood, California, USA; 2009.
25. G. Paganelli, Y. Guezennec, G. Rizzoni, "Optimizing Control Strategy for Hybrid Fuel Cell Vehicle", *SAE 2002 World Congress; Detroit, MI; United States; SAE paper 2002-01-0102*, 2002.
26. A. F. A. Serrarens, R. M. Van Druten, M. Steinbuch, "Rule-based energy management strategies for hybrid vehicle drivetrains: a fundamental approach in reducing the computation time", *4th IFAC symposium on mechatronic systems, Heidelberg, Germany*, Vol. 2, pp. 740-745, 2006.
27. T. Hofman, M. Steinbuch, R. M. Van Druten, A. F. A. Serrarens, "Rule-based energy management strategies for electric vehicles", *International Journal of Electric and Hybrid Vehicles*, Vol. 1, No. 1, pp. 71-94, 2007.
28. C. Musardo, G. Rizzoni, Y. Guezennec, B. Staccia, "A-ECMS: An Adaptive Algorithm for Hybrid Electric Vehicle Energy Management", *European Journal of Control*, Vol. 11, No. (4-5), pp. 509-524, 2005.

29. B. Škugor, M. Cipek, D. Pavković, J. Deur: “Design of a power-split hybrid electric vehicle control system utilizing a rule-based controller and an equivalent consumption minimization strategy”, Proceedings of the Institution of Mechanical Engineers, Part D, Journal of Automobile Engineering, Vol. 228, No. 6, pp. 631-648, 2014.
30. B. Škugor, J. Deur, “Instantaneous Optimization-based Energy Management Control Strategy for Range Extended Electric Vehicle”, SAE 2013 World Congress and Exhibition; Detroit, MI; United States; SAE paper 2013-01-1460, 2013.
31. R. Shankar, J. Marco, F. Assadian, “Design of an optimized charge-blended energy management strategy for a plugin hybrid vehicle”, Proceedings of the 2012 UKACC International Conference on Control, CONTROL 2012; Cardiff; United Kingdom; art. no. 6334701, pp. 619-624, 2012.
32. N. J. Schouten, M. A. Salman, N. A. Kheir, ”Energy management strategies for parallel hybrid vehicles using fuzzy logic”, Control Engineering Practice, No. 11, pp. 171–177, 2003.
33. C. Dextreit, F. Assadian, I. V. Kolmanovsky, “Hybrid electric vehicle energy management using game theory”, SAE World Congress; Detroit, MI; United States; SAE paper 2008-01-1317, 2008.
34. R. Johri, A. Salvi, Z. Filipi, “Optimal Energy Management for a Hybrid Vehicle Using Neuro-Dynamic Programming to Consider Transient Engine Operation”, Proceedings of 4th Annual Dynamic Systems and Control Conference, DSCC 2011; Arlington, VA; United States; Vol. 2, pp. 279-286, 2011.
35. R. Johri, Z. Filipi, “Self-Learning Neural controller for Hybrid Power Management using Neuro-Dynamic Programming”, SAE Technical Paper 2011-24-0081, presented at ICE2011 Conference, Capri, Italy, 2011.
36. B. M. Conlon, P. J. Savagian, A. G. Holmes and Jr. M. O. Harpster, “Output Split Electrically-Variable Transmission with Electric Propulsion using one or two Motors”, U.S. Patent No. 7 867 124, 2011.
37. M. A. Miller, A. G. Holmes, B. M. Conlon, P. J. Savagian, “The GM “Voltec” 4ET50 Multi-Mode Electric Transaxle”, SAE International Journal of Engines, Vol. 4, No. 1, pp. 1102-1114, 2011.
38. J. Deur, M. Cipek, B. Škugor, J. Petrić, “Modeling and Low-level Control of Range Extended Electric Vehicle Dynamics”, International Conference on Powertrain Modeling and Control (PMC 2012), Bradford, UK, 2012.
39. Q. Falières, O. Grasset, K. Roblet, Y. Xu, C. Noiret, L. Serrao, A. Sciarretta, “A contradictory analysis of GM Voltec powertrain”, The European Electric Vehicle Congress (EEVC-2011), Brussels, Belgium, 2011.
40. B. Škugor, M. Cipek, J. Deur, “Control Variables Optimization and Feedback Control Strategy Design for the Blended Operating Mode of an Extended Range Electric Vehicle”, SAE International Journal of Alternative Powertrains, SAE paper # 2014-01-1898, Vol. 3, No. 1, pp. 152-162., 2014.

41. L. Tribioli, S. Onori, "Analysis of energy management strategies in plug-in hybrid electric vehicles: Application to the GM Chevrolet Volt", Proceedings of the American Control Conference (ACC 2013); Washington, DC; United States; art. no. 6580774, pp. 5966-5971, 2013.
42. M. Sivertsson, "Adaptive control using map-based ECMS for a PHEV", IFAC Workshop on Engine and Powertrain Control, Simulation and Modelling (E-COSM 2012); Rueil-Malmaison; France; pp. 357-362, 2012.
43. M. Zhang, Y. Yang, C. Chunting, "Analytical Approach for the Power Management of Blended-Mode Plug-In Hybrid Electric Vehicles", IEEE Transactions on vehicular technology, Vol. 61, No. 4, pp. 1554-1566, 2012.
44. P. B. Sharer, A. Rousseau, D. Karbowski, S. Pagerit, "Plug-in hybrid electric vehicle control strategy: Comparison between EV and charge-depleting options", SAE World Congress; Detroit, MI; United States; 2008.
45. M. Cipek, M. Čorić, B. Škugor, J. Kasać, J. Deur, "Control Variable Optimization for an Extended Range Electric Vehicle", International Journal of Powertrains (IJPT), Vol. 5, No. 1, pp. 30-54, 2016.
46. B. Škugor, J. Deur, "Analysis of Techno-Economic Aspects of an Energy System Including Delivery Electric Vehicle Fleet and Renewable Energy Sources", SDEWES, Dubrovnik, Croatia, 2015.
47. M. Andre, "The ARTEMIS European driving cycles for measuring car pollutant emissions", Science of the Total Environment, Vol. 334-335, pp. 73-84, 2004.
48. G. Souffran, L. Miegerville, and P. Guerin, "Simulation of real-world vehicle missions using a stochastic markov model for optimal powertrain sizing", IEEE Transactions on Vehicular Technology, Vol. 61, No. 8, pp. 3454–3465, 2012.
49. M. Pourabdollah, A. Grauers, B. Egardt, "Effect of driving patterns on components sizing of a series PHEV", 7th IFAC Symposium on Advances in Automotive Control, Tokyo, Japan, 2013.
50. S. Zhang, R. Xiong, "Adaptive energy management of a plug-in hybrid electric based on driving pattern recognition and dynamic programming", Applied Energy, Vol. 55, pp. 68-78, 2015.
51. "EU CO2 Emission Standards for Passenger Cars and Light-Commercial Vehicles", Publication of International Council on Clean Transportation, 2014.
52. J. Barco, A. Guerra, L. Munoz, N. Quijano, "Optimal Routing and Scheduling of Charge for Electric Vehicles: Case Study", 2013.
53. T. K. Lee, Z. Filipi, "Synthesis of real-world driving cycles using stochastic process and statistical methodology", Int. J. Vehicle Design, Vol. 57, No. 1, pp. 17-36, 2011.
54. B. Škugor, J. Deur, "Delivery vehicle fleet data collection, analysis and naturalistic driving cycles synthesis", Int. J. of Innovation and Sustainable Development (IJISD), Vol. 10, No. 1, 19-39, 2016.

55. A. Gopal, L. Schewel, S. Saxena, A. Phadke, "The Transportation Leapfrog: Using Smart Phones to Collect Driving Data and Model Fuel Economy in India", Report, Berkeley National Lab, 2013.
56. T. K. Lee, Z. S. Filipi, "Response surface modeling approach for the assessment of the PHEV impact on the grid", 7th IEEE Vehicle Power and Propulsion Conference (VPPC), Chicago, IL, United States, 2011.
57. B. Škugor, J. Deur, "A bi-level optimisation framework for electric vehicle fleet charging management", *Applied Energy*, Vol. 184, pp. 1332-1342, 2016.
58. T. K. Lee, T. Gordon, Z. Filipi, "Stochastic Modeling for Studies of Real-World PHEV Usage: Driving Schedule and Daily Temporal Distributions", *IEEE Transactions on Vehicular Technology*, Vol. 61, No. 4, pp. 1493-1502, 2012.
59. B. Škugor, M. Hrgetić, J. Deur, "GPS measurement-based road grade reconstruction with application to electric vehicle simulation and analysis", SDEWES, Dubrovnik, Croatia, 2015.
60. J. Lin, D. A. Niemeier, "An exploratory analysis comparing a stochastic driving cycle to California's regulatory cycle", *Atmos. Environ.*, 36(38), 5759–5770, 2002.
61. P. Nyberg, "Evaluation, Generation, and Transformation of Driving Cycles", Doctoral dissertation, 2015.
62. B. Škugor, J. Deur, "Dynamic Programming-based Optimization of Electric Vehicle Fleet Charging", *IEEE International Electric Vehicle Conference (IEVC)*, Florence, Italy, 2014.
63. J. Zheng, W. Xiaoyu, M. Kun, Z. Chun, Z. Shouzhen, "Aggregation model-based optimization for electric vehicle charging strategy", *IEEE Transactions on Smart Grid*, Vol. 4, No. 2, pp. 1058-1066, 2013.
64. F. J. Soares, P. M. Rocha Almeida, J. A. Pecas Lopes, "Quasi-real-time management of Electric Vehicles charging", *Electric Power Systems Research*, Vol. 108, pp. 293–303, 2014.
65. B. Škugor, J. Deur, "Dynamic Programming-based Optimisation of Charging an Electric Vehicle Fleet System Represented by an Aggregate Battery Model", *Energy*, Vol. 92, No. 3, pp. 456-465, 2015.
66. B. Škugor, J. Deur, "A Novel Model of Electric Vehicle Fleet Aggregate Battery for Energy Planning Studies", *Energy*, Vol. 92, No. 3, pp. 444-455, 2015.
67. M. Cipek, B. Škugor, J. Deur, "Comparative Analysis of Conventional and Electric Delivery Vehicles Based on Realistic Driving Cycles", *European Electric Vehicle Congress (EEVC 2014)*, Brussels, Belgium, 2014.
68. T. K. Lee, B. Adornato, Z. Filipi, "Synthesis of Real-World Driving Cycles and Their Use for Estimating PHEV Energy Consumption and Charging Opportunities: Case Study for Midwest/U.S.", *IEEE Transactions on Vehicular Technology*, Vol. 60, No. 9, pp. 4153-4163, 2011.

69. R. E. Bellman, S. E. Dreyfus, "Applied Dynamic Programming", Princeton University Press, New Jersey, 1962.
70. J. M. Miller, "Hybrid electric vehicle propulsion system architectures of the e-CVT type", IEEE Transaction on Power Electronic, Vol. 21, No. 3, pp. 756–767, 2006.
71. L. Chen, F. Zhu, M. Zhang, Y. Huo, C. Yin and H. Peng, "Design and Analysis of an Electrical Variable Transmission for a Series-Parallel Hybrid Electric Vehicle", IEEE Transactions on vehicular technology, Vol. 60, No. 5, pp. 2354-2363, 2011.
72. M. Cipek, J. Deur and J. Petrić, "Bond Graph Modeling and Analysis of Series-Parallel Hybrid Electric Vehicle Transmissions", SAE paper No. 2010-01-1309, 2010.
73. M. Cipek, J. Deur, and J. Petrić, "Bond Graph Modeling and Power Flow Analysis of Series-Parallel HEV Transmissions", International Journal of Powertrains (IJPT), Vol. 1, No. 4, pp. 396-419, Inderscience Enterprises Ltd., 2012.
74. M. Cipek, "Modeliranje, analiza i optimalno upravljanje pogonima hibridnih električnih vozila", doktorska disertacija, 2015.
75. U. D. Grebe and L. T. Nitz, "VOLTEC – The propulsion system for Chevrolet Volt and Opel Ampera", ATZ autotechnology, 02/2011.
76. M. Cipek, D. Pavković, and J. Petrić, "A control-oriented simulation model of a power-split hybrid electric vehicle", Applied energy, Vol. 101, pp. 121–133, 2013.
77. J. Liu, H. Peng, "Modeling and Control of a Power-Split Hybrid Vehicle", IEEE Transactions on Control Systems Technology, Vol. 16, No. 6, pp. 1242-1251, 2008.
78. L. Trumm, "GM Li-Ion Battery Pack Manufacturing", 2011 DOE Hydrogen and Fuel Cells Program, and Vehicle Technologies Program Annual Merit Review and Peer Evaluation, General Motors LLC (GM), May 11, 2011, *PPT presentation*.
79. R. Parrish, K. Elankumaran, M. Gandhi, B. Nance, P. Meehan, D. Milburn, S. Siddiqui, and A. Brenz, "Voltec Battery Design and Manufacturing", SAE Technical Paper 2011-01-1360, 2011.
80. H. Hu, R. Smaling, S. J. Baseley, "Advanced Hybrid Powertrains for Commercial Vehicles", SAE Book, ISBN: 978-0-7680-3359-5, 2012.
81. U. Hoffmann, H. Hofmann, "Einführung in die Optimierung - mit Anwendungsbeispielen aus dem Chemie-Ingenieur-Wesen", Verlag Chemie, 1971.
82. E. D. Finkel, "DIRECT Optimization Algorithm User Guide", 2003.
83. R. Patil, B. Adornato, Z. Filipi, "Impact of Naturalistic Driving Patterns on PHEV Performance and System Design", SAE Paper No. 2009-01-2715, 2009.
84. M. Montazeri-Gh, A. Fotouhi, A. Naderpour, "Driving patterns clustering based on driving features analysis", Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2011., Vol. 225: 1301-1317
85. J. A. Gubner, "Probability and Random Processes for Electrical and Computer Engineers", Cambridge University Press, New York, 628 p, 2006.

86. C. M. Grinstead, J. L. Snell, "Introduction to Probability", University Press of Florida, September 1, 2009.
87. D. Dallinger, J. Link, M. Büttner, "Smart Grid Agent: Plug-in Electric Vehicle", IEEE Transactions on Sustainable Energy, Vol. 5, No. 3, 2014.
88. S. Martinenas, A. B. Pedersen, M. Marinelli, P. B. Andersen, C. Træholt, "Electric Vehicle Smart Charging using Dynamic Price Signal", IEEE International Electric Vehicle Conference (IEVC), Florence, Italy, 2014.
89. H. Lund, "EnergyPLAN, advanced energy systems analysis computer model", documentation version 11.1. 2013.
90. K. Deb, A. Pratap, S. Agarwal, T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II", IEEE Trans Evol Comput. 2002; 6(2):182–97.
91. MAN Catalogue, TGM 15.240 15 Tonne 4x2 BL Rigid, - 2014, <http://www.mantrucks.co/pdf/tgm/tgm-15t-4x2-rigid.pdf>
92. Z. Yuan, S.-H. Hou, D. Li, W. Gao, X. Hu, "Optimal Energy Control Strategy Design for a Hybrid Electric Vehicle", Discrete Dynamics in Nature and Society, Volume 2013, Article ID 132064, 2013.
93. Technical Data Book, Commercial Vehicle Tires, Continental Reifen Deutschland GmbH, - 2014, http://www.continental-truck-tires.com/www/download/transport_de_en/misc/tech_info/download/technical_data_book_pdf_en.pdf
94. EVO Electric Ltd Catalogue, AF-230 Motor/Generator – 2014, <http://www.evo-electric.com/inc/files/AF-230%20Spec%20Sheet%20V1.pdf>
95. H. Mettlach, "Development of the Li-Ion battery for the Opel Ampera Extended-Range Electric Vehicle", GM Alternative Propulsion Center - Europe Adam Opel GmbH, 3rd International Congress on Advanced battery Technology, Wiesbaden, 22nd June 2010, PPT
96. MAN Catalogue, D0836 6-cylinder in line engines for commercial vehicles – 2014, http://www.man.com.au/wp-content/uploads/download-manager-files/D0836_truck_engine_EN.pdf
97. ZF Friedrichshafen AG catalogue, Automatic transmission system for mid-range trucks, 12 AS 1420 TO, ZF-ASTronic mid (Truck) - 2014, http://www.zf.com/media/media/en/productfinder_media/trucks/trucks_driveline_astronic_mid/pdf_99/12_as_1420_to.pdf
98. T.J. Barlow, S. Latham, I.S. McCrae, P.G. Boulter, "A reference book of driving cycles for use in the measurement of road vehicle emissions", Published Project Report PPR354, Transport Research Laboratory TRL, 2009.
99. I. J. M. Besselink, P. F. van Oorschot, E. Meinders, H. Nijmeijer, "Design of an efficient, low weight battery electric vehicle based on a VW Lupo 3L", The 25th World Battery, Hybrid and Fuel Cell Electric Vehicle Symposium & Exhibition, EVS-25 Shenzhen, China, 2010.

Prilozi

Prilog A – Parametri pogona električnih vozila proširenog dometa (EREV)

A.1. Parametri pogona tipa Chevrolet Volt

Tablica A-1: Parametri EREV pogona tipa Chevrolet Volt.

R_{ic} [Ω]	R_{idc} [Ω]	Q_{max} [Ah]	m_v [kg]	g [m/s^2]	R_o [-]
0.056128	0.115904	45	1700	9.81	0.008
ρ_{air} [kg/m^3]	A_f [m^2]	C_d [-]	h [-]	i_o [-]	r [m]
1.225	2.22	0.275	2.24	2.16	0.317
K_{SoC} [W]	Δ_{SoC} [-]	$\omega_{mg1,max}$ [rad/s]	$\omega_{mg2,max}$ [rad/s]	$\omega_{e,min}$ [rad/s]	$\omega_{e,max}$ [rad/s]
$1.5 \cdot 10^5$	0.02	630	1044	0	523

Tablica A-2: Parametri varijabilne histereze (2-25) za različite vozne cikluse.

	N_{buffer} [-]	λ_L [Nm]	λ_U [Nm]	$\tau_{R,stdL}$ [Nm]	$\tau_{R,stdU}$ [Nm]
NEDC	26	30	70	0	300
HWFET	10	30	70	0	750
UDDS	54	30	70	0	300
US06	28	30	70	0	650

A.2. Parametri EREV pogona dostavnog vozila

Tablica A-3: Parametri EREV pogona dostavnog vozila.

$v_{v,max}$ [km/h]	r [m]	R_o [-]	g [m/s^2]	ρ_{air} [kg/m^3]	C_d [-]
90	0.388	0.012	9.81	1.225	0.63
i_o [-]	$\omega_{m,max}$ [rad/s]	$\tau_{m,max}$ [N]	h_{t1} [-]	h_{t2} [-]	A_f [m^2]
3.7	838	700	8.2	3.45	9.63
K_{SoC} [W]	Δ_{SoC} [-]	P_{off} [kW]	P_{on} [kW]	\bar{A}_{ek} [g/Ws]	b [-]
$9.5 \cdot 10^5$	0.01	0	10	$6.393 \cdot 10^{-5}$	50000

Prilog B – Nelinearni agregatni model flote električnih vozila

B.1. Nelinearni agregatni model baterije modelirane kao spremnik naboja

Nelinearni model individualne baterije j -tog vozila, modeliran kao spremnik naboja umjesto kao spremnik energije, može se izvesti iz modela nadomjesnog električnog kruga prikazanog na slici 2-6a. Konačna jednadžba stanja nelinearnog modela baterije dana je izrazom (2-3). Pritom se varijabla stanja u izrazu (2-3), koja predstavlja stanje napunjenosti baterije SoC , ovdje označava s SoC_j , a upravljačka varijabla P_{batt} (snaga punjenja/praznjenja baterije) s $P_{c,j}$, kako bi se varijable stanja i upravljačke varijable definirale za svako vozilo zasebno (indeks j označava indeks vozila). Napon otvorenog kruga U_{oc} (Slika 2-6b) i unutarnji otpor baterije (postavljen da ovisi samo o predznaku struje, iako tipično ovisi i o SoC-u) postavljen je na iste vrijednosti kao u odjeljku 2.1.3 (Chevrolet Volt baterija; vidi također prilog A.1). Valja podsjetiti da kod ovog modela baterije, pozitivne vrijednosti snage punjenja $P_{c,j}$ odgovaraju praznjenju baterije, dok negativne vrijednosti odgovaraju punjenju baterije (vidi izraz (2-3)).

Agregatni SoC računa se usrednjavanjem individualnih vrijednosti SoC-a svih vozila unutar flote:

$$SoC_{agg,ind}(t) \equiv \frac{1}{N_v} \sum_{j=1}^{N_v} SoC_j(t). \quad (B-1)$$

Indeks agg,ind označava da je ovaj agregatni SoC dobiven korištenjem vrijednosti SoC-a individualnih baterija.


Korištenjem jednadžbi (2-3) i (B-1) i Jensenove nejednakosti

$$\frac{f(x_1) + f(x_2) + \dots + f(x_N)}{N} \leq f\left(\frac{x_1 + x_2 + \dots + x_N}{N}\right), \quad (B-2)$$

gdje $f(\cdot)$ predstavlja bilo koju konkavnu funkciju, može se izvesti sljedeća relacija:

$$\begin{aligned} \dot{SoC}_{agg,ind}(t) &= \frac{1}{N_v} \sum_{j=1}^{N_v} \dot{SoC}_j(t) = \frac{1}{N_v} \sum_{j=1}^{N_v} \frac{\sqrt{U_{oc}^2 - 4RP_{c,j}(t)} - U_{oc}}{2Q_{max}R} \leq \\ &\frac{1}{2Q_{max}R} \left[\sqrt{U_{oc}^2 - \frac{4R}{N_v} \sum_{j=1}^{N_v} P_{c,j}(t)} - U_{oc} \right] \end{aligned} \quad (B-3)$$

Jensenova nejednakost vrijedi u ovom slučaju jer je funkcija na lijevoj strani nejednakosti (B-3) konkavna u odnosu na $P_{c,j}$, što se potvrđuje i grafički na slici B-1 (za potrebe izvoda agregatnog modela flote, pretpostavljene su konstantne vrijednosti U_{oc} i R).



Slika B-1: Grafička reprezentacija nelinearne jednadžbe stanja individualne baterije (2-3) – potvrda konkavnosti funkcije.

Jednakost se u izrazu (B-3) postiže u slučaju kad sve vrijednosti pojedinačnih snaga punjenja $P_{c,j}$ imaju iste vrijednosti (za slučaj pretpostavljenih konstantnih vrijednosti U_{oc} i R). Sumacijski izraz s lijeve strane nejednakosti (B-3) može se podijeliti u dva agregirana izraza, gdje prvi uključuje samo pozitivne pojedinačne snage baterija (pražnjenje), dok drugi uključuje samo negativne snage baterija (punjenje). Radi toga se i desna strana nejednakosti (B-3) može podijeliti u zasebne dijelove vezane uz punjenje i pražnjenje, što daje

$$\begin{aligned} \dot{SoC}_{agg,ind}(t) \cong \dot{SoC}_{agg,nlin}(t) &= \frac{1}{2Q_{max}} \cdot \left\{ \left[\sqrt{U_{oc}^2 - \kappa_p \frac{4R_{dch}}{N_v} P_{cp,agg}(t)} - U_{oc} \right] \frac{1}{R_{dch}} \right. \\ &\left. + \left[\sqrt{U_{oc}^2 - \kappa_n \frac{4R_{ch}}{N_v} P_{cn,agg}(t)} - U_{oc} \right] \frac{1}{R_{ch}} \right\} \end{aligned} \quad (B-4)$$

Ovdje, agregatna snaga $P_{cp,agg}$ označava sumu pozitivnih snaga (pražnjenje), dok agregatna snaga $P_{cn,agg}$ označava sumu negativnih snaga (punjenje):

$$P_{cp,agg}(t) = \sum_{j=1}^{N_v} P_{cp,j}(t), \begin{cases} P_{cp,j} = P_{c,j}, \text{ ako } P_{c,j} \geq 0 \\ P_{cp,j} = 0, \text{ u protivnom} \end{cases} \quad (B-5)$$

$$P_{cn,agg}(t) = \sum_{j=1}^{N_v} P_{cn,j}(t), \begin{cases} P_{cn,j} = P_{c,j}, \text{ ako } P_{c,j} < 0 \\ P_{cn,j} = 0, \text{ u protivnom} \end{cases}$$

Motivacija za podjelu desne strane izraza (B-3) na dijelove vezane uz punjenje i pražnjenje je povećanje točnosti agregatnog modela baterije i omogućavanje uključanja zasebnih vrijednosti unutarnjih otpora baterije prilikom punjenja R_{ch} , odnosno prilikom pražnjenja baterije R_{dch} .

Desna strana izraza (B-4) predstavlja jednadžbu stanja nelinearnog modela agregatne baterije, čija je varijabla stanja označena sa $SoC_{agg,nlin}$. Empirijski faktori κ_p i κ_n dodani su u izraz (B-4) kako bi se polazna nejednakost (B-3) pretvorila u jednakost, odnosno kako bi se težilo izjednačenju vrijednosti agregatne varijable stanja $SoC_{agg,nlin}$ sa stvarnom varijablom stanja ($SoC_{agg,ind}$) dobivenom usrednjavanjem varijabli stanja individualnih baterija (vidi izraz (B-1)).

B.2. Validacija nelinearnog modela agregatne baterije

B.2.1. Optimiranje empirijskih faktora nelinearnog modela baterije κ_p i κ_n

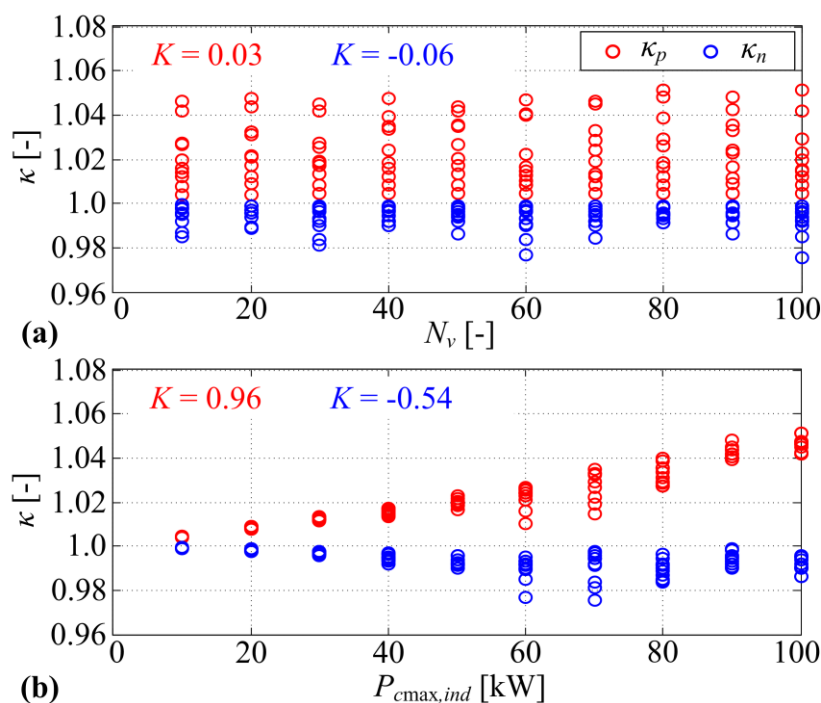
Vremenski kontinuirane jednadžbe (2-3) i (B-4) su diskretizirane i faktori κ_p i κ_n su numerički optimirani s ciljem minimizacije kumulativne razlike između $SoC_{agg,ind}$ i $SoC_{agg,nlin}$ trajektorija

$$J = \sum_{k=0}^{N_t-1} |SoC_{agg,ind}(k) - SoC_{agg,nlin}(k)|. \quad (B-6)$$

Analizom jednadžbe (B-4), može se vidjeti da ograničenja $\kappa_p \geq 1$ i $\kappa_n \leq 1$ moraju biti zadovoljena kako bi se minimizirala kriterijska funkcija (B-6). Ovaj uvid sužava područje pretraživanja optimalnih parametara κ_p i κ_n i tako pojednostavljuje optimiranje. Optimiranja su provedena iterativno korištenjem *simplex* optimizacijskog algoritma (Matlab funkcija *fminsearch*). U svakoj iteraciji optimiranja, snage punjenja individualnih baterija generirane

su slučajno za svako vozilo u svakom diskretnom vremenskom koraku, iz intervala $[-P_{cmax,ind}, P_{cmax,ind}]$, korištenjem uniformnog generatora slučajnih brojeva. Ovo rezultira s κ_p i κ_n vrijednostima koje su optimalne u prosječnom smislu za odgovarajuće razdiobe snaga punjenja baterija. Jedinične vrijednosti su korištene kao početna rješenja za parametre κ_p i κ_n . Pritom se koristi korak diskretizacije od 1 s ($\Delta T=1s$).


Optimiranja parametara κ_p i κ_n provedena su za različit broj vozila unutar flote ($N \in [10, 20, \dots, 100]$) i različite vrijednosti maksimalne snage punjenja individualne baterije ($P_{cmax,ind} \in [10, 20, \dots, 100]$ kW). Pritom je broj vremenskih koraka N_t postavljen u 1000, dok je početni SoC svakog vozila postavljen u 0.5 ($SoC_{init}=0.5$). Napon otvorenog kruga fiksiran je na $U_{oc}(SoC_{init})$ (vidi sliku 2-6b). Optimirane vrijednosti faktora κ_p i κ_n prikazane su na slici B-2 u ovisnosti o vrijednosti parametara N_v (Slika B-2a) i $P_{cmax,ind}$ (Slika B-2b). Ovi rezultati ukazuju na to da optimalne vrijednosti parametara κ_p i κ_n nisu korelirane s brojem vozila N_v , dok su vidno korelirane s maksimalnom snagom punjenja $P_{cmax,ind}$. Ovo je potvrđeno i korelacijskim indeksima K definiranim u prilogu D i računatim korištenjem primjenim



Slika B-2: Optimirane vrijednosti κ -faktora za različit broj vozila N_v u floti i različite vrijednosti maksimalne snage punjenja individualnih baterija $P_{cmax,ind}$ (K – korelacijski indeksi).

MATLAB funkcije *corrcoef* (npr. $K=0.03$ na slici B-2a predstavlja korelacijski indeks κ_p i N_v vektora), gdje $K \approx 0$ odgovara slučaju kada ne postoji korelacija među ulaznim vektorima, dok vrijednosti K koje se približavaju vrijednostima 1 i -1 označavaju redom jaku korelaciju odnosno anti-korelaciju.


Slično, optimiranja κ -faktora također su provedena za različite kombinacije početnih vrijednosti SoC-a ($SoC_{init} \in [0.05, 0.2, \dots, 0.95]$) i maksimalne snage punjenja ($P_{cmax,ind} \in [10, 20, \dots, 100]$ kW). Pritom je broj vozila postavljen u konstantnu vrijednost jednaku 10 ($N_v = 10$). Rezultati prikazani na slici B-3a pokazuju da za razliku od parametra broja vozila N_v , između κ parametara i početnog SoC-a SoC_{init} postoji slaba korelacija (Slika B-3a). Ovo se može pripisati različitim vrijednostima napona otvorenog kruga U_{oc} za različite vrijednosti SoC_{init} koje značajno utječu na korisnost baterije. Slika B-3b ukazuje na to da su parametri κ_p i κ_n i u ovom slučaju jako korelirani s maksimalnom snagom punjenja.



Slika B-3: Optimirane vrijednosti κ -faktora parametara za različite početne vrijednosti SoC-a (SoC_{init}) i maksimalne snage punjenja $P_{cmax,ind}$ (K – korelacijski indeks).

Daljnja optimiranja i analize provedeni su kako bi se istražila ovisnost parametara κ_p i κ_n o srednjim vrijednostima ($P_{c,mean}$) i standardnim devijacijama ($P_{c,std}$) individualnih snaga punjenja, pri konstantnim vrijednostima početnog SoC-a i broja vozila ($SoC_{init}=0.5$, $N_v=100$).

Broj vremenskih koraka N_t postavljen je u 100. Individualne snage punjenja generirane su slučajno iz Gaussove razdiobe $G(P_{c,mean}, P_{c,std})$ u svakom diskretnom vremenskom trenutku za svako vozilo. Optimalne vrijednosti parametra κ_p dobivene su za slučaj $P_{c,mean} > 0$, dok su optimalne vrijednosti parametra κ_n dobivene u slučaju $P_{c,mean} < 0$. Rezultati optimiranja prikazani na slici B-4 otkrivaju da su parametri κ_p i κ_n jako ovisni i o srednjoj vrijednosti ($P_{c,mean}$) i standardnoj devijaciji ($P_{c,std}$) individualne snage punjenja. Također, u slučaju $P_{c,std} = 0$, kad su vrijednosti snaga punjenja za sva vozila jednaki, parametri κ_p i κ_n poprimaju vrijednosti 1.



Slika B-4: Ovisnost κ -faktora o srednjim vrijednostima i standardnim devijacijama individualnih snaga punjenja.

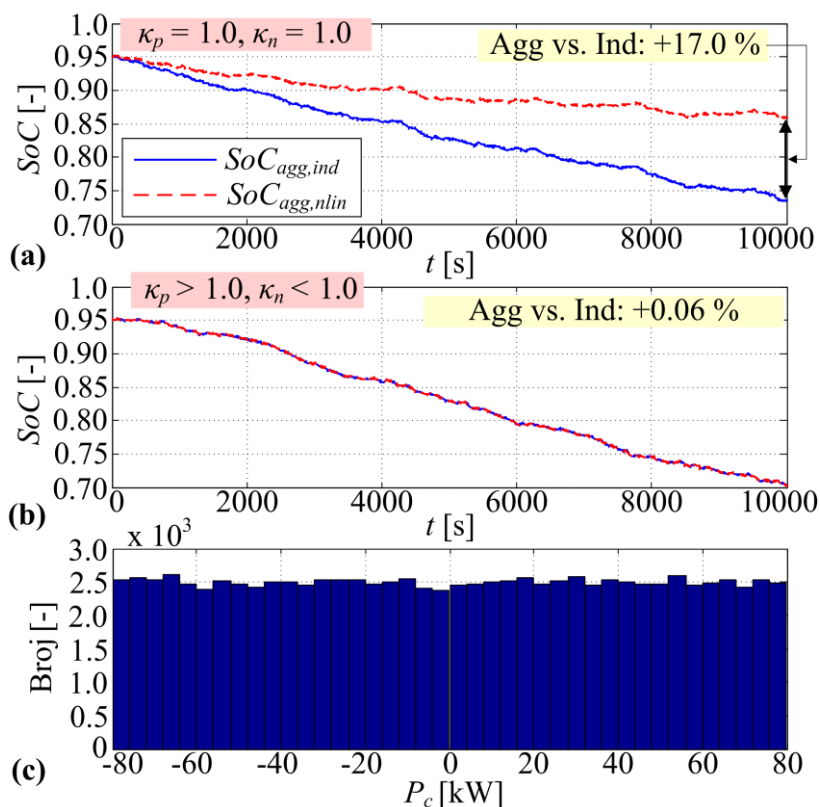
Konačno, kako optimalne vrijednosti κ_p i κ_n parametara ne ovise o broju vozila N_v , nelinearni model agregatne baterije (B-4) parametriran je samo u ovisnosti o $P_{c,max,ind}$ i SoC vrijednostima. Stvarne vrijednosti $P_{c,max,ind}$ i SoC-a zaokružuju se na najbliže vrijednosti za koje su optimiranja κ parametara provedena i odabiru se odgovarajuće vrijednosti κ_p i κ_n parametara.

B.2.2. Validacija modela

Kako bi se validirao nelinearni agregatni model baterije (B-4) (uključujući optimirane κ -faktore), individualne snage punjenja generirane su slučajno na diskretnom vremenskom horizontu $N_t = 10000$ ($\Delta T = 1$ s) za svako EV na sličan način kao i kod optimiranja κ parametara. Broj vozila postavljen je na vrijednost 10 ($N_v = 10$), a početne vrijednosti SoC-a u 0.95 ($SoC_{init} = 0.95$). Uniformna raspodjela individualnih snaga punjenja u rasponu od -80 kW do 80 kW, za koje je

model baterije validiran, prikazan je na slici B-5c. Sada je napon otvorenog kruga baterije U_{oc} postavljen da bude ovisan o SoC-u (vidi sliku 2-6b) i za individualni i za agregatni model baterije, dok je unutarnji otpor baterije postavljen da bude ovisan samo o predznaku struje ($R_{ch} = 0.056 \Omega$, $R_{dch} = 0.115 \Omega$).


Koristeći generirane profile individualnih snaga punjenja i jednadžbe (2-3), (B-1) i (B-4), $SoC_{agg,nlin}$ i $SoC_{agg,ind}$ trajektorije mogu biti rekonstruirane korištenjem vremenski diskretne relacije: $SoC(k+1) = SoC(k) + (dSoC/dt)\Delta T$. Slika B-5a prikazuje rekonstruirane SoC trajektorije za slučaj korištenja jediničnih vrijednosti za parametre κ_p i κ_n , dok slika B-5b ilustrira značajno unaprijeđenje u točnosti modela u slučaju kad se koriste optimirane vrijednosti parametara κ_p i κ_n (odstupanje konačne vrijednosti SoC-a od +0.06% u odnosu na +17%). Valja napomenuti, da, iako postoji uravnoteženost između snaga punjenja i pražnjenja (Slika B-5c), SoC trajektorije postupno padaju zbog gubitaka u bateriji koji su prisutni i kod




Slika B-5: Usporedba agregatnih SoC trajektorija više-agentskog i nelinearnog modela baterije za neoptimirane (a) i optimirane κ vrijednosti (b), za slučaj uniformno distribuiranih individualnih snaga punjenja (c).

punjenja i kod pražnjenja baterija.

Odlično poklapanje dviju SoC trajektorija prikazanih na slici B-5b je očekivano jer su κ parametri optimirani za konkretan slučaj uniformne razdiobe individualnih snaga punjenja. Međutim, u stvarnosti ovo ne treba biti ispunjeno s obzirom da se EV unutar flote mogu puniti/prazniti s drugačijim profilima snage, npr. fiksnim iznosima snaga. Stoga je agregatni nelinearni model baterije dodatno validiran za slučajeve: (a) fiksnih iznosa snaga punjenja/pražnjenja (Slika B-6) i (b) iznosa snaga punjenja/pražnjenja generiranih iz normalne razdiobe (Slika B-7). Pritom se u slučaju a) fiksni iznos snage baterije odabire slučajno na način da svi postavljeni iznosi imaju jednaku vjerojatnost odabira. U slučaju b), s s jednakom vjerojatnošću se odabire predznak snage baterije (lijeva ili desna normalna razdioba na slici B-7c), pa se potom iz pripadne normalne razdiobe generira snaga baterije.



Slika B-6: Usporedba SoC trajektorija za neoptimirane (a) i optimirane κ vrijednosti (b) za slučaj slučajno odabiranih fiksnih diskretnih razina snaga punjenja/pražnjenja baterija (c).



Slika B-7: Usporedba SoC trajektorija za neoptimirane (a) i optimirane κ vrijednosti (b) u slučaju normalno distribuiranih vrijednosti snaga punjenja/pražnjenja (c).

Iz rezultata prikazanih na slikama B-6 i B-7 može se zamijetiti da u oba slučaja korištenje optimiranih κ parametara značajno unapređuje točnost u usporedbi sa slučajevima kad se koriste jedinične vrijednosti κ parametara, odnosno odstupanje konačnih vrijednosti SoC-a bitno se smanjuje u oba slučaja: (a) +0.9% u odnosu na +10.5% (Slika B-6) i (ii) +2.7% u odnosu na +10.5% (Slika B-7). Ovo je očekivano nešto lošije u odnosu na validacijske rezultate prikazane na slici B-5b (odstupanja od +0.9% i +2.7% u odnosu na +0.06%), zato što κ parametri nisu optimirani za korištene razdiobe snaga punjenja/pražnjenja. Usprkos tome, ovi rezultati se mogu smatrati zadovoljavajućim, tj. opravdavaju korištenje nelinearnog agregatnog modela baterije čak i uz „grubo“ podešene κ parametre (Slika B-3).

Korisnost individualnih baterija pri punjenju ($\eta_{ch,ind}$) i pražnjenju ($\eta_{dch,ind}$) izračunate su na temelju iznosa struje dobivenog iz snage baterije P_c kroz jednadžbu $P_{c,j} = U_{oc}(SoC_j) \cdot i(t) - R(SoC_j, i) \cdot i^2(t)$ kako slijedi:

$$\eta_{dch,ind} = \frac{P_c \Delta T}{P_c \Delta T + i^2 R_{dch}}, \text{ za } P_c > 0$$

$$\eta_{ch,ind} = \frac{|P_c| \Delta T - i^2 R_{ch}}{|P_c| \Delta T}, \text{ za } P_c < 0$$
(B-7)


gdje izrazi $i^2 R_{dch}$ i $i^2 R_{ch}$ predstavljaju energiju gubitaka u bateriji. Korisnosti agregatne baterije izračunate su iz agregatnih snaga i derivacija SoC-a na sljedeći način

$$\eta_{dch,agg} = \frac{P_{cp,agg}}{N_v \cdot Q_{max} \cdot U_{oc}(SoC_{agg,nlin}) \cdot \dot{SoC}_{agg,nlin}}$$

$$\eta_{ch,agg} = \frac{N_v \cdot Q_{max} \cdot U_{oc}(SoC_{agg,nlin}) \cdot \dot{SoC}_{agg,nlin}}{|P_{cn,agg}|}$$
(B-8)

gdje $P_{cp,agg}$ i $P_{cn,agg}$ predstavljaju pozitivnu (pražnjenje) odnosno negativnu (punjenje) snagu agregatne baterije (vidi jednadžbu (B-5)), dok $dSoC_{aggp,nlin}/dt$ i $dSoC_{agg,nlin}/dt$ predstavljaju derivacije SoC-a uzrokovane snagama $P_{cp,agg}$ i $P_{cn,agg}$ (vidi desnu stranu jednadžbe (B-4)).

Slika B-8 prikazuje dobro poklapanje individualnih i agregatnih korisnosti punjenja/pražnjenja u ovisnosti o individualnoj snazi baterije ($|P_{c,j}| = P_{c,ind}$ za svaki $j \in N$). Pritom se može zamijetiti lagano odstupanje agregatne korisnosti od individualne korisnosti u slučaju punjenja u rasponu snaga baterije od 80 do 100 kW. Korisnosti padaju s povećanjem



Slika B-8: Usporedni prikaz individualnih i agregatnih korisnosti punjenja i pražnjenja baterije u funkciji snage punjenja individualnih baterija ($\eta_{ch,ind,mean} = 0.98$, $\eta_{dch,ind,mean} = 0.95$).

individualne snage punjenja $P_{c,ind}$, jer gubitci u bateriji rastu kvadratno u ovisnosti o struji koja je proporcionalna snazi punjenja.

Nadalje, nelinearni modeli baterija uspoređeni su s linearnim agregatnim modelom koji se uobičajeno koristi u različitim studijama vezanima uz električna vozila. Linearni model koji se koristi ovdje temelji se na naprednom agregatnom modelu baterije koji je definiran jednadžbom (4-4), gdje su za potrebe usporednih analiza zanemareni dijelovi vezani uz vozila koja se spajaju na mrežu i koja se odspajaju s mreže. Također, model (4-4) proširen je kako bi se omogućio dvosmjernan tok snage (iz mreže u EV i obrnuto) i prilagođen kako bi negativni iznosi snaga odgovali punjenju baterije, te pozitivni iznosi snaga pražnjenju baterije što je slučaj kod nelinearnog modela baterije (2-3). Ovo rezultira sljedećom vremenski diskretnom jednadžbom stanja:


$$SoC_{agg,lin}(k+1) = SoC_{agg,lin}(k) + \eta_{ch} \frac{|P_{cn,agg}(k)| \Delta T}{E_{max,agg}} - \frac{P_{cp,agg}(k) \Delta T}{\eta_{dch} E_{max,agg}}. \quad (B-9)$$

Pritom se konstantne korisnosti punjenja i pražnjenja linearnog modela postavljaju u vrijednosti jednake srednjim vrijednostima korisnosti nelinearnog individualnog modela baterije ($\eta_{ch} = 0.98$, $\eta_{dch} = 0.95$; vidi sliku B-8).


Slika B-9 prikazuje da u slučaju korištenja linearnog modela (s konstantnim korisnostima), SoC trajektorije linearnog modela ($SoC_{agg,lin}$) počinju značajno odstupati od SoC trajektorija nelinearnog modela baterije (s inherentno varijabilnim korisnostima), tj. odstupanje konačnog SoC-a je u rasponu od -4% do -10% za razdiobu individualnih snaga punjenja generiranih na sličan način kao i u slučaju rezultata danih na slikama B-5, B-6 i B-7.

Daljna usporedba konačnih vrijednosti SoC-a dobivenih korištenjem agregatnog nelinearnog modela baterije (B-4) i agregatnog linearnog modela (B-9) u odnosu na konačni SoC predviđen više-agentskim nelinearnim modelom (B-1) provedena je za različite raspone uniformnih razdioba snaga baterije u rasponu $[-P_{cmax,ind}, P_{cmax,ind}]$. Ovi rezultati prikazani su na slici B-10 i ukazuju da su odstupanja konačnih vrijednosti SoC-a za linearni agregatni model u rasponu od -8% do 6%, dok su ta odstupanja zanemariva u slučaju nelinearnog agregatnog modela baterije. Ovo dodatno potvrđuje značajno unaprijeđenu točnost predloženog nelinearnog agregatnog modela baterije koji predstavlja spremnik naboja u

odnosu na linearni agregatni model koji predstavlja spremnik energije.



Slika B-9: Usporedba SoC trajektorija za slučaj linearnih i nelinearnih modela agregatne baterije za uniformno generirane (a), slučajno odabrane diskretne (b) i normalno distribuirane (c) individualne snage punjenja.



Slika B-10: Usporedba odstupanja konačnih vrijednosti SoC-a agregatnog linearnog i nelinearnog modela u odnosu na konačne vrijednosti agregatnog SoC-a realnog više-agentskog modela baterija flote EV.

Prilog C – Detalji vezani uz računanje limita energije punjenja pojedinačnih vozila

Ostvariv gornji limit na energiju punjenja, dan izrazom (4-16), dobiven je korištenjem jednadžbe stanja pojedinačne baterije (4-6a), pri čemu je vrijednost SoC-a u narednom diskretnom vremenskom trenutku, $SoC_j(k+1)$, ograničena na maksimalnu vrijednost 1:

$$SoC_j(k) - \Delta SoC_j(k) + \eta_{ch} \frac{E_{c,j}(k)}{E_{max,ind}} = 1. \quad (C-1)$$

Iz jednadžbe (C-1) slijedi jednadžba (4-16), pri čemu se $\Delta SoC_j(k)$ računa prema izrazu (4-6b).

Kako bi se izračunao donji limit na energiju punjenja j -tog vozila u diskretnom vremenskom trenutku k , a vezano uz izbjegavanje kršenja ograničenja SoC-a vozila na odlasku (4-12), ponovno se koristi jednadžba (4-6a), uz $SoC_j(k_f) = 1$, te modificira kako slijedi:

$$SoC_j(k) - \Delta SoC_j(k) + \eta_{ch} \frac{P_{cmin,j}(k)t_{c1,j}(k) + P_{cmax,ind}(t_{c2,j}(k) - t_{c1,j}(k))}{E_{max,ind}} = 1, \quad (C-2)$$

gdje se donji limit snage punjenja $P_{cmin,j}(k)$ u trenutnom diskretnom vremenskom koraku k (vremenski period $t_{c1,j}$) računa temeljem pretpostavke granično ostvarivog scenarija da će snaga punjenja j -te baterije imati maksimalnu moguću vrijednost $P_{cmax,ind}$ u svim preostalim koracima prije planiranog odlaska vozila (vremenski period $t_{c2,j} - t_{c1,j}$; vidi ilustraciju na slici 4-6). Izvlačenjem $P_{cmin,j}(k)$ iz jednadžbe (C-2) dobiva se jednadžba (4-19).

Ako bi dobiveni donji limit snage punjenja $P_{c,j}$ j -tog vozila bio veći od maksimalne dozvoljene snage punjenja $P_{cmax,ind}$ (specijalan (donji) slučaj u jednadžbi (4-18)), tada će j -ta baterija biti punjena konstantnom snagom $P_{c,j}$ u svim koracima do odlaska, a koja će omogućiti zadovoljavanje uvjeta (4-12) da SoC vozila na odlasku bude 1. Umetanjem $E_{c,j}(k) = P_{c,j}(k)t_{c2,j}(k)$ u jednadžbu (C-1) i preuređenjem dobiva se zahtijevana konstantna snaga punjenja

$$P_{cmin,j} = (1 + \Delta SoC_j(k) - SoC_j(k)) \frac{E_{max,ind}}{\eta_{ch} t_{c2,j}(k)}. \quad (C-3)$$

Korištenjem jednadžbe (C-3) i relacije $E_{cmin,j}(k) = t_{c1,j}(k)P_{cmin,j}$ (vidi izraz (4-18)), dobiva se konačni izraz za minimalnu energiju punjenja, dan kao specijalni slučaj u jednadžbi (4-18).

Prilog D – Definicija korelacijskog pokazatelja

Mjera sličnosti dva vektora \mathbf{x} i \mathbf{y} , oba duljine N , opisana je korelacijskim pokazateljem

$$K_{\mathbf{x},\mathbf{y}} = \text{cov}(\mathbf{x},\mathbf{y})/(\sigma_{\mathbf{x}}\sigma_{\mathbf{y}}), \quad (\text{D-1})$$

koji poprima vrijednosti u intervalu $[-1,1]$, gdje su kovarijanca $\text{cov}(\mathbf{x},\mathbf{y})$ i standardna devijacija $\sigma_{\mathbf{x}}$ (i slično $\sigma_{\mathbf{y}}$) definirane kako slijedi

$$\text{cov}(\mathbf{x},\mathbf{y}) = \frac{\sum_{i=1}^N (x_i - \bar{\mathbf{x}})(y_i - \bar{\mathbf{y}})}{N-1}, \quad (\text{D-2})$$

$$\sigma_{\mathbf{x}} = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{\mathbf{x}})^2}{N-1}}. \quad (\text{D-3})$$

Pritom, $\bar{\mathbf{x}}$ i $\bar{\mathbf{y}}$ označavaju srednje vrijednosti vektora \mathbf{x} i \mathbf{y} , a N broj njegovih elemenata. Za jednake ulazne signale/vektore (puna sličnost) korelacijski pokazatelj $K_{\mathbf{x},\mathbf{y}}$ poprima vrijednost 1. Za slučaj kad je $K_{\mathbf{x},\mathbf{y}} = 0$, među ulaznim signalima ne postoji korelacija, dok za slučaj $K_{\mathbf{x},\mathbf{y}} = -1$ među ulaznim signalima postoji potpuna antikorelacija (npr. dva sinusna signala koji su u fazi međusobno razmaknuti za 180°). U Matlabu se korelacija dvaju signala/vektora računa korištenjem funkcije *corrcoef*.

Prilog E – Generiranje ulaznih razdioba modela flote EV korištenjem Monte Carlo postupka


Kako bi se provela dodatna validacija izvedenih modela flote EV danih u poglavlju 4 (vidi odjeljak 4.4.2), generiraju se nove ulazne razdiobe pripadnih modela korištenjem Monte Carlo postupka temeljem snimljenih podataka opisanih u poglavlju 3.

Prvo, vremenski trenutci vezani uz dolaske ($t_{in,DC,i}$) i odlaske ($t_{out,DC,i}$) iz distributivnog centra (indeks i označava vozni ciklus; vidi sliku E-1) izvlače se iz skupa snimljenih podataka i preračunavaju se s tromjesečnog perioda (91 dan) i sekundne vremenske baze na 24-satni period i 15-minutnu vremensku bazu na sljedeći način:

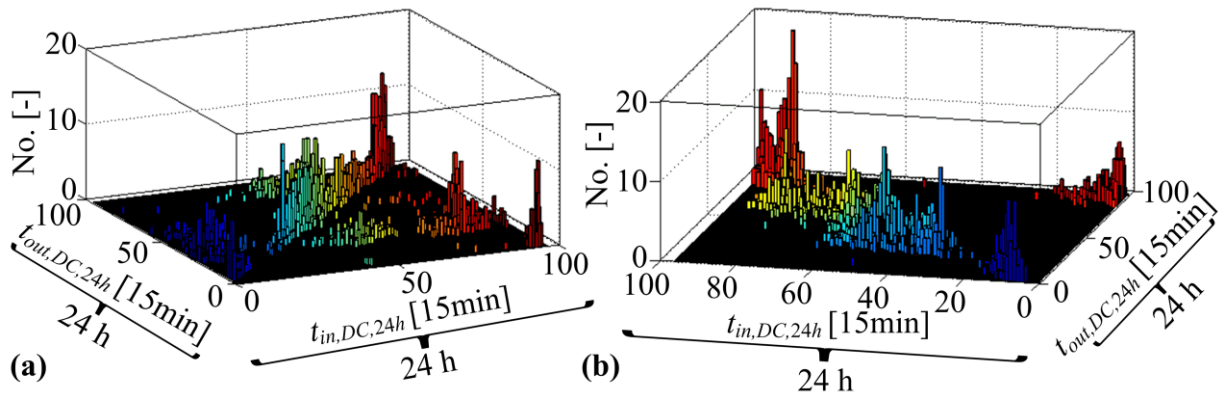
$$t_{in,DC,i,24h} = \left(\left\lfloor \frac{t_{in,DC,i}}{900} \right\rfloor + 1 \right) \text{ mod } 96, \quad \text{zasvaki } i, \quad (\text{E-1a})$$

$$t_{out,DC,i,24h} = \left(\left\lfloor \frac{t_{out,DC,i}}{900} \right\rfloor + 1 \right) \text{ mod } 96, \quad \text{zasvaki } i, \quad (\text{E-1b})$$

gdje faktor 900 označava broj sekundi unutar perioda od 15 minuta, faktor 96 broj perioda od 15 minuta unutar 24h, a *mod* predstavlja operator koji rezultira ostatkom cjelobrojnog dijeljenja. Potom se parovi ($t_{in,DC,i-1,24h}$, $t_{out,DC,i,24h}$) i ($t_{out,DC,i,24h}$, $t_{in,DC,i,24h}$) prebrojavaju i mapiraju u 3D koordinatne sustave (vidi sliku E-2).



Slika E-1: Ilustracija dolazaka i odlazaka iz distributivnog centra (DC) (i indeks označava i -ti vozni ciklus).



Slika E-2: Razdiobe prebrojanih parova dolazaka i odlazaka iz distributivnog centra ($t_{in,DC,i-1}$, $t_{out,DC,i}$) (a), te parova odlazaka i dolazaka u distributivni centar ($t_{out,DC,i}$, $t_{in,DC,i}$) (b) preračunatih s tromjesečnog perioda (91 dan) na 24-satni period uz 15-minutnu vremensku bazu.

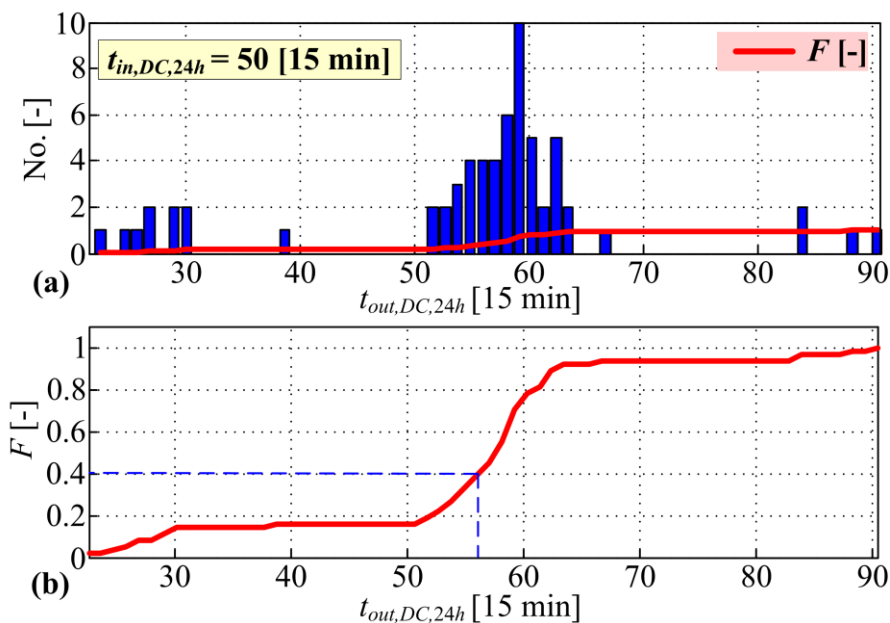
Na temelju prebrojanih parova dolasci-odlasci (Slika E-2a) i odlasci-dolasci (Slika E-2b) i generatora slučajnih brojeva, moguće je generirati nove sekvence vremena dolazaka i odlazaka vozila iz distributivnog centra. Primjerice, na slici E-3 prikazan je broj odlazaka iz distributivnog centra u trenutcima $t_{out,DC,24h}$, u slučaju da je vozilo u $t_{in,DC,24h} = 50$ diskretnom vremenskom trenutku ušlo u distributivni centar. Valja podsjetiti da su podaci sa slike E-3a izvučeni iz matrice prikazane na slici E-2a za konkretan slučaj $t_{in,DC,24h} = 50$ (podaci u 50. retku u matrici). Na slici E-3 također je prikazana kumulativna funkcija broja odlazaka iz distributivnog centra u ovisnosti o vremenu $t_{out,DC,24h}$, koja je dodatno normirana kako bi zadovoljila uvjete na funkciju distribucije slučajne varijable, a koja se definira kako slijedi:

$$F(x) \equiv P(X \leq x) = \int_{-\infty}^x f(t)dt, \quad x \in R, \quad (E-2)$$

i za koju treba biti zadovoljeno $F(-\infty) \equiv 0$, te $F(+\infty) \equiv 1$ (vidi sliku E-3b). Pritom X predstavlja neku slučajnu varijablu, t predstavlja pomoćnu varijablu, a f funkciju gustoće vjerojatnosti slučajne varijable. Odlazak iz distributivnog centra, za neki vozni ciklus i , odabire se potom na temelju broja y , koji se generira slučajno korištenjem uniformne razdiobe vjerojatnosti u intervalu $[0,1]$, kako slijedi (vidi primjer predstavljen plavom crtkanom linijom na slici E-3b gdje je $y=0.4$):

$$t_{out,DC,i,24h} = F^{-1}(y). \quad (E-3)$$

Na sličan način se, u ovom radu, odabiru nova stanja Markovljevog lanca kod sinteze voznih ciklusa (vidi odjeljak 3.2.3).



Slika E-3: Razdioba broja snimljenih odlazaka iz distributivnog centra (a), te funkcija distribucije vjerojatnosti (F) odlaska iz distributivnog centra (b), za slučaj $t_{in,DC,24h} = 50$.

Postupak generiranja novih sekvenci dolazaka i odlazaka za neko vozilo na predefiniranom vremenskom periodu i na sekundnoj vremenskoj bazi (ovdje 1 mjesec = $30 \cdot 24 \cdot 3600$ s) počinje tako da se pretpostavi da za svako vozilo vrijedi $t_{in,DC,0} = 1$ [s], $t_{in,DC,0,24h} = 1$ [15min] (gdje 0 odgovara periodu prije prvog voznog ciklusa), tj. da je vozilo došlo u distributivni centar u početnom trenutku. Tada se vrijednost pomoćne varijable $*t_{out,DC,1}$ (vrijeme odlaska na sekundnoj bazi u 24-satnom periodu) dobiva slučajno na temelju funkcije distribucije vjerojatnosti dobivene iz prebrojanih parova ($t_{in,DC,i-1,24h}$, $t_{out,DC,i,24h}$) uz uvjet $t_{in,DC,0,24h} = 1$ (na isti način kako je ilustrirano na slici E-3b). Stvarno vrijeme odlaska $t_{out,DC,1}$ (početak 1. voznog ciklusa) tada se dobije iz $*t_{out,DC,1}$ korištenjem sljedeće jednadžbe (definirane za neki opći vozni ciklus i):

$$t_{out,DC,i} = 24 \cdot 3600 \cdot n_{DAN,i} + *t_{out,DC,i}, \quad (E-4)$$

gdje umnožak $24 \cdot 3600$ označava broj sekundi u jednom danu, a $n_{DAN,i}$ broj proteklih dana od početnog referentnog trenutka pa do početka voznog ciklusa i . Nakon određivanja vremena odlaska $t_{out,DC,1}$, potrebno je slučajno generirati vrijeme dolaska u distributivni centar $t_{in,DC,1}$. Na temelju $t_{out,DC,1,24h}$, koji je određen s $*t_{out,DC,1}$, iz $(t_{out,DC,24h}, t_{in,DC,24h})$ (Slika E-2b) dobiva se funkcija distribucije vjerojatnosti (vidi primjer na slici E-3b) iz koje se, nadalje, generira pomoćna varijabla $*t_{in,DC,1}$ (vrijeme dolaska na sekundnoj bazi u 24-satnom periodu). Stvarno vrijeme dolaska $t_{in,DC,1}$ tada se dobije iz $*t_{in,DC,1}$ korištenjem sljedeće jednadžbe dane za opći vozni ciklus i :

$$t_{in,DC,i} = 24 \cdot 3600 \cdot n_{DAN,i} + *t_{in,DC,i}, \quad (E-5)$$

Broj proteklih dana za i -ti vozni ciklus određuje se na temelju sljedeće rekurzivne relacije:

$$n_{DAN,i} = \begin{cases} n_{DAN,i-1} + 1, & *t_{out,DC,i} < t_{in,DC,i-1,24h} \\ n_{DAN,i-1} + 1, & *t_{in,DC,i} < t_{out,DC,i,24h} \\ n_{DAN,i-1}, & \text{u protivnom} \end{cases}, \quad (E-6)$$

gdje inicijalna vrijednost $n_{DAN,0}$ za period prije prvog voznog ciklusa ($i=0$) iznosi 0.

Dobivanjem $t_{in,DC,1,24h}$, koji je određen s $*t_{in,DC,1}$, opisanim postupkom dolazi se do $t_{out,DC,2}$. Ovaj postupak se iterativno ponavlja sve dok $t_{in,DC,i}$ ili $t_{out,DC,i}$ ne postanu veći od nekog zadanog vremenskog perioda koji je u ovom radu za potrebe generiranja novih ulaznih razdioba modela flote EV postavljen na $30 \cdot 24 \cdot 3600$ sekundi, tj. vremenu trajanja od 1 mjeseca.

Prilog F – Parametri DP optimiranja punjenja flote EV

DP optimiranje punjenja distribuiranog (tj. više-agentnog) modela flote

$P_{c,\min} = 0$ kW, $P_{c,\max,ind} = 10$ kW, $SoC_{low,lim}=0$, $SoC_{upp,lim} = 1$, $N_{control} = 1000$, $N_{soc} = 100$, $N_v = 10$, $K_f = 10^{10}$, $K_{g1} = K_{g2} = K_{g3} = 10^8$, $K_{g4} = 10^5$, $K_{g5} = K_{g7} = K_{g8} = K_{g9} = 10^3$, $K_{g6} = 10^4$, $\Delta T = 1$ h, $N_t = 2184$ h (za $t_f = 3$ mjeseca i $\Delta T = 1$ h), $E_{\max} = 16$ kWh, $E_{\max,agg} = 160$ kWh, $\eta_{ch} = \eta_{dch} = 0.92$, $SoC_{init} = 0.99$, $SoC_{end} = 0.99$, $SoC_{\min} = 0.3$, $SoC_{\max} = 1$.

DP optimiranje punjenja osnovnog agregatnog modela flote

$P_{c,\max,grid} = 100$ kW, $P_{c,\max,ind} = 10$ kW, $E_{\max,agg} = 160$ kWh (za 10 EV, svako kapaciteta baterije 16 kWh), $\eta_{ch} = \eta_{dch} = 0.92$, $P_{c,agg,\min} = 0$ kW, $P_{c,agg,\max} = 100$ kW, $SoC_{agg,init} = 0.5$, $SoC_{agg,\min} = 0$, $SoC_{agg,\max} = 1$, $N_{control} = 1000$, $N_{soc} = 100$, $N_t = 2184$ h (za $t_f = 3$ mjeseca i $\Delta T = 1$ h), $K_f = 10^{10}$, $K_{g1} = 10^8$, $K_{g2} = 10^7$, $K_{g3} = 10^3$.

DP optimiranje punjenja naprednog agregatnog modela flote

$P_{c,\max,grid} = 100$ kW, $P_{c,\max,ind} = 10$ kW, $E_{\max,agg} = 160$ kWh (za 10 EV, svako kapaciteta baterije 16 kWh), $\eta_{ch} = \eta_{dch} = 0.92$, $P_{c,agg,\min} = 0$ kW, $P_{c,agg,\max} = 100$ kW, $SoC_{agg,init} = 0.5$, $SoC_{agg,\min} = 0$, $SoC_{agg,\max} = 1$, $N_{control} = 1000$, $N_{soc} = 100$, $N_t = 2184$ h (za $t_f = 3$ mjeseca i $\Delta T = 1$ h), $K_f = 10^{10}$, $K_{g1} = 10^{16}$, $K_{g2} = 10^{12}$, $K_{g3} = 10^{-1}$, $K_{g4} = 10^{13}$, $K_{g5} = 10^3$, $K_{g6} = 10^{11}$, $K_{g7} = 10^{-2}$.

Prilog G – Heuristički pristup punjenju flote EV

Heuristički postupak punjenja agregatnog modela flote EV preuzet je iz [4, 89], te je korišten u poglavlju 5 kako bi se dobio uvid u prednosti optimiranja punjenja temeljenog na DP algoritmu u odnosu na heuristički pristup punjenju. Ovdje je dan kratki opis tog postupka s originalnim zapisom oznaka i originalnim jednadžbama. Originalne oznake iz [4, 89] su s oznakama u ovom radu povezane kako slijedi:

- $t_{V2G} = (P_{dem,agg} - P_{reg,agg})\Delta T$: razdioba zahtjeva transporta za energijom,
- $c_{V2G} = n_{dc,agg} \cdot P_{cmax,ind}$: ograničenje na maksimalnu snagu punjenja,
- $e_{Charge} = P_{c,agg}\Delta T$: energija punjenja agregatne baterije,
- $\mu_{Charger} = \eta_{ch}$: korisnost punjenja agregatne baterije,
- $S_{V2G-Battery} = E_{max,agg}$: energetska kapacitet agregatne baterije,
- $s_{V2G-Battery} = E_{max,agg} \cdot SoC_{agg}$: razina energije u agregatnoj bateriji u trenutnom satu.

Valja podsjetiti da agregatni model koji se koristi u [4, 89], uz minorne razlike, odgovara osnovnom agregatnom modelu flote EV predstavljenom u poglavlju 4, a koji je modeliran kao spremnik energije.

U ovom pristupu cilj je minimizirati višak proizvedene energije iz OIE pritom zadovoljavajući ograničenja postavljena na SoC. Kako bi se izračunao potencijal smanjenja viška proizvedene energije iz OIE (e_{CEEP}) temeljem skladištenja energije u EV floti, potrebni su sljedeći podaci vezani uz transport:

- 1) ukupna potrošnja energije razmatranog transportnog sustava tijekom određenog vremenskog perioda, D_{V2G} ,
- 2) normirana razdioba aktivnosti flote vozila na cesti (dana u rasponu [0,1]), δ_{V2G} .

Pritom se, kao i u ovom radu, pretpostavlja vrijeme diskretizacije od 1h. Razdioba zahtjeva transporta za energijom, t_{V2G} , dobiva se korištenjem podataka D_{V2G} , δ_{V2G} i pretpostavke da je zahtjev transporta za energijom proporcionalan aktivnosti vozila na cesti (vidi validaciju ovog pristupa u [54])

$$t_{V2G} = (D_{V2G} \delta_{V2G} / \sum \delta_{V2G}) \eta_{CHARGE}, \quad (G-1)$$

gdje η_{CHARGE} predstavlja korisnost punjenja agregatne baterije.

Vremenska razdioba gornjeg ograničenja na energiju punjenja agregatne baterije postavlja se zbog ograničenja na maksimalnu snagu punjenja pojedinačnog vozila (maksimalna snaga punjača) $C_{Charger}$. Preostali dio desne strane izraza (G-2) predstavlja broj vozila koja su parkirana i spojena na mrežu.

$$c_{V2G} = C_{Charger} \cdot V2G_{Connection-Share} \left[(1 - V2G_{max-Share}) + V2G_{max-Share} (1 - \delta_{V2G} / \max(\delta_{V2G})) \right] \quad (G-2)$$

Pritom, parametar $V2G_{Connection-Share}$ predstavlja udio parkiranih vozila koja su ujedno i spojena na mrežu, te $V2G_{max-Share}$ predstavlja maksimalan udio vozila koja su na cesti tijekom vršnih zahtjeva za energijom.

Agregatna energija punjenja e_{Charge} postavlja se na vrijednost koja odgovara višku proizvedene energije iz OIE, e_{CEEP} , ako e_{Charge} ne premašuje ograničenja na maksimalni energetska kapacitet $(S_{V2G-Battery} - s_{V2G-Battery}) / \mu_{Charge}$ i maksimalnu snagu punjenja c_{V2G} , koja je ujedno i maksimalna energija punjenja u nekom satu (zbog vremena diskretizacije od 1h), kako slijedi:

$$e_{Charge} = \min(e_{CEEP}, (S_{V2G-Battery} - s_{V2G-Battery}) / \mu_{Charge} c_{V2G}). \quad (G-3)$$

Pritom, $S_{V2G-Battery}$ odgovara ukupnom energetskom kapacitetu agregatne baterije, dok $s_{V2G-Battery}$ odgovara razini energije u agregatnoj bateriji u trenutnom satu.

Nadalje, donji limit na energiju u agregatnoj bateriji $s_{V2G-Battery-min}$ postavlja se kako bi se spriječio manjak energije za potrebe transporta. Donji limit $s_{V2G-Battery-min}$ računa se kao energije potrebna da se pokrije zahtjev transporta u trenutnom i u sljedećih y sati (vidi izraz (G-4)). Inicijalno, prag y postavlja se u 1h i ako opisana logika punjenja (G-3), uz postavljeni prag, rezultira manjkom energije u bateriji ($s_{V2G-Battery} < 0$), y se povećava za 1 i proračun punjenja se provodi ispočetka. Prag y se povećava dok se ne zadovolji ograničenje na minimalnu energiju u bateriji $s_{V2G-Battery} \geq 0$ na čitavom vremenskom horizontu punjenja.

$$s_{V2G-Battery-min} = \sum_{x=a}^{a+y} t_{V2G}(x). \quad (G-4)$$

Tada se donje ograničenje na energiju punjenja agregatne baterije izražava kao

$$e_{Charge} \geq \max\{(s_{V2G-Battery-min} - s_{V2G-Battery}) / \mu_{Charge}, 0\}, \quad (G-5)$$

gdje se *max* operator koristi kako bi se u obzir uzela činjenica da se razmatra samo jednosmjernan tok energije (iz mreže prema vozilima; $e_{Charge} \geq 0$).

Konačno, dinamika agregatne baterije opisana je diskretnom jednačbom stanja kako slijedi (usporedi jednačbu (4-1)):

$$s_{V2G-Battery} := s_{V2G-Battery} - t_{V2G} + (e_{Charge} \mu_{Charge}). \quad (G-6)$$

Životopis

Branimir Škugor (rod. 1987) stekao je titulu magistra inženjera elektrotehnike i informacijske tehnologije 2011. godine na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu. Od siječnja 2012. godine radi kao znanstveni novak na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu, gdje također pohađa doktorski studij. Sudjelovao je na istraživačkom projektu „ICT-podržana integracija električnih vozila u energetske sustave s visokim udjelom obnovljivih izvora energije“ podržanom od strane Hrvatske zaklade za znanost, te na dva projekta podržana od tvrtke Ford Motor. Autor je ili suautor 5 radova u CC/SCI/SCI-Ex časopisima, 3 rada u ostalim časopisima, 17 radova u zbornicima skupova s međunarodnom recenzijom, te niza studija i tehničkih izvještaja. Dobitnik je nagrade za najbolji članak na 9. SDEWES konferenciji održanoj 2014. godine. Njegovi istraživački interesi uključuju napredno upravljanje pogonima hibridnih električnih vozila, modeliranje i optimalno punjenje flote električnih vozila, te analizu i sintezu voznih ciklusa.

Popis javno objavljenih radova:

1. B. Škugor, J. Deur, “A bi-level optimisation framework for electric vehicle fleet charging management”, *Applied Energy*, DOI: 10.1016/j.apenergy.2016.03.091, 2016. (članak, znanstveni)
2. B. Škugor, J. Deur, “Dynamic Programming-based Optimization of Charging an Electric Vehicle Fleet System Represented by an Aggregate Battery Model”, *Energy*, Vol. 92, pp. 456-466, 2015. (članak, znanstveni)
3. B. Škugor, J. Deur, “A Novel Model of Electric Vehicle Fleet Aggregate Battery for Energy Planning Studies”, *Energy*, Vol. 92, pp. 444-455, 2015. (članak, znanstveni)
4. B. Škugor, J. Deur, M. Cipek, D. Pavković, “Design of a Power-split Hybrid Electric Vehicle Control System Utilizing a Rule-based Controller and an Equivalent Consumption Minimization Strategy”, *Proceedings of the Institution of Mechanical Engineers, Part D, Journal of Automobile Engineering*, Vol. 228, No. 6, pp. 631-648, 2014. (članak, znanstveni)

5. B. Škugor, J. Deur, "Delivery vehicle fleet data collection, analysis and naturalistic driving cycles synthesis", *Int. J. Innovation and Sustainable Development*, Vol. 10, No. 1, pp. 19-39, 2016. (članak, znanstveni)
6. M. Cipek, B. Škugor, M. Čorić, J. Kasać, J. Deur, "Control variable optimisation for an extended range electric vehicle", *Int. Journal of Powertrains*, Vol. 5, No. 1, pp. 30-54, 2016. (članak, znanstveni)
7. J. Deur, B. Škugor, M. Cipek, "Integration of Electric Vehicles into Energy and Transport Systems", *Automatika*, Vol. 56, No. 4, pp. 395-410, 2015. (članak, znanstveni)
8. B. Škugor, M. Cipek, J. Deur, "Control Variables Optimization and Feedback Control Strategy Design for the Blended Operating Mode of an Extended Range Electric Vehicle", *SAE International Journal of Alternative Powertrains*, SAE paper # 2014-01-1898, Vol. 3, No. 1, pp. 152-162, 2014.
9. B. Škugor, V. Ivanović, J. Deur, "Dynamic Programming-Based Design of Shift Scheduling Map Taking Into Account Clutch Energy Losses During Shift Transients", *SAE World Congress and Exhibition, Detroit, SAD*, 2016. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
10. B. Škugor, J. Deur, "A Nonlinear Charge-based Model of Electric Vehicle Fleet Aggregate Battery", *Proceedings of European Electric Vehicle Congress (EEVC2015)*, Brussels, Belgium, 2015. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
11. B. Škugor, M. Hrgetić, J. Deur, "GPS measurement-based road grade reconstruction with application to electric vehicle simulation and analysis", *10th Conference on Sustainable Development of Energy, Water and Environment Systems (10th SDEWES)*, Dubrovnik, Croatia, 2015. (predavanje, bez recenzije, objavljeni rad, znanstveni)
12. B. Škugor, J. Deur, "Analysis of Techno-Economic Aspects of an Energy System Including Delivery Electric Vehicle Fleet and Renewable Energy Sources", *10th Conference on Sustainable Development of Energy, Water and Environment Systems (10th*

- SDEWES), Dubrovnik, Croatia, 2015. (predavanje, bez recenzije, objavljeni rad, znanstveni)
13. B. Škugor, J. Deur, "Bi-level Optimisation Framework for Electric Vehicle Fleet Charging", 10th Conference on Sustainable Development of Energy, Water and Environment Systems (10th SDEWES), Dubrovnik, Croatia, 2015. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 14. B. Škugor, J. Deur, "Dynamic Programming-based Optimization of Electric Vehicle Fleet Charging", IEEE International Electrical Vehicle Conference (IEVC 2014), Florence, Italy, 2014. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 15. M. Cipek, B. Škugor, J. Deur, "Comparative Analysis of Conventional and Electric Delivery Vehicles Based on Realistic Driving Cycles", Proceedings of European Electric Vehicle Congress (EEVC 2014), Brussels, Belgium, 2014. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 16. J. Deur, B. Škugor, M. Cipek, "Integration of Electric Vehicles into Energy and Transport Systems", Proc. of 34th Conference on Automation in Transportation 2014, Invited paper, pp. 1-16, Dubrovnik, Croatia, 2014. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 17. B. Škugor, J. Deur, "Dynamic Programming-based Optimization of Charging an Electric Vehicle Fleet System Represented by an Aggregate Battery Model", 9th Conference on Sustainable Development of Energy, Water and Environment Systems (9th SDEWES), Venice, Italy - Istanbul, Turkey, 2014. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 18. B. Škugor, J. Deur, "A Novel Model of Electric Vehicle Fleet Aggregate Battery for Energy Planning Studies", 9th Conference on Sustainable Development of Energy, Water and Environment Systems (9th SDEWES), Venice, Italy - Istanbul, Turkey, 2014. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 19. B. Škugor, V. Ranogajec, J. Deur, "On Smoothing HEV/EREV Supervisory Control Action Using an Extended ECMS Approach", The International Electric Vehicle Sym-

- posium & Exhibition (EVS27), Barcelona, Spain, 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
20. B. Škugor, J. Deur, "The vehicle fleet data collection, processing, analysis, and naturalistic driving cycles synthesis", 8th Conference on Sustainable Development of Energy, Water and Environment Systems (8th SDEWES), Dubrovnik, Croatia, 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 21. B. Škugor, J. Deur, "Instantaneous Optimization-based Energy Management Control Strategy for Extended Range Electric Vehicle", Paper #2013-01-1460, 2013 SAE World Congress, Detroit, MI, 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 22. M. Cipek, M. Čorić, B. Škugor, J. Kasać, J. Deur, "Dynamic Programming-based Optimization of Control Variables of an Extended Range Electric Vehicle", Paper #2013-01-1481, SAE 2013 World Congress, Detroit, MI, 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 23. B. Škugor, D. Pavković, J. Deur, "A Series-Parallel HEV Control Strategy Combining SoC Control and Instantaneous Optimisation of Equivalent Fuel Consumption", Proceedings of 2nd European Electric Vehicle Congress (EEVC 2012), Brussels, Belgium, November 19-22, 2012. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 24. B. Škugor, D. Pavković, J. Deur, "A Series-Parallel Hybrid Electric Vehicle Control Strategy Including Instantaneous Optimization of Equivalent Fuel Consumption", Proceedings of 2012 IEEE Multi-Conference on Systems and Control (2012 IEEE MSC), pp. 310-316, Dubrovnik, Croatia, October 3-5, 2012. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
 25. J. Deur, M. Cipek, B. Škugor, J. Petrić, "Modeling and Low-level Control of Range Extended Electric Vehicle Dynamics", Proceedings of the International Conference on Powertrain Modelling and Control (PMC2012), University of Bradford, Bradford, UK, September, 2012. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)

Curriculum vitae

Branimir Škugor (b. 1987) received his M.Sc. degree in Electrical Engineering in 2011 from the University of Zagreb, Croatia. Since 2011, he has been a Research assistant at the Faculty of Mechanical Engineering and Naval Architecture, where he also attends PhD study. He has participated on the project „ICT-aided integration of Electric Vehicles into the Energy Systems with a high share of Renewable Energy Sources“ supported by Croatian Science Foundation, and two projects supported by Ford Motor Company. He is the author or co-author of 5 journal papers indexed in CC/SCI/SCI-Ex databases, 3 papers in other journals, 17 papers presented at international conferences, and a number of technical reports and studies. He received the best paper award at 9th Conference on Sustainable Development of Energy, Water and Environment Systems (SDEWES) held 2014. His research interest includes advanced control of hybrid electric vehicles powertrain, modelling and charging control of electric vehicle fleets, and analysis and synthesis of driving cycles.