Model za unaprjeđenje energetske učinkovitosti i prometne sigurnosti željezničkoga prijevoza primjenom naprednih pogonskih tehnologija i udaljenih uskopojasnih senzorskih mreža

Kljaić, Zdenko

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:596040

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-23**

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

Sveučilište u Zagrebu

FAKULTET PROMETNIH ZNANOSTI

Zdenko Kljaić

MODEL ZA UNAPRJEĐENJE ENERGETSKE UČINKOVITOSTI I PROMETNE SIGURNOSTI ŽELJEZNIČKOGA PRIJEVOZA PRIMJENOM NAPREDNIH POGONSKIH TEHNOLOGIJA I UDALJENIH USKOPOJASNIH SENZORSKIH MREŽA

DOKTORSKI RAD

Zagreb, 2021.

Sveučilište u Zagrebu

FAKULTET PROMETNIH ZNANOSTI

ZDENKO KLJAIĆ

MODEL ZA UNAPRJEĐENJE ENERGETSKE UČINKOVITOSTI I PROMETNE SIGURNOSTI ŽELJEZNIČKOGA PRIJEVOZA PRIMJENOM NAPREDNIH POGONSKIH TEHNOLOGIJA I UDALJENIH USKOPOJASNIH SENZORSKIH MREŽA

DOKTORSKI RAD

Mentori:
Prof. dr. sc. Tomislav Josip Mlinarić
Izv. prof. dr. sc. Danijel Pavković

Zagreb, 2021.

University of Zagreb

FACULTY OF TRAFFIC AND TRANSPORT SCEINCES

ZDENKO KLJAIĆ

MODEL FOR IMPROVEMENT OF RAILWAY TRANSPORT ENERGY EFFICIENCY AND TRAFFIC SAFETY BY MEANS OF ADVANCED POWER-TRAIN TECHNOLOGIES AND REMOTE NARROW-BAND SENSOR NETWORKS

DOCTORAL THESIS

Supervisors:
Prof. Tomislav Josip Mlinarić, Ph. D.
Assoc. Prof. Danijel Pavković, Ph. D

Zagreb, 2021.

Informacije o mentorima:

Prof. dr. sc. Tomislav Josip Mlinarić rođen je 1969. godine u Zagrebu, Republika Hrvatska. Osnovnu i srednju školu završio je u Zagrebu. Diplomirao je na Fakultetu prometnih znanosti, Sveučilišta u Zagrebu, 1994. godine. Doktorirao je na Fakultetu prometnih znanosti Sveučilišta u Zagrebu 2002. godine. Danas je stalno zaposlen kao redoviti profesor na Fakultetu prometnih znanosti, gdje obnaša dužnost dekana Fakulteta. Predaje na preddiplomskom i diplomskom studiju iz područja tehnologije željezničkoga prometa. Na doktorskom studiju sudjeluje u nastavi na više kolegija. Od 2007. godine član je Uredničkog odbora časopisa Promet – Traffic and Transportation. Od 2014. do 2018. bio je prodekan za znanost i vanjsku suradnju Fakulteta prometnih znanosti Sveučilišta u Zagrebu. Član je Hrvatske komore inženjera tehnologije prometa i transporta. Član je Znanstvenog vijeća za promet Hrvatske akademije znanosti i umjetnosti.

Izv. prof. dr. sc. Danijel Pavković (rođ. 1975.) stekao je titulu diplomiranog inženjera i magistra znanosti (polje elektrotehnika) 1998., odnosno 2003. godine na Fakultetu elektrotehnike i računarstva Sveučilištu u Zagrebu, dok je titulu doktora znanosti (polje strojarstvo) stekao 2007. godine na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu. Od studenog 2016. godine zaposlen je kao izvanredni profesor na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu, gdje sudjeluje u nastavi na preddiplomskom i diplomskom studiju iz područja elektrotehnike, elektronike, senzorike i mikroprocesorskih sustava, te četiri kolegija na poslijediplomskom doktorskom studiju. Do sada je sudjelovao je na 18 istraživačkih, razvojnih i tehnologijskih projekata podržanih od strane Ministarstva znanosti, obrazovanja i športa Republike Hrvatske, tvrtki Ford Motor i Jaguar Cars, CROSCO, HELB, Europske komisije (u sklopu FP7 okvirnog programa) i Hrvatske zaklade za znanost. Autor je ili ko-autor 32 rada u CC/SCI/SCI-Ex časopisima, šest radova u ostalim časopisima, 72 rada u zbornicima skupova s međunarodnom recenzijom, jedne znanstvene knjige, jednog poglavlja u knjizi, jednog patenta, te niza studija i tehničkih izvještaja. Za njegov istraživački rad dodijeljena mu je 2005. godine Državna nagrada za znanstvene novake u području tehničkih znanosti. Aktivni je član društava KoREMA i IEEE više od 12 godina, a od 2018. godine član je Znanstvenog vijeća za energetiku Hrvatske akademije znanosti i umjetnosti (HAZU).

Informacije o doktorskom radu:

1. Naziv doktorskoga studija: Tehnološki sustavi u prometu i transportu
2. Lektoriranje doktorskog rada: Selena Rabatić, mag.philol.croat.
3. Fakultet na kojemu je doktorski rad branjen: Fakultet prometnih znanosti Sveučilišta u Zagrebu.

SAŽETAK

Prijedlog sustava za povećanje energetske učinkovitosti i sigurnosti željezničkoga prijevoza temelji se na postupcima usredotočenim na specifične domene pogonskih sustava i željezničke infrastrukture uz korištenje strukturiranih skupova podataka, pokazatelja i indeksa kao ulaznih podataka za upravljanje voznim misijama.

U radu se predlaže novi model za upravljanje voznim misijama željezničkih vozila, optimiran na temelju podataka iz udaljenih senzorskih mreža. Pritom hibridni pogon s više izvora energije, odnosno spremnikom električne energije, poboljšava energetsku efikasnost pri prometovanju brdsko-planinskim trasama, dok je za ispunjenje vozne misije u nepovoljnim vremenskim uvjetima potrebno i poznavanje stanja trase u određenom lokacijskom i vremenskom intervalu.

Zbog složenosti takvog sustava potrebno je računalno podržano dinamičko upravljanje s učinkovitim matematičkim modelima. Ulazni parametri modela hibridnog pogona željezničke vuče ograničeni su na lokalne domenske varijable, te je stoga u radu predloženo udaljeno prikupljanje minimalne grupe informacija potrebnih za prediktivno upravljanje s ciljem istodobnog povećanja sigurnosti prijevoza. Predloženi postupak prikupljanja informacija temelji se na ekspertnom prometno-tehnološkom znanju i tehnološkim mogućnostima senzorskih mreža četvrte i pete generacije (4G/5G).

Dobiveni se rezultati koriste u simulacijskom okruženju za sintezu i provjeru predloženog modela upravljanja željezničkim prijevozom.

Ključne riječi: željeznički promet, udaljene senzorske mreže, pokazatelji, indeks, model upravljanja, energetska učinkovitost, povećana sigurnost prometovanja.

EXTENDED SUMMARY

The proposal for a system to increase energy efficiency and railway transport safety is based on procedures focused on specific domains of drive systems and railway infrastructure using structured datasets, indicators and indices as inputs for management of driving missions.

The thesis proposes a new model for the management of driving missions, optimized based on the data from remote sensor networks. On the other hand, a hybrid drive with multiple energy sources, that is, an electrical energy storage system, improves the energy efficiency when operating on mountain routes, while the knowledge of a minimal data set describing the condition of the route at a specific location and time interval is required to fulfill the driving mission under adverse weather conditions.

Due to the complexity of such a system, computer-aided dynamic management based on efficient mathematical models is required. The input parameters of the hybrid traction drive model are limited to local domain variables, and therefore, the paper proposes a predictive management scheme aimed at simultaneous increase of transport safety. The proposed information collection process is based on expert traffic technology knowledge and technological capabilities of the fourth and fifth generation (4G/5G) sensor networks. The results obtained are used in a simulation environment for the synthesis and validation of the proposed model of railway transport management.

This thesis initially proposes a quasi-static model of a conventional diesel - electric locomotive. The proposed model designed based on the known parameters of the locomotive drive assembly, such as the rated power of the diesel engine and the output electric power of the generator unit, and the electrical traction system power input. For the purpose of deriving the fuel consumption model and the related exhaust emissions model, as well as the traction force and traction power characteristics of the propulsion system, the characteristics of a similar diesel engine and generator are matched and their fuel consumption data were taken from the available literature for the purpose of adjustment (scaling) in order to correspond to the power characteristics of the target engine-generator unit of the considered diesel-electric locomotive. Thus-defined conventional locomotive model is then used for the hypothetical conversion of the locomotive into a battery-hybrid and fully-electric battery-based variants by adding a suitable battery energy storage system of sufficiently large capacity, in parallel to the generator in the former case, or standalone in the latter case. In addition, an appropriately optimized energy management strategy has been devised in order to keep the battery state-of-charge

within predefined limits, while aiding the conventional propulsion system during its operation, and also facilitating recuperation of a portion of the train potential energy during descending by converting its kinetic energy to electrical energy through regenerative braking by means of traction electrical motors. A new approach to rail freight haul by combined use of conventional diesel-electric and battery-electric locomotives for different characteristic scenarios of individual and joint (tandem) operation is also considered herein. In order to manage power flows between the conventional and battery electric locomotives, and to ensure an additional level of safety aimed at maintaining the battery state-of-charge charge above the minimum recommended value of 20% in demanding traction conditions, the driver's Notch command reduction rule is also included, which intercepts and conditions the accelerator command set by the driver. Simulation models of battery-electric and conventional diesel-electric locomotives are compared and simulated in different tandem and stand-alone combinations for the considered mountainous rail route and the case of a return journey, including realistic railway slopes and speed limits.

The work presented herein also describes the development of the comprehensive model of a battery-hybrid diesel-electric locomotive extended with additional data related to the state of the railway infrastructure, which are obtained from a remote network of wireless sensors based on the application of fourth and fifth generation narrow-band communication technologies. The data used in the model refer to two key parameters that define the track conditions, i.e. the wheel-to-railway coefficient of adhesion and the average head wind speed, which, in turn, correspond to the changing weather conditions on the track. These data are then used within the freight train model to predict its driving dynamics, and are also used to find the optimal parameters of the battery state-of-charge controller for different operating modes, thus avoiding unnecessary and harmful deep battery discharging within the battery-hybrid diesel-electric locomotive.

For the selected profile of the mountain railway route managed by the Croatian national railway company (Croatian railways, HŽ), an energy efficiency assessment is also performed, corresponding to a comparative assessment of fuel consumption of conventional and hybrid battery locomotives using a return journey simulation scenario, which includes realistic route slopes and train speed limitations. The obtained simulation results have shown that utilization of a battery-hybrid locomotive can result in significant energy savings and reduction in fuel consumption by up to 16.5%, which is also reflected in the proportional reduction of greenhouse

gas emissions. Extended simulation model involving variable track conditions has been able to identify the necessary adjustment of driver behavior (i.e., change of driving mode and need for braking) under variable wheel-to-rails adhesion conditions. These modifications of the locomotive operating mode also resulted in increased travel time under worsened track conditions (compared to the reference case with constant adhesion and head wind) in accordance with the limitations of the locomotive traction system. Deteriorated track conditions (i.e. reduced adhesion and increased head wind) also result in increased fuel consumption and deeper discharge of the battery energy storage system within the battery-hybrid diesel-electric locomotive due to suboptimal operation of the main drive (i.e. diesel engine-generator set and traction electric motors). In particular, in the case of reduced adhesion, the potential for collecting the kinetic energy of the freight train via traction electric motor drive is significantly reduced, while an increase in head wind generally results in increased energy consumption.

The presented results have shown that an optimized battery state-of-charge controller that uses track status information from the remote wireless sensors network can maintain the battery state-of-charge above the minimum recommended value of 20%, which has not been the case with the state-of-charge controller with constant parameters. Therefore, the optimized controller is capable of preventing deep discharges of the battery, and, thus to reduce its degradation and the associated reduction of battery life, while maintaining fuel consumption at an acceptable level for the specific highly-demanding driving scenario. The results also indicate that the train model that includes track condition data from remote sensors can predictively determine the duration of a running mission on the railway segment in question and to predict possible unplanned train stops due to unfavorable meteorological conditions on the track.

Based on the established correlation of friction coefficient, ambient temperature and absolute air humidity, a fuzzy logic-based algorithm for classifying the state of adhesion between wheels and rails on the railway line has been derived with the aim of warning the driver of changes in braking and traction force potential on the individual parts of the route based on air humidity and temperature measurements from the remote sensors network. The fuzzy route classification algorithm and the appropriate driver's intervention in the case of reduced braking and traction force potential is facilitated through the reduction of train speed (which inherently also increases the traffic safety and facilitates easier emergency stopping), and the overall concept has been tested by computer simulations. The proposed track condition classification algorithm effectively alerts the driver to timely reduce the train speed on critical sections where

poor track adhesion conditions are detected. This is extremely important for the next generation of autonomously driven railway vehicles, which, due to the lack of a driver and his driving experience on a certain traffic route, have to use a predictive sensor network, whose data availability becomes a critical safety factor at higher train speeds. Moreover, such systems with predictive warnings significantly contribute to the reduction of excessive cognitive load of train drivers and increase the safety of the train transportation process, especially in difficult weather and geographical conditions. This ultimately contributes to the overall increased safety of rail traffic in terms of increasing the stability of the railway timetables.

The final part of the paper presents a technological and economic analysis conducted under the condition of expected battery life and the associated expected capacity drop of 20% during battery operation, where the hybrid locomotive can maintain the same traction performance as the conventional one. Based on the current installation costs of contemporary lithium-ion batteries, it is expected that the investment costs in hybridization could be recouped approximately three times within the expected battery life. Furthermore, the obtained simulation results for a battery-electric locomotive show that such a locomotive is the most energy efficient solution, but is able to cross the considered mountain route only at very low loads. If additional battery charging is introduced in the middle of the route, the battery-electric locomotive in independent operation can achieve an increase in traction as well as improved driving characteristics. In tandem operations, a battery-electric locomotive can provide significant fuel savings of up to 20% associated with the simultaneous use with the diesel-electric locomotive, especially if a double-charging scenario is considered, which is also reflected in the proportional reduction in greenhouse gases emissions. If electricity costs are also taken into account, conventional tandem configurations plus a battery locomotive can provide savings of up to 22%. While these savings may not be able to justify the estimated cost of a brand new battery-electric locomotive based on the current costs of battery-powered energy storage systems, this may not be the case when considering long-term use, given the current declining trends of battery purchase costs.

Key words: railway traffic, remote sensor networks, indicators, index, management model, energy efficiency, increased traffic safety.

Sadržaj

1. UVOD 1

1.1. MOTIVACIJA ISTRAŽIVANJA 1
1.2. ISTRAŽIVAČKA PROBLEMATIKA I ZNANSTVENA HIPOTEZA 3
1.3. KOMPOZICIJA RADA 6
1.4. DOSADAŠNJE SPOZNAJE I TRENDOVI ISTRAŽIVANJA 8
1.4.1. Analiza željezničkoga prijevoza 8
1.4.2. Evolucija energetske učinkovitosti i prometno-tehnološke sigurnosti željezničkoga prometa 9
1.4.3. Trend razvoja autonomnih urbanih vozila za kretanje po virtualnim željezničkim tračnicama sa senzorskom podrškom 13
1.4.4. Modeliranje udaljenih senzorskih mreža u službi podrške prometnim entitetima u pokretu 15
1.4.5. Vremenski uvjeti, adhezija i otpori gibanja željezničkoga vozila 22
1.4.6. Otpornost na klimatske promjene sustava za upravljanje i optimizaciju željezničkoga prijevoza 29
1.4.7. Primjena umjetne inteligencije i neizrazite (fuzzy) logike u automatizaciji željezničkoga prometa 32

2. MODELIRANJE ŽELJEZNIČKOGA PRIJEVOZA NA TRASI BRDSKO-PLANINSKE PRUGE 39

2.1. KONFIGURACIJA BRDSKO PLANINSKE ŽELJEZNIČKE PRUGE 39
2.2. DEFINIRANJE ŽELJEZNIČKE RUTE I VOZNE MISIJE 40
2.3. MODEL KONVENCIONALNE DIESEL-ELEKTRIČNE LOKOMOTIVE 42
2.3.1. Karakteristike i statičko ponašanje pogonskih strojeva 43
2.3.2. Model električne trakcije lokomotive 50
2.3.3. Modeliranje uzdužne dinamike gibanja 52
2.3.4. Ukupni model teretnog vlaka i model strojovođe 53
2.4. MODEL HIBRIDNE DIESEL-ELEKTRIČNE LOKOMOTIVE 55
2.4.1. Kvazistatistički model baterije 55
2.4.2. Skaliranje glavnog agregata hibridne baterijske dizel-električne lokomotive 58
2.4.3. Upravljački sustav hibridnog pogona 59
2.4.4. Parametarsko optimiranje regulatora na bazi pravila 61
2.5. MODEL BATERIJSKE LOKOMOTIVE 63
2.6. MODEL OPTIMIZACIJE I KLASIFIKACIJE PODATAKA IZ UDALJENIH SENZORSKIH MREŽA 66
2.6.1. Senzorski sustavi na željezničkoj infrastrukturi 66
2.6.2. Uskopojasne senzorske mreže s malom potrošnjom energije 68
2.6.3. Komunikacijski model i implementacija u simulacijskom okruženju 74

2.7. POSTUPAK OBRADE PODATAKA IZ SENZORSKIH MREŽA NAMIJENJEN PODRŠCI UPRAVLJANJA ŽELJEZNIČKOGA PRIJEVOZA ... 77
2.7.1. Metodologija anketiranja eksperata u području željezničkoga prijevoza ... 77
2.7.2. Rezultati ankete ... 78
2.7.3. Ulazni podaci i validacija podataka ... 85
2.7.4. Upravljanje „fuzzy“ logikom - klasifikator stanja trase ... 90

3. SIMULIRANJE ŽELJEZNIČKOGA PRIJEVOZA NA TRASI BRDSKO PLANINSKE PRUGE ... 92

3.1. SIMULACIJA VOZNE MISIJE POGONJENE KONVENCIONALNOM DIESEL-ELEKTRIČNOM LOKOMOTIVOM ... 92
3.2. SIMULACIJA VOZNE MISIJE POGONJENE HIBRIDNOM LOKOMOTIVOM ... 95
3.3. SIMULACIJA VOZNE MISIJE POGONJENE BATERIJSKOM LOKOMOTIVOM ... 99
3.3.1. Domet baterijske lokomotive ... 99
3.3.2. Baterijska lokomotiva u tandemu s konvencionalnom ... 101
3.4. SIMULACIJA VOZNE MISIJE POGONJENE HIBRIDNOM LOKOMOTIVOM UZ VARIJACIJU VREMENSKIH UVJETA ... 105
3.4.1. Simulacijski model vlaka uz varijabilne vremenske uvjete na trasi ... 106
3.4.2. Simulacijski rezultati ... 109

4. TEHNOLOŠKO-EKONOMSKA ANALIZA I DISKUSIJA REZULTATA ... 113

4.1. POTENCIJALNE UŠTEDE UTROŠENOG GORIVA I REDUKCIJE EMISIJA ŠTETNIH PLINOVA ... 113
4.1.1. Potencijalna ušteda uz primjenu baterijsko-hibridne lokomotive ... 113
4.1.2. Potencijalne uštede uz primjenu baterijske lokomotive ... 117
4.2. PREDVIĐANJE ZASTOJA I MOGUĆE INTERVENCIJE ... 120
4.3. POVEĆANJE SIGURNOSTI I UČINKOVITOSTI PRIJEVOZA UZ VARIJABILNE UVJETE NA TRASI ... 121
4.3.1. Simuliranje ovisnosti koeficijenta trenja o atmosferskim varijablama ... 121
4.3.2. Rezultati simulacije vozne misije vlaka uz primjenu fuzzy klasifikatora stanja željezničke trase ... 122

5. ZAKLJUČAK ... 126

LITERATURA ... 131

POPIS TABLICA ... 146

POPIS SLIKA ... 147

ŽIVOTOPIS ... 151

CURRICULUM VITAE ... 152

PRILOG 1. – ANKETNI UPITNIK NA HRVATSKOM JEZIKU ... 153

PRILOG 2. – ANKETNI UPITNIK NA ENGLESKOM JEZIKU ... 156

1. UVOD

1.1. Motivacija istraživanja

Dugoročni ciljevi Europske unije se temelje na zelenoj energetskoj tranziciji. Europska komisija je usvojila paket mjera za uspješnije korištenje obnovljivih izvora energije i veću energetsku učinkovitost, te pravno obvezujuće smjernice za ispunjenje ciljeva Pariškog sporazuma o klimi.

Prema ovim smjernicama najmanje 32% energetske potrošnje u EU-u do 2030. godine mora biti iz obnovljivih izvora. Države članice, pa tako i Republika Hrvatska trebaju osigurati da najmanje 14 % goriva u sektoru prometa dolazi iz obnovljivih izvora, te energetsku učinkovitost je potrebno povećati za 32,5 % do 2030 [1].

Strategija dekarbonizacije energetskog sektora uvjetuje i značajne promjene u sektoru prometa i transporta u smislu upotrebljivih energenata, što se reflektira i na korištene pogonske tehnologije. Prema dokumentu Europske komisije o financiranju ubrzavanja inovacija u području čiste energije zahtjeva se integracija pametnih, najsuvremenijih digitalnih tehnologija u sve aspekte energetskog sustava, obnovljivih izvora, e-mobilnosti i naprednog stanovanja.

Na temelju naprednih koncepata baterija i novih pogonskih sustava, sljedeća generacija vozila sastavni je dio inovativne infrastrukture i energetskih rješenja. Razvoj jeftinijih, lakših, sigurnijih baterija povećanog kapaciteta i dometa, kao i inovativne tehnologije te rješenja za punjenje prilagođenih potrošačima prioritet su za istraživanje i inovacije u području prometa, a ujedno su potencijalna konkurentna prednost za prometnu industriju EU-a. Dodatne prilike donosi digitalizacija jer omogućuje usluge povezanog i automatiziranog prometa te pametne mobilnosti, koje su trenutno u demonstracijskoj fazi radi rješavanja tehničkih i zakonodavnih problema [2].

U Strateškom programu EU za istraživanje i inovacije u prometu razvijen je prvi dugoročni strateški pristup za pripremu predviđene promjene prometnog sustava u okviru istraživanja i inovacija koji kombiniraju inovativne niskougljične tehnologije, usluge povezanog i automatiziranog prometa i pametne mobilnosti primjenom novih tehnologija. Utvrđena je potreba za prelazak na autonomniji i povezaniji promet kao nužni uvjet za postizanje viših razina učinkovitosti i dekarbonizacije prometnog sustava. Prema dokumentima

Europske komisije do 2030 godine, brzi željeznički promet udvostručit će se širom Europe i predviđen je za gradska i međugradska kolektivna putovanja. Za putovanja manja od 500 km trebala bi biti dostupna ugljično neutralna automatizirana mobilnost za manje grupe ljudi ili roba. Također prema dokumentu EK, s naslovom „Utjecaj digitalizacije i robotizacije prometa na kreiranje politika EU-a“ navedeno je sljedeće: digitalizacija i robotizacija u području mobilnosti ljudi i prijevoza robe društvu donose nekoliko potencijalnih prednosti, kao što su bolja pristupačnost i praktičnost za putnike, učinkovitost i produktivnost logistike, poboljšana prometna sigurnost i smanjenje emisija. No, ovakva rješenja istodobno izazivaju zabrinutost u pogledu sigurnosti[3]. Stoga su potrebna istraživanja i razvoj rješenja poglavito u području senzorskih mreža kako bi se rizici novih tehnologija sveli na minimum.

Energetska učinkovitost je jedna od početnih komponenti energetske tranzicije s ciljem smanjenja potrebe za energijom, kako bi se smanjila proizvodnja, pa prema tome i emisije CO_2. Potrošnja energije nije nepromjenjiva, već dinamička veličina koja ovisi o potrošačkim objektima, standardima, tehnološkom napretku i klimatskim značajkama koje utječu na potrošnju energije.

Željeznički prijevoz označen je kao najbitniji vid prometovanja u strategiji razvoja prometne politike EU, a s ciljem postizanja učinkovitijih i održivijih načina prijevoza. Mobilnost putnika, a poglavito roba ključna je sastavnica unutarnjeg tržišta EU-a, te je nužna za održavanje konkurentnosti europskih industrija i usluga. Mobilnost roba znatno utječe na gospodarski rast pa je pod stalnim pritiskom optimizacije troškova. Međutim, prijevoz roba ima i nepovoljan utjecaj na okoliš i kakvoću života građana, pa su dodatni zahtjevi za željezničke prometne sustave potrošnja energije iz obnovljivih izvora, tzv. zelene energije, a smanjenje potrošnje energije iz fosilnih goriva. Zelenu tranziciju željezničkih prometnih sustava otežavaju trendovi značajne proizvodnje zelene energije na mjestu potrošnje, čija isporuka viškova energije u mrežu treba biti sustavno regulirana. Zbog osnovnih odrednica željezničkoga prometa, a to su sigurna i učinkovita mobilnost, pojavljuju se izazovi potrebne nove infrastrukture napajanja što se dijelom rješava kroz razvoj pametnih mreža (engl. Smart Grid). Koncept pametnih mreža temelji se na naprednim mjernim sustavima (engl. AMI - Advanced Metering Infrastructure), platformama za upravljanje, te distribuiranim proizvođačima uključujući i obnovljive izvore, te potrošači koji sada mogu biti i u pokretu, a to su prometni entiteti. Ovdje je važno naglasiti da potrošači mogu postati i isporučitelji energije, što znači da su potrebni distribuirani inteligentni spremnici energije. Napredne elektroenergetske mreže

predstavljaju skup tehnologija koje omogućavaju integraciju obnovljivih izvora u elektroenergetsku mrežu te uvode nove tehnologije i tehnološke inovacije kako bi razvili nove usluge, primjerice isporuka energije pokretnim potrošačima koji mogu biti i isporučitelji energije, a to su budući, uglavnom autonomni prometni entiteti u cestovnom ili željezničkom prometu.

Zahtjevi za ubrzanom digitalizacijom prometnog sektora imaju za posljedicu izuzetno velike količine podataka, računalstvo u oblaku, implementaciju mobilne komunikacijske mreže 5G, različitih grupa senzora, atenuatora, adaptera, te implementacija logističke robotike i umjetna inteligencija kao ključnog čimbenika za ostvarivanje napretka u području digitalnog i automatiziranog prometa.

Ovako veliki tehnološki napredak u prometnim sustavima, poglavito u željezničkim, predstavlja veliki izazov i zahtjeva nove napredne matematičke modele upravljanja, što je istraživačka tema ove doktorske disertacije.

1.2. Istraživačka problematika i znanstvena hipoteza

Cilj istraživanja je razraditi cjelovit i sistematičan pristup, te definirati uspješan model hibridnog pogona željezničkoga prometnog entiteta podržanog informacijama iz udaljenih uskopojasnih senzorskih mreža male potrošnje energije, a s ciljem postizanja energetske učinkovitosti i sigurnosti željezničkoga prometovanja.

Znanstvena hipoteza istraživanja je da se uspješnost strategije upravljanja željezničkoga prometnog entiteta s hibridnim pogonom može povećati prema kriteriju energetske učinkovitosti i prometne sigurnosti ako se u određenom vremenskom odsječku tijekom vozne misije, dodaju strukturirane informacije temeljene na ekspertnom znanju iz udaljenih senzorskih mreža.

Osnovni materijal za istraživanje su podaci sa senzora, te geografski i lokacijski podaci o kretanju željezničkih prometnih entiteta. Dio podataka su generirani na osnovu povijesnih informacija, te će biti prikupljeni i obrađeni anketni podaci.

Metodologija istraživanja temelji se na analitičkom i numeričkom pristupu, a pojedini postupci su detaljnije razrađeni u potonjem tekstu. Za potrebe istraživanja koristit će se

programski alat Matlab/Simulink, za implementaciju modela željezničkoga prijevoza i komunikacijskih sustava, te algoritama upravljanja i njihovu simulacijsku provjeru.

Temeljem prethodne analize područja željezničkoga prijevoza, a koji uključuje: modele električne vuče konvencionalnih i hibridnih lokomotiva, prilagođene informacije o proizvoljnim željezničkim trasama, te informacije o mogućnosti primjene inovativnih senzorskih i komunikacijskih tehnologija za poboljšanje učinkovitosti i sigurnosti prijevoza, predložen je plan istraživanja u predmetnom području.

Istraživanje energetske učinkovitosti željezničkoga prijevoza počiva na modeliranju pogona lokomotive koji uključuje vučne električne motore i izvor energije bilo s kontaktne mreže ili iz dieselskog agregata. Kao najkompleksniji slučaj razmatra se hibridna dieselska lokomotiva opremljena sustavom pohrane energije zasnovanim na naprednim elektrokemijskim baterijama.

Izrada odgovarajućeg simulacijskog modela pogodnog za optimizacijske studije, uključuje masu i teret cjelokupne kompozicije, kako bi model čim vjernije oponašao okolnosti što bliže onima na terenu. U svrhu izgradnje i proširenja modela prijevoza realnim podacima o trasi pristupljeno je prikupljanju podataka o tipičnim željezničkim trasama zasnovanim na GPS koordinatama i primjeni on-line softverskih alata. U tu svrhu, najprije je provedena analiza geografski najpogodnije trase brdsko-planinske pruge s koje će se prikupiti polazni podaci. Lokacijski podaci trase su strukturirani uzimajući u obzir ograničenja nagiba trase i maksimalne dozvoljene brzine kompozicije, te pozicije tunela i drugih prirodnih struktura koje ograničavaju točnost GPS koordinata pojedinih segmenata trase, a razmatra se i prikupljanje podataka iz željezničkoga vozila u gibanju.

Nakon prikupljanja, analize i validacije podataka za parametre temperature i vlage zraka procjenjuje se stanje površinske vlažnosti i koeficijent adhezije tračnica. Model senzorske mreže se temelji na uskopojasnim celularnim komunikacijskim mrežama s malom potrošnjom energije pa je potrebna koordinacija i s operatorima telekomunikacijskog sustava zbog pokrivenosti područja od interesa za navedena istraživanja. Za područja gdje nisu moguća mjerenja uzeti su povijesni podaci i na osnovu njih modelirati podaci za istraživanje. Prikupljeni podaci s udaljenih senzora se analiziraju radi izdvajanja ključnih značajki, odnosno indeksa stanja na trasi, te se na njih dalje referira kao na polazne pokazatelje. Naime, očekuje se da će budući trend razvoja udaljenih senzorskim mreža rezultirati vrlo velikim brojem raznorodnih senzora pa je potrebno optimirati ulazne informacije prema zahtjevima prometno-tehnološkog

procesa uzimajući pritom u obzir sve važne čimbenike, a to su mobilnost, te vremenske i lokacijske informacije.

U svrhu optimiranja količine informacija sadržanih u polaznim pokazateljima potrebna su znanja iz nekoliko znanstveno tehničkih područja. Zato se podaci potrebni za definiranje veze između polaznih pokazatelja i optimiranog pokazatelja prikupljaju ekspertnom metodom, tj. anketiranjem znanstvenih eksperata iz različitih tehničkih domena, na temelju čega će se analizom prikupljenih podataka i sintezom anketnih podataka kreirati odgovarajući indeksi s težinskim faktorima. Utvrđuje se kriteriji za procjenu posljedica svake opcije ili indeksa. Indeksi s težinskim faktorima su ulazni podaci, strukturirani s korektivnim posljedicama na model upravljanja željezničkoga prometnog entiteta s hibridnim pogonom.

Nakon provedenog procesa optimiranja sustava za prijenos informacija, izrađuje se simulacijski model senzorskog sustava pogodnog za primjene u željeznici temeljem poznatih tehničkih specifikacija. Polazni pokazatelji, odnosno ulazne informacije su optimirane na način da se preko indeksa s težinskim faktorima šalju korektivne informacije prema sustavu upravljanja željezničkoga prometnog entiteta i to u određenom vremenskom i lokacijskom odsječku. U slučaju da izmjeri polaznih pokazatelja nemaju korektivni karakter, onda u tom slučaju neće biti preneseni kroz komunikacijsku mrežu (zadržava se postojeća informacija o stanju trase u sustavu vođenja), čime su ostvareni zahtjevi na senzorsku komunikacijsku mrežu u smislu minimalne potrošnje energije. Statistički model se temelji na laboratorijskim i terenskim mjerenjima kojima se ustanovljavaju parametri sustava kao što su domet, te brzina i pouzdanost prijenosa podataka.

Na temelju prethodno dobivenih rezultata, napravljena je integracija pojedinih pod-modela u sveobuhvatni sustav temeljem kojeg će se moći provesti: optimiranje potrošnje energije za predefiniranu željezničku trasu, te komparativna analiza u pogledu energetske učinkovitosti i sigurnosti prijevoza. Dobiveni rezultati se interpretiraju te se analiziraju potencijalna odstupanja u smislu ograničenja predloženog modela. Kroz diskusiju i sintezu rezultata u zaključku istraživanja, verificirana je temeljna hipoteza i prikazani su ostvareni znanstveni doprinosi. Na kraju su navedena moguća područja primjene predloženog modela, njegova potencijalna ograničenja i prijedlozi daljnjih istraživanja s ciljem njegovog daljnjeg unaprjeđenja.

1.3. Kompozicija rada

Doktorski rad sastoji se od pet poglavlja, popisa korištene literature, popisa tablica, popisa slika i priloga s anketnim upitnicima. Rad sadrži i dodatne radne materijale (programske alate, prikupljene ulazne podatke, izlazne podatke testirane u simulaciji).

Rad je podijeljen na sljedeća poglavlja:

1. Uvod
2. Modeliranje željezničkoga prijevoza na trasi brdsko planinske pruge
3. Simuliranje željezničkoga prijevoza na trasi brdsko planinske pruge
4. Tehnološko-ekonomska analiza i diskusija rezultata
5. Zaključak

U uvodnom dijelu rada opisana je osnovna motivacija istraživanja, te istraživačka problematika i znanstvena hipoteza s opisom cilja istraživanja. Prikazana je kompozicija rada po poglavljima, te su na kraju prezentirane dosadašnje spoznaje i trendovi istraživanja, zajedno s relevantnim rezultatima iz literature vezanim za učinkovitost i sigurnost prometovanja u željezničkom prijevozu.

U drugom poglavlju (Modeliranje željezničkoga prijevoza na trasi brdsko-planinske pruge) predstavljeni su matematički i empirijski pod-modeli koji sačinjavaju cjelokupni model teretnog vlaka koji prometuje odabranom brdsko-planinskom željezničkom trasom, čije su ključne značajke (profil nadmorske visine i nagib trase) određeni na temelju slobodno dostupnih podataka dobivenih putem Interneta i odgovarajuće programske podrške, te se opisuje profil vozne misije i definiraju realni parametri vučnog pogona i otpori gibanju. Izrađuju se modularni kvazi-statički modeli teretnog vlaka pogodni za analizu energetske učinkovitosti i sigurnosti prometovanja, a koji uključuju modele razmatranih vučnih jedinica (lokomotiva). Kvazi-statički modeli lokomotiva zasnovani su na analizi tokova snaga i statičkim mapama potrošnje goriva, emisija ispušnih plinova te razvijene snage dizelskog agregata i trakcijske/kočne sile. Također je uključena i tehnološko-ekonomska procjena investicijskih troškova vezanim uz hibridizaciju, odnosno elektrifikaciju pogona kroz ugradnju baterijskog sustava za pohranu energije. Konačno, u poglavlju 2 se također opisuje prikladan model mreže uskopojasnih distribuiranih senzora temeljene na mobilnoj tehnologiji 4G/5G, a koja je integrirana s prethodno opisanim modelom teretnog vlaka radi pravovremene dojave potencijalno opasnih uvjeta na trasi u smislu niske adhezije i velikog intenziteta vjetra na promatranoj dionici, pri

čemu su korištena ekspertna znanja prometnih stručnjaka formulirana u formi upravljačkog algoritma zasnovanog na primjeni neizrazite (engl. fuzzy) logike.

U trećem poglavlju (Simuliranje željezničkoga prijevoza na trasi brdsko planinske pruge) prikazani su rezultati simulacijskih analiza temeljenih na odabranoj voznoj misiji koja uključuje povratno putovanje na odabranoj brdsko-planinskoj ruti za različite konfiguracije (opterećenja) teretnih vlakova i vučne jedinice (lokomotive). Pritom se razmatraju konvencionalna dizel-električna i baterijsko-električna propulzija, te baterijsko-hibridna propulzija zasnovana na baterijsko-električnoj lokomotivi, odnosno pojedinačni i tandemski rad različitih vučnih jedinica. Razmatrani simulacijski scenariji također uključuju i utjecaj dostupnosti informacija o stanju trase s udaljene mreže bežičnih senzora. Na temelju dobivenih rezultata simulacije određuju se indeksi poboljšanja energetske učinkovitosti i smanjenja emisija ispušnih plinova, odnosno povećanja sigurnosti prometovanja u slučaju primjene ekspertnih znanja zasnovanih na dostupnim mjerenjima s udaljenih senzora za danu dionicu trase.

U četvrtom poglavlju (Tehnološko-ekonomska analiza i diskusija rezultata) analiziraju se potencijali uštede dizelskog goriva i energije, te smanjenja emisija ispušnih plinova kroz hibridizaciju sustava vuče teretnog vlaka kroz primjenu baterijsko-hibridne dizel-električne lokomotive, odnosno tandemski rad dizelske i baterijsko-električne lokomotive, na temelju čega se provodi analiza isplativosti, odnosno povrata investicije za različite razmatrane scenarije. U ovom poglavlju se također razmatraju sigurnosni aspekti primjene naprednih sustava udaljenih senzorskih mreža kroz procjenu izvedivosti voznih redova temeljem saznanja o stanju trase, te mogućnosti pravovremene adaptacije vozne misije u smislu ograničenja brzine prometovanja kada su identificiraju potencijalno nepovoljni uvjeti na trasi primjenom udaljenih mjerenja i ekspertnih znanja integriranih u upravljački algoritam temeljen na neizrazitoj logici.

U petom poglavlju (Zaključak) prikazana su zaključna razmatranja kroz fokusirani pregled provedenog procesa znanstvenog istraživanja. Peto poglavlje sumarno objedinjuje rezultate uspješnog istraživanja, te pregled osnovnih značajki predloženog modela za unaprjeđenje energetske učinkovitosti i prometne sigurnosti željezničkoga prijevoza primjenom naprednih pogonskih tehnologija i udaljenih uskopojasnih senzorskih mreža, te se također ističu izvorni znanstveni doprinosi doktorske disertacije.

1.4. Dosadašnje spoznaje i trendovi istraživanja

1.4.1. Analiza željezničkoga prijevoza

U prometnom sektoru trenutno se troši oko 20% globalno proizvedenih fosilnih goriva [4], čime on postaje drugi najveći izvor emisija ugljičnog dioksida (CO_2) [5] te značajno doprinosi alarmantnom povećanju koncentracije atmosferskog CO_2 i s time povezanim stakleničkim efektima [6]. Nadalje, potrebe industrije i društva za jeftinom energijom i dalje se većim dijelom pokrivaju iz fosilnih izvora, što postaje sve složeniji zadatak u uvjetima izrazito fluktuirajućih cijena nafte i njenih derivata. Iako se još uvijek ulaže u nova nalazišta, te poboljšanje eksploatacije postojećih nalazišta [7], ne-obnovljivi karakter ovog izvora energije nalaže da će u bliskoj budućnosti biti dosegnut maksimum njegove proizvodnje [8]. Navedeni argumenti predstavljaju ključnu motivaciju za elektrifikaciju prometnog sektora, što je najjače izraženo u cestovnom prometu gdje se u posljednjih 15 godina pojavljuje sve više hibridnih električnih i potpuno električnih vozila [4, 5, 9]. Napredne tehnologije koje su, između ostalog, omogućile povećanje udjela elektrificiranih vozila u prometnom sektoru prepoznate su i kao ključni faktori za razvoj inteligentnih transportnih sustava [10] i njihovu integraciju unutar okvira pametne elektroenergetske mreže (Engl. Smart Grid) [11], naročito u uvjetima povećanog sudjelovanja obnovljivih izvora u ukupnoj energetskoj bilanci [12].

Elektrificirani sustav željezničke vuče zasniva se na distribuciji električne energije kroz odgovarajući nisko-naponski (do 800 V) ili srednje naponski sustav (do 25 kV) preko nad-tračničkog vodiča koji dovodi električnu energiju lokomotivi, a koja u tom slučaju ne mora biti opremljena primarnim izvorom energije [13]. Konkretno, električne lokomotive su karakterizirane većim omjerom snage prema masi (odnosno specifičnom snagom [kW/t]) u usporedbi s dieselskim (diesel-električnim) lokomotivama [12], te također mogu iskoristiti dio kinetičke energije kroz regenerativno kočenje [14]. Prema referencama [13], [15] i [16], zbog velikih investicijskih troškova elektrifikacije, značajan broj postojećih duljih željezničkih trasa karakteriziranih manjom gustoćom prometa još uvijek nisu elektrificirane [13]. Stoga je, radi fleksibilnosti prijevoza u uvjetima djelomične ili potpune nedostupnosti elektrificiranih željezničkih trasa, i dalje nužno imati značajan broj dieselskih lokomotiva u flotama nacionalnih i privatnih željezničkih kompanija [17].

Željeznički prijevoz možemo podijeliti u dvije skupine, koje se razlikuju prema prijevoznim zahtjevima usluge, te brzinom i načinom tehnološkog razvoja, a to su putnički željeznički prijevoz i teretni prijevoz. Putnički prijevoz u RH i regionalnom okruženju uglavnom je u opadanju zbog smanjenja prometnih mogućnosti željezničke infrastrukture, te zbog preferencije putnika za individualizacijom u prijevozu. Za razliku od putničkog, teretni željeznički prijevoz ima snažan pritisak na tehnološki razvoj i integraciju u jedinstveni Europski željeznički sustav (prema EU direktivi 2012/34/EU). Također, procesom globalizacije troškovi prijevozničkih usluga su postali vrlo značajni u poslovnom procesu, pa su postali predmet stalne optimizacije. U željezničkom teretnom prijevozu optimizacija ide u smjeru energetske učinkovitosti i tehnološkog razvoja u smislu dublje integracije s ostalim prometnim i logističkim sektorima. Uslijed navedenih zahtjeva ubrzano se razvija intermodalni prijevoz tereta.

Intermodalni prijevoz tereta je kretanje robe u jednoj te istoj utovarnoj jedinici uzastopnim načinima prijevoza bez rukovanja samom robom prilikom promjene načina prijevoza [18] . Integrirajući i koordinirajući upotrebu različitih načina prijevoza dostupnih u intermodalnim prometnim mrežama, intermodalni prijevoz tereta pruža priliku za optimalno korištenje fizičke infrastrukture kako bi se osigurale troškovne i energetski učinkovite usluge prijevoza. Naročito se uz pomoć davatelja informacija može postići takozvani sinkromodni prijevoz odabirom modaliteta prema najnovijim logističkim informacijama, npr. transportnim zahtjevima prevožene robe, prometnim informacijama okoline infrastrukture [19]. Prema navedenom je vidljivo da se od željezničke infrastrukture očekuje ubrzana digitalizacija, kako bi željeznički prijevoz postao troškovno i energetski prihvatljiv način prijevoza prema zahtjevima gospodarskog razvoja.

1.4.2. Evolucija energetske učinkovitosti i prometno-tehnološke sigurnosti željezničkoga prometa

Željeznički prijevozni sustav je kroz povijest imao vrlo važnu ulogu u različitim socijalnim, društvenim i ekonomskim okolnostima . Razvojem željezničke industrije razvijali su se i optimizacijski zahtjevi te sigurnosna ograničenja. Koristile su se različite tehnike, od primjene različitih goriva do modifikacije pogona, vozila i infrastrukture. Dosadašnji trendovi

istraživanja o uštedi energije u željeznici su fokusirani na strategiju vožnje, te sustave za pogon i pohranu energije [20].

Optimiranje potrošnje energije u željezničkom prijevozu predstavlja višedimenzionalni nelinearni problem s brojnim tehnološko prometnim ograničenjima, naročito u režimima rada s povećanim stupnjem autonomije gdje se pojavljuju i brojna sigurnosna ograničenja. Područje optimiranja autonomnih željezničkih vozila je relativno novo područje istraživanja, pa se često primjenjuju znanstvena iskustva i iz drugih mehatroničkih područja. Autori u referenci [21] daju prijedlog planiranja za prediktivni nadzor i adaptaciju unutar samo optimirajućeg upravljanja potrošnje energije autonomnog željezničkoga vozila.

Međutim, upotreba diesel-električnih lokomotiva iziskuje značajna izdvajanja za pogonsko dieselsko gorivo, te je stoga izražen trend u istraživanju i razvoju sustava optimalnog upravljanja hibridnim diesel-električnim pogonom [22], pri čemu se poseban naglasak daje na uvođenje sustava za pohranu energije zasnovanog na naprednim elektrokemijskim baterijama [23]. Pritom je potrebno posebnu pažnju posvetiti sigurnosnim aspektima primjene baterija, gdje se sa stanovišta pogodnosti za primjene u željeznici ističu natrij-nikal-klorid visoko-temperaturne (tzv. ZEBRA) baterije [23] i napredne tehnologije litijevih baterija kao što su litij-željezo-fosfat ($LiFePO_4$) baterije [24].

Prema simulacijskom modelu u referencama [25] i [26], predložene baterije su uspješno primijenjene u hibridizaciji dieselskog pogona u izoliranom postrojenju za istraživanje [27]. Analiza u referenci [27], temeljena na modelu tokova snaga mikromreže, ukazala je na značajne potencijale za uštede dieselskog goriva kao i redukciju emisija stakleničkih plinova u iznosu od 12% od sadašnjih vrijednosti. Shodno tome, realno je očekivati da bi hibridizacija pogona dieselske lokomotive s ugradnjom baterijskog sustava za pohranu energije mogla doseći slične razine uštede goriva, gdje referenca [28] navodi mogućnost uštede od čak 20% za određene režime rada. Posljedično, očekuje se i redukcija emisija stakleničkih plinova i ostalih zagađivača [29], uz realnu mogućnost smanjivanja emisija akustičke buke lokomotive uslijed iskorištavanja akumulirane električne energije u bateriji i posljedično niže potrebe za snagom iz dieselskog agregata [30].

Dosadašnja najzastupljenija istraživanja energetske učinkovitosti u željezničkom prijevozu temelje se na informacijama iz zatvorenih domenskih sustava, kao pod referencom [31] gdje se istraživanje fokusira na informacije dobivene iz senzora unutar vozila. Dobiveni rezultati istraživanja su mjerljivi i pozitivni, ali se ne mogu koristiti za druge namjene kao što

je povećanje sigurnosti prometovanja, te za druge prometne entitete na istoj prometnoj infrastrukturi. U području energetske učinkovitosti, te povećanja sigurnosti prometovanja željezničkoga transporta bave se domenski stručnjaci (energetika, proizvođači željezničkih vozila, proizvođači tehničkih sustava za željeznicu, operatori infrastrukture i vozila) te znanstvena zajednica koja se bavi istraživanjem željezničke prometne tehnologije, pogonsko energetskih sustava, te dijelom znanstvenici iz područja ekologije. Također, ovim područjem se bave i lokalna i nacionalna uprava, te agencije kao agencija za sigurnost željezničkoga prometa, koje uglavnom rade na planiranju i provođenju strategije i planiranih mjera za poboljšanje. Proučavanjem znanstvene i stručne literature može se primijetiti nedostatak istraživačkih projekata temeljenih na više-industrijskim domenama, što je donekle i očekivano jer su prometni sustavi visoko regulirani pravilima i preporukama. Pojavom novih tehnologija na kojima se temelji digitalizacija u širem smislu društva i industrije otvaraju se i nove istraživačke mogućnosti koje mogu pridonijeti poboljšanju.

Zaključak je, prema postojećoj znanstvenoj literaturi, da su prijedlozi sustava za povećanje energetske učinkovitosti i sigurnosti željezničkoga prijevoza temeljeni na postupcima usredotočenim samo na jednu od specifičnih domena pogonskih sustava, vozila ili segmenata željezničke infrastrukture uz korištenje domenski ograničenih skupova podataka za upravljanje voznim misijama. Takvi postupci doprinose ograničenim rezultatima i često su primjenjivi samo na određeno vozilo. Konzervativne izvore podataka često puta nije moguće globalno primijeniti ili su nedovoljno optimirani pa zagušuju cjelovitu mrežu i onemogućuju širu primjenu na pokretne prometne entitete. Stoga je potencijal podataka, optimiranih i strukturiranih prema ekspertnim znanjima, a temeljen na novim komunikacijskim tehnologijama, potencijal koji nije dovoljno iskorišten i potrebno ga je dodatno istražiti kroz istraživačke projekte.

Novija istraživanja energetske učinkovitosti i povećanja sigurnosti željezničkoga prometa temelje se na digitalizaciji željezničkih sustava i implementaciji senzorskih i komunikacijskih mreža 5G. Jedan od primjera je istraživanje korejskog nacionalnog instituta za željeznička istraživanja, koji je 2019 god. realizirao završetak izgradnje testne Osong željezničke trase i počeo s testiranjem dinamičkog upravljanja autonomnim željezničkim vozilima na temelju 5G komunikacijskih mreža, prikazanom na slici 1.

Slika 1. Testiranje 5G autonomnih željezničkih vozila na trasi „Osong Railway“ SK [32]

Sustav djeluje prema distribuiranom upravljačkom modelu, putem kojeg se svaki vlak automatski kontrolira izravnom komunikacijom od vlaka/vozila do vlaka/vozila, uzimajući u obzir informacije iz senzorskih mreža i lokacijske podatke za prediktivno računanje. U stvarno-vremenskim sustavima upravljanja, donošenje odluka provodi se kroz središnji kontrolni centar koji ima uvid o svim podacima vozila i infrastrukture. Tijekom testiranja utvrđena je mogućnost skraćenja sigurnosne udaljenosti između vlakova, a time i efikasnije korištenje željezničke infrastrukture. Testirana tehnološka rješenja uzimaju u obzir položaj prethodnog vlaka na pruzi i varijable kao što su položaj vlaka, brzina i put kočenja na osnovu informacija iz okoline, kako bi se omogućilo automatsko podešavanje sigurnosnih margina, odnosno operativne „dinamičke envelope“ vozila u smislu adaptacije brzine i održavanja minimalnog sigurnosnog razmaka između dvaju vozila.

Istraživači korejskog nacionalnog instituta za željeznička istraživanja zaključuju da bi testirani sustav mogao rezultirati značajnim smanjenjem potrebne količine signalne opreme uz prugu i povećati kapacitet linija do 30%. Pored toga, navedeno istraživanje indicira da bi tehnologija mogla smanjiti utjecaj ljudskih pogrešaka, smanjiti troškove ulaganja i poboljšati radove održavanja te da bi se tehnologija mogla u budućnosti koristiti za kvalitetnije upravljanje križnim prolaznim spojevima trasa. Upotreba 5G komunikacije smanjuje kašnjenje prijenosa informacija između vlakova, istovremeno povećavajući kapacitet prijenosa podataka i pouzdanost do 20 puta u usporedbi sa standardno korištenim GSM-R sustavima [32].

Daljnja istraživanja su usmjerena ka dodatnim ispitivanjima tehnologije preusmjeravanja vlakova i implementacije tehnologije dinamičnog odvajanja i spajanja vlakova, kao i prema naprednoj kontroli razmaka vlakova, te sustavima upravljanja i

komunikacije od vlaka i do infrastrukture. Ove nove tehnologije mogu smanjiti zagušenja i omogućiti vlakovima učinkovitiji promet [32], kako navodi Hee-Seung, voditelj istraživačkog projekta. Namjera je, u budućnosti, omogućiti implementaciju pametnih rješenja za energetski učinkovit i siguran prijevoz željeznicom, konvergencijom zelenih i digitalnih inicijativa.

1.4.3. Trend razvoja autonomnih urbanih vozila za kretanje po virtualnim željezničkim tračnicama sa senzorskom podrškom

Ceste su prometno-tehnički uređene građevine s podlogom, oznakama i opremom namijenjenim za kretanje cestovnih vozila, ali i pješaka u skladu sa zakonom. Cestovni način prijevoza omogućuje maksimalnu fleksibilnost putovanja s obzirom na rutu, smjer, vrijeme i brzinu putovanja. Uslugu prijevoza tzv. „od vrata do vrata“ moguće je pružiti samo s ovim načinom prijevoza.

Željeznička pruga se u većini slučajeva sastoji od dvije metalne tračnice koje čine kolosijek za kretanje samo određenih željezničkih vozila. Željeznička pruga kao prometno-tehnička građevina sastoji se od donjeg i gornjeg ustroja pruge, signalno-sigurnosnih sustava, telekomunikacijskih, elektrovučnih postrojenja i uređaja na infrastrukturi, građevinskih i tehničkih uređaja za osiguravanje cestovnih i pješačkih prijelaza, te ostalih postrojenja, uređaja na pruzi, signalnih oznaka, pružnog i zračnog pojasa iznad pruge u visini 12 m odnosno 14 m kod dalekovoda. Iz navedenog je vidljivo da je željeznička infrastruktura kompleksna, i zahtjevna za financiranje izgradnje i održavanja.

Europski gradovi nastoje smanjiti automobilski promet, pa je trend istraživačkih projekata s ciljem traženja novih inovativnih transportnih tehnologija koje će omogućiti urbanu mobilnost, manje prometne gužve i bolju energetsku učinkovitost uz, naravno, smanjenje emisije stakleničkih plinova. Također su zahtjevi da se infrastruktura može brzo implementirati u urbane zone. Kao odgovor na navedene zahtjeve pojavio se hibridni transportni sustav s autonomnim ili polu-autonomnim upravljanjem i s električnim pogonom. Ovaj sustav ima karakteristike cestovnog i željezničkog prijevoznog sustava. Značajni razlozi za prihvaćanje ovakvih sustava su: brza implementacija, moguće promjene trase prometovanja, autonomni način upravljanja, moguća integracija i koegzistiranje s ostalim gradskim vidovima prometa. Izrazito veliki zahtjevi su na senzorske mreže u vozilima i infrastrukturi, te na komunikacijsko povezivanje (uglavnom 5G) s okolnom gradskom infrastrukturom. Također ovdje se javlja i

zakonska problematika, jer je promet visoko regulirana djelatnost, a ovi sustavi su kombinacija nekoliko vidova prometa.

U kineskom gradu Zhuzhou prometuju autonomni vlakovi s virtualnim tračnicama (engl. Autonomous Rail Rapid Transit ART), slika 2. Koriste se također u Dohi, Katar. ART sustav koristi ugrađene senzore za vožnju duž virtualne trase. Senzorski sustavi zamjenjuju potrebu za postavljanjem stvarnih kolosijeka, kao mehaničkih vodilica željezničkoga vozila. Ovakvi sustavi dramatično smanjuju vrijeme gradnje i troškove u usporedbi s ostalim željezničkim transportnim sustavima. Nepostojanje trajnog željezničkoga kolosijeka omogućuje fleksibilno postavljanje trase u skladu s prometnim uvjetima, uz istodobnu regulaciju prometovanja u skladu s pravilima željezničkoga prometa.

Slika 2. U gradu Zhuzhou prometuju autonomni vlakovi sa virualnim tračnicama i senzorskom podrškom (engl. Autonomous Rail Rapid Transit - ART) [33]

Autonomni željeznički brzi tranzit (ART) novi je obrazac javnog prijevoza sa sljedećim prednostima: točnosti, velikog kapaciteta, uštede energije, kao i fleksibilnosti u postavljanju i mijenjanju prometnih trasa, te ukupnih troškova implementacije i eksploatacije. Očekuje se da će ART sustavi biti trendovi javnog prijevoza u srednje velikim gradovima [34].

Inovativni prijevozni sustavi sa svojstvima autonomije, ograničenog kretanja od službene lokacije do druge službene lokacije, te personaliziranim svojstvima ubrzanog transporta su vrlo kompatibilni s trenutnom metro infrastrukturom. Uspjeh ovakvih novih transportnih tehnologija je u mogućim kraćim linijama između postaja, te bitno manji troškovi implementacije, ako se integriraju u postojeću prometnu infrastrukturu [35].

1.4.4. Modeliranje udaljenih senzorskih mreža u službi podrške prometnim entitetima u pokretu

Procesom digitalizacije prometnih sustava počinje se generirati izuzetno velika količina podataka s ciljem poboljšanja sigurnosti i učinkovitosti. Koriste se u stvarno vremenskom obliku ili kao statistički obrađeni podaci za kasnije uspješnije prometne procese. Podaci se kreiraju i koriste uglavnom u ograničenim zatvorenim sustavima, pa su česti primjeri nemoguće interoperabilnosti. Zbog navedenih izazova prepoznaje se potreba za optimiziranim modelima za prikupljane podataka, ali također i za strukturiranje na način višemodne mogućnosti korištenja.

Hrvatske željeznice trenutno imaju relejne signalno-sigurnosne uređaje, koji su instalirani prije 30-40 godina. Pruge za regionalni i lokalni promet većinom su osigurane mehaničkim kolodvorskim uređajima, te različitim tipovima pojednostavljenih relejnih uređaja. Prema planu poslovanja do 2024. godine najavljena je zamjena zastarjelih magnetskih tračničkih kontakata s novim elektroničkim senzorima.

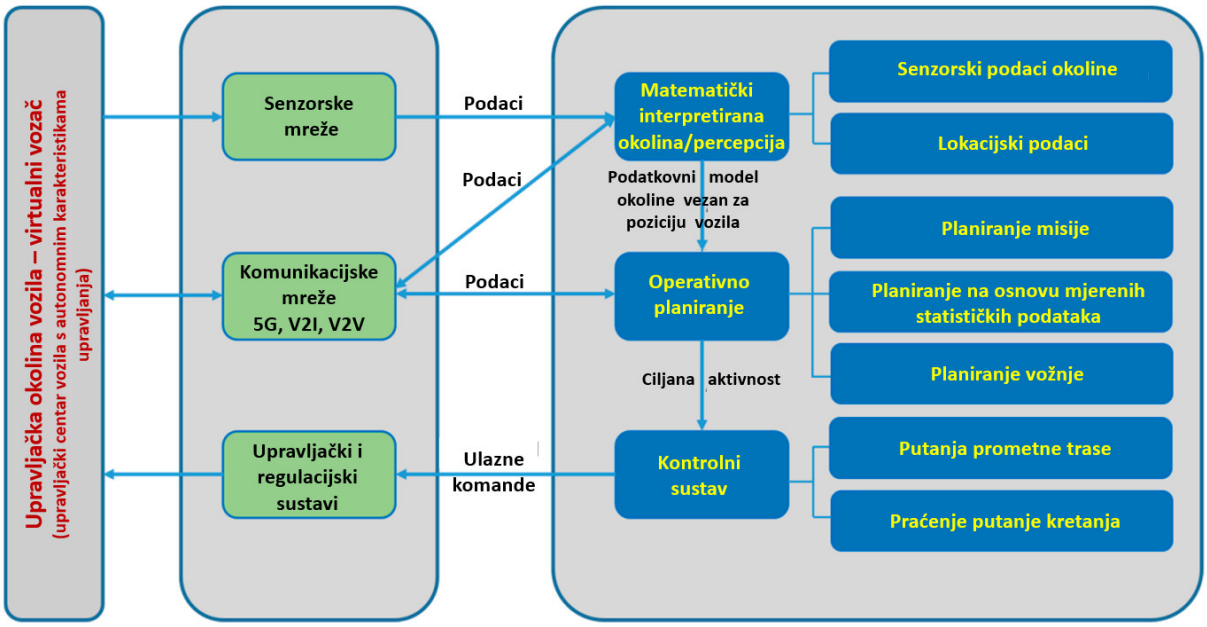

Slika 3. Model upravljanja autonomnim prometnim entitetom sa podrškom senzorskih mreža [36]

Trendovi u prometnoj industriji su uvođenje Interneta stvari (IoT), umjetne inteligencije i Big Data koncepta za podršku upravljanju, te povezivanje komunikacijama nove generacije 5G. Brzi napredak u elektronici, informacijskim i komunikacijskim tehnologijama omogućio je i razvoj vozila s autonomnim upravljanjem, tzv. samovozeća vozila, koja su se inicijalno ispitivala u cestovnom prometu, a sada se testiraju i na željezničkoj infrastrukturi. Model upravljanja kombinira senzore, komunikaciju, te softver za upravljanje i navigaciju (slika 3.) [36].

Prostorna i vremenska informacija o pokretnim prometnim objektima je od velike važnosti za upravljanje vozilom s povećanom autonomnosti upravljanja. U prometnim sustavima trenutno je najveći trend korištenja globalnog navigacijskog satelitskog sustava za informacije o poziciji. Globalni navigacijski satelitski sustav (Engl. Global Navigation Satellite System, GNSS) je standardizirani termin za satelitske navigacijske sustave koji omogućuju autonomno geoprostorno pozicioniranje s globalnom prekograničnom pokrivenošću. Ovaj sustav omogućuje krajnjim terminalnim uređajima ili satelitskim prijenosnim zemaljskim prijemnicima determinaciju njihove trenutne lokacije. Pozicija je određena kroz više informacijskih dimenzija, a to su: zemljopisna širina (Engl. latitude), zemljopisna dužina (Engl. longitude) te nadmorska visina (Engl. altitude) [37].

Nadmorska visina se definira u odnosu na kontekst u kojem se koristi, ali se općenito može definirati kao udaljenost u vertikalnom smjeru između referentnog nivoa i neke točke ili objekta. Vertikalna udaljenost može biti u smjeru prema dolje, pa onda se definira kao dubina, kao što je slučaj kod autonomnih ronilica. Osim ovih pozicijskih informacija, sve više se koristi i brzina kretanja kako ključna informacija dinamike vozila, poglavito u sustavima prediktivnog upravljanja autonomnim sustavima [38]. U suvremenim prometnim sustavima sve više se koriste i prolazni lokacijski senzori, zbog povećane sigurnosti prometno-tehnološkog procesa ili naplate prometnih servisa.

Od postojećih GNSS sustava, navigacijski sustav GPS (Engl. Global Positioning System) sustav je najčešće u upotrebi i točnost određivanja pozicije prijemnika dobivene primjenom ovog sustava mogu biti unutar nekoliko metara, koristeći pritom za lokalizaciju vremenske signale koje duž linije vidljivosti odašilje radio-frekvencijski odašiljački modul sa satelita. Uzroci odstupanja točnosti pozicijskih informacija mogu biti različiti. Odstupanja zbog ionosferskog utjecaja nastaju kada satelitski signal usporava dok prolazi kroz gornje slojeve atmosfere. Sustav se može korigirati da koristi ugrađeni model koji računa prosječno vrijeme

kašnjenja [39]. Odstupanja zbog višestaznog prijema događaju se kada se GPS signal reflektira od objekata, kao što su zgrade ili površine velikih stijena prije nego što stigne do prijamnika. Zbog navedenih ograničenja preciznosti sustava za pozicioniranje, a poglavito u tračničkih vozila pri velikim brzinama, istražuju se i drugi redundantni načini pozicioniranja kao što su 5G komunikacijske mreže. Zbog svoje potpuno nove arhitekture, 5G sustavi mogu dati vrlo precizne lokacijske informacije koje se koriste u strojnoj komunikaciji (Engl. Machine type communication, MTC) s primjenama u raznim digitalnim servisima i sustavima naplate, čime se potvrđuju mogućnosti ovakvih sustava u dinamičkom praćenju klijenata. Stoga se očekuje da bi lociranje (pozicioniranje) tračničkih vozila pri velikim brzinama predstavljalo novo i dinamično područje razvoja i primjena 5G komunikacijskih mreža [40].

Princip pozicioniranja vlakova velikih brzina u novim 5G radio (Engl. New Radio, NR) mrežama, korištenjem specifičnih NR sinkronizacijskih signala prikazan je na slici 4. 5G mreže predstavljaju novu tehnološku mogućnost za pozicioniranje s visokom točnošću i visokom dostupnosti, npr. za potrebe autonomnih vlakova gdje minimalni zahtjevi za dostupnost mogu biti 99,9999%. Globalni navigacijski satelitski sustavi (GNSS) trenutno ne mogu zadovoljiti ove kriterije.

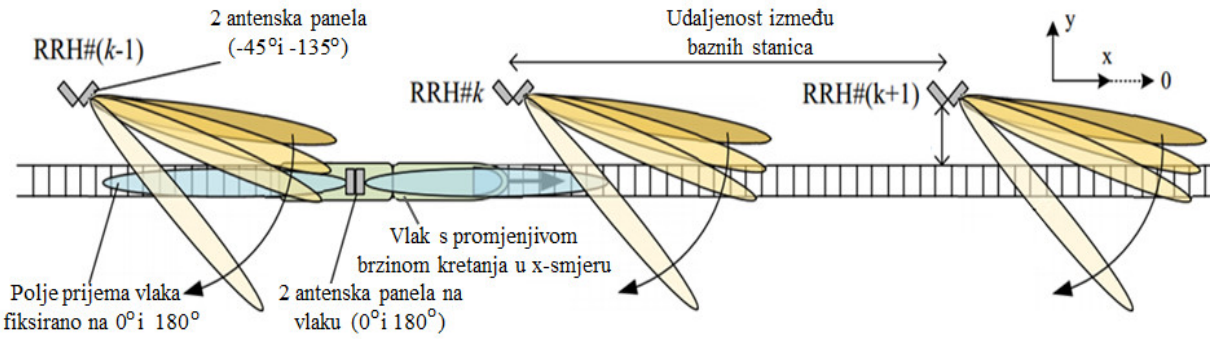

Slika 4. Model pozicioniranja temeljenog na 5G tehnologiji za autonomne vlakove velikih brzina (400 km/h) s točnošću od 1 m i vremenskim intervalima od 5 milisekundi. [40].

Dizajn komunikacijskih mreža pete generacije otvorio je nove mogućnosti za povećanje digitalizacije ljudskog društva, ali poglavito industrije i prometnih sustava koji su zbog svoje važne odrednice mobilnosti dobili potpuno novo tehnološko okruženje za razvoj. Novi dizajn RAN-a (Engl. Radio Access Network) izuzetno je važan za prometne sustave, jer se s novom

5G generacijom komunikacijskih mreža otvaraju nove mogućnosti za širu integraciju takozvanih telematičkih sučelja. Nova generacija pristupnih mreža omogućit će:

a.) holističku (sveobuhvatnu) arhitekturu upravljanja spektrom,
b.) okvir za harmonizaciju radio sučelja koji omogućava efikasnu integraciju novih i postojećih radio sučelja,
c.) okvir za multi-radio sučelja i „multi-slice“ upravljanje resursima,
d.) implementaciju sučelja koji osiguravaju kontinuiranost pristupa (Engl. cross-layer & crossair),
e.) dinamičko upravljanje prometom,
f.) energetski efikasno upravljanje pristupnom mrežom,
g.) upravljanje interferencijom u fiksnim i dinamičkim radio topologijama, te
h.) inovativni pristup u definiranju neaktivnog stanja korisničke opreme (Engl. User Equipment) koje će omogućiti uštedu energije baterije.

Nadalje, 5G dizajn omogućuje zajednički kontrolni okvir i okvir za korisnička rješenja dublje integrirana u komunikacijsku infrastrukturu što otvara nove mogućnosti za tzv. „cross-industry“ rješenja koja su vrlo važna za prometne sustave čija se integracija s drugim industrijskim ili javnim sustavima želi provesti [41, 42].

Očekuje se da će u budućnosti postojati široki raspon rješenja temeljenih na konceptu interneta stvari. Trenutno smo svjedoci brzog razvoja jednog segmenta interneta stvari, a to je tzv. masivni Internet stvari (Engl. Massive IoT) čije komunikacijske zahtjeve zadovoljava i trenutno komercijalno dostupna napredna LTE mreža. Implementacijom 5G sustava, mobilnog širokopojasnog pristupa ekstremnih brzina i robusne povezanosti s niskom latencijom, otvaraju se potpuno nove mogućnosti za podršku autonomnim režimima prometovanja. Na slici 5 prikazana su tehnološka područja s različitim zahtjevima na komunikacijsku mrežu. Na lijevoj strani slike je grupa masivnog interneta stvari, gdje su tehnološki pozicionirane senzorske mreže s malim informacijskim zahtjevima i malim brzinama komuniciranja, ali je cijena upotrebe ovakvih sustava vrlo niska, pa su u poslovnom smislu ovakvi sustavi vrlo prihvatljivi. Ovakvi sustavi se koriste u željezničkoj logistici, održavanju, te prikupljanju informacija za povećanje putničkog korisničkog iskustva. Na desnoj strani slike je grupa kritičnog interneta stvari, koji imaju vrlo visoke zahtjeve za pouzdanost, dostupnost i nisku latenciju. Ovakva rješenja mogu se temeljiti na naprednim LTE ili 5G komunikacijskim mrežama. Volumeni rješenja su tipično razmjerno mali, ali je poslovna vrijednost znatno veća. Primjer ovakvih

rješenja su pametne mreže (Engl. Smart grid) ili prometni sustavi za sigurnost i nadzor (Engl. Traffic safety and control) [43].

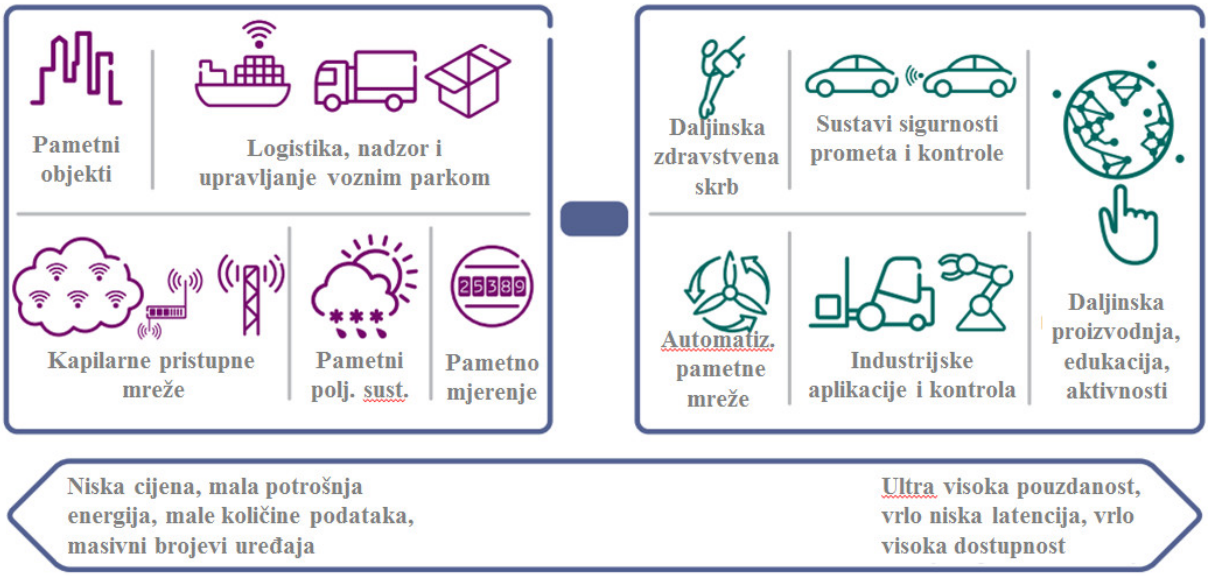

Slika 5. Karakteristike senzorskih mreža za masivne i kritičke aplikacije interneta stvari [43].

Snažan napredak u razvoju senzorskih mreža vidljiv je u svim domenama, a naročito u području prometa gdje je upravo značajna komunikacijska komponenta zbog najvažnije prometne odrednice, a to je mobilnost. Sintagma Internet stvari (Engl. Internet of Things, IoT) ili tehnološki gledano prošireni sustav komunikacije između strojeva ili automata (Engl. Machine to Machine Communication, M2M) zajedno s krajnjim senzorima označava transparentnu integraciju velikog broja heterogenih vanjskih sustava, koji posljedično omogućuju digitalizaciju prometne infrastrukture.

Također, razvojem komunikacijskih sustava prema 5G funkcionalnostima otvaraju se nove mogućnosti u području inteligentnih transportnih sustava [44], poglavito u području upravljanja autonomnim tračničkim vozilima. Pod referencom [45] dan je pregled mogućih tehnologija, protokola i arhitekture inteligentnih sustava temeljenih na konceptu komunikacije vozila (Engl. Vehicular Communication Systems). Nadalje, budući transportni sustavi temeljeni na ne-fosilnim tehnologijama pogona vozila također su usko vezani za sustave pametnih energetskih mreža (Engl. Smart Grid) [46], te 5G softverskih definiranih mreža za vozila, kako navodi referenca [47].

Dosadašnji pristupi razvoju koncepta za masovnu komunikaciju strojeva (engl. Massive Machine-Type Communications) temeljili su se na razvoju IoT platforme . Međutim, takva mreža postavlja specifične zahtjeve za performansama [48], iskazane kroz veće brzine prijenosa, veće količine podataka, smanjenu potrošnju energije, veću kvalitetu usluge i razvoj novih usluga i novih korisnika kao što su strojevi u pokretu. Trenutni razvoj mobilnih informacijsko-komunikacijskih mreža otvara nove mogućnosti u području digitalizacije i autonomnih sustav, pa je ovaj trend rezultirao velikim brojem istraživanja.

Projekt konzorcija "5G - Connected Mobility" pokrenut je s ciljem istraživanja 5G komunikacijskih tehnologija u prometnim sustavima (slika 6.). Članovi konzorcija su Ericsson, Deutsche Bahn, Deutsche Telekom, Vodafone, 5G Lab Germany, Tehničko sveučilište (TU) Dresden, Savezna mrežna agencija (BNetzA), Federalno ministarstvo prometa i digitalne infrastrukture (BMVI), te njihovi partneri [49].

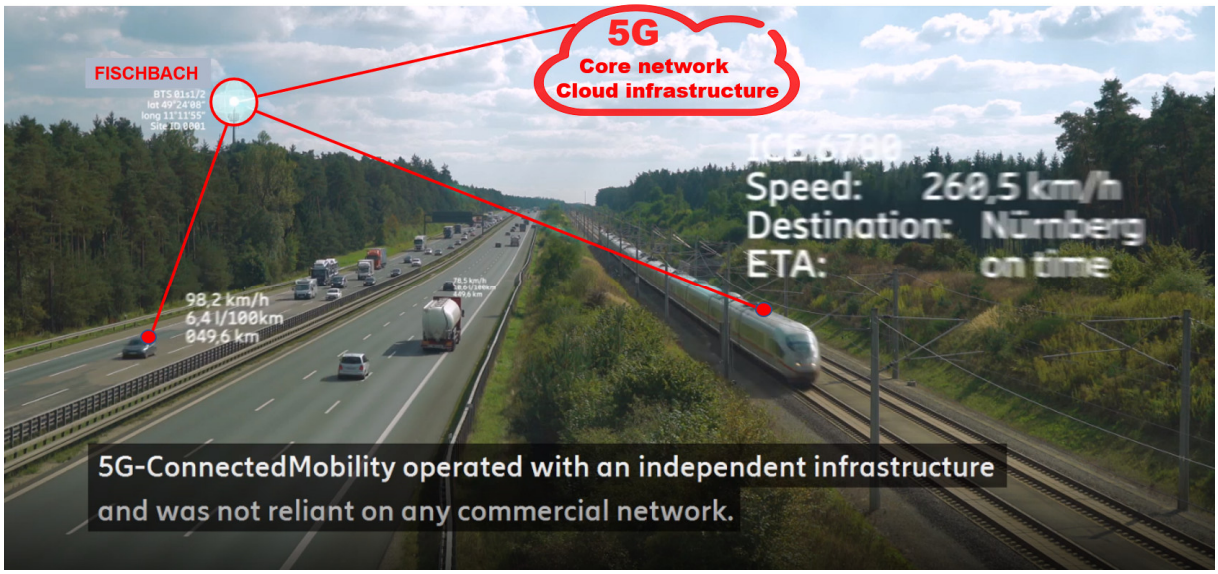

Slika 6. Projekt „5G - Connected Mobility“ u partnerstvu Deutsche Bahn i Ericsson - testiranje senzorskih sustava temeljenih na 5G tehnologijama na brzoj željezničkoj pruzi između Nürnberga-Feuchta i Gredinga u Bavarskoj, Njemačka, [49].

Istraživanja željezničkoga prometa odvijala su se na ispitnoj dionici brze željezničke pruge između čvorova Nürnberg-Feucht i Greding u Bavarskoj, Njemačka. Postignuta je brzina prijenosa podataka od 820 Mbit/s, pri kretanju željezničkoga vlaka do 200 km/h i to u podijeljenoj mrežnoj komunikaciji za tzv. kritične aplikacije s izuzetno malim latencijama (engl. Low-latency communication) ispod 2 ms , što su komunikacijski zahtjevi za autonomna vozila u pokretu [50].

U istoj istraživačkoj mreži implementirane su napredni senzorski sustavi temeljeni na uskopojasnim tehnologijama Narrowband IoT i CAT-M1, prvi put u Njemačkoj i EU. Simulirane su istovremeno funkcije automatskog upravljanja vlakom, nadzora vlakova i multimedijalne zabave putnika u vlaku (digitalne umrežene igre, glazba, HD video). Testovi su provedeni na otvorenoj pruzi (definirani segment), na kolodvorima opremljenim senzorima (slika 7.) i s Deutsche Bahn vlakom (ICE TD klase 605) s hibridnom dizel-električnom vučom. Ovo je trenutno najbrži prometno-istraživački laboratorij na tračnicama („advanced TrainLab - Deutsche Bahn“ (slika 8.), odnosno istraživačko-testni vlak njemačkih željeznica s osnovnom namjenom testiranja inovativnih tehnologija.

Slika 7. Željeznički kolodvor - testiranje komunikacijskih i senzorskih sustava temeljenih na 5G tehnologijama, Deutsche Bahn - Njemačka [51].

Ovaj istraživački vlak ICE TD klase 605 predviđen je za velike brzine prometovanja i opremljen s hibridnim pogonom - dizel-električne vuče (engl. high-speed diesel multiple unit train). Proizvođač vlaka Siemens/Bombardier je prilagodio vlak za istraživačke vožnje na elektrificiranim i na neelektrificiranim pružnim trasama, brzinama do 200 km/h. Vlak je dužine 107 metara, s osovinskim opterećenjem od 15 tona, a sastoji se od dva središnja i dva krajnja pogonska dijela vučne snage 1700 kW (engl. Traction power) i pokretnom trakcijskom silom od 160 kN (engl. Starting tractive effort) [52].

Slika 8. „Advanced TrainLab"- Deutsche Bahn istraživački vlak (ICE TD klase 605) s hibridnim dizel-električnim pogonom opremljen naprednim komunikacijskim i senzorskim sustavima [53].

Ovaj napredni istraživački vlak u partnerstvu Deutsche Bahn-a i Ericsson-a opremljen je antenskim sustavima i digitalnom opremom za testiranje komunikacijsko-signalnih i senzorskih rješenja na temelju 5G i ostalih komunikacijskih tehnologija. U sklopu projekta 5G-Connected Mobility izvršena su početna mjerenja na testnom polju, na ruti između Nürnberga i Ingolstadta.

1.4.5. Vremenski uvjeti, adhezija i otpori gibanja željezničkoga vozila

Razvojem prometnih tehnologija u smislu pokretnih objekata i u smislu infrastrukture, postignuti su veliki uspjesi prevazilaženja prirodno-geografskih barijera. Veliki inženjerski poduhvati su alpske željezničke pruge, npr. prva planinska pruga u Europi izgrađena sa standardnim rasponom tračnica, gdje je bilo potrebno svladati iznimno težak teren i veliku visinsku razliku, a to je željeznička pruga preko Semmeringa u Austriji (Njem. Semmeringbahn) izgrađena 1854. godine, te potom i Raetinska pruga (Njem. Rhätische Bahn) u švicarskom kanton Graubünden, između St. Moritz i Davosa. To su pruge koje prometuju u izrazito teškim vremenskim uvjetima. No, današnji željeznički promet ima snažne zahtjeve na ekonomsku i energetsku optimizaciju, te povećanje sigurnosti i prijevozne točnosti. U

okolnostima klimatskih promjena gdje su očekivani iznenadni ekstremni vremenski uvjeti otvara se potreba istraživanja i prijedloga rješenja za učinkovitiji željeznički prijevoz.

Prema izvješću Hrvatskih željeznica od 09.01.2009. godine (Središnji državni portal, RH Ministarstvo mora, prometa i infrastrukture) stoji sljedeće: zbog iznimno niskih temperatura koje u nekim dijelovima Hrvatske dosežu i minus 18 stupnjeva C, dolazi do poremećaja u željezničkom prometu. Zbog niskih temperatura dolazi do pucanja tračnica, zaleđivanja skretnica, te povećanog broja kvarova vučnih vozila i signala. Zbog svega toga događaju se poremećaji u prometu na cijeloj HŽ-ovoj mreži pruga, a svako pojedinačno kašnjenje izaziva lančanu reakciju i kašnjenje ostalih vlakova na mreži. Na žalost, kašnjenja nekih vlakova su i do 90 minuta, a mjerodavne službe ulažu velike napore kako bi se u slučaju zastoja putnici prevezli što prije prvim sljedećim vlakom ili autobusima [54].

Unatoč većoj dostupnosti i sofisticiranosti vremenskih informacija, te uvođenju novih prometnih tehnologija, nepovoljni vremenski uvjeti i dalje stvaraju značajne probleme željezničkim operatorima. Iznenadne vremenske nepogode predstavljaju značajne izazove prometnim operatorima i trenutni sustavi vremenske prognoze ne omogućuju prometnim operatorima pravovremeni odgovor u smislu izbjegavanja, oporavka i komuniciranja rizika od opasnosti uzrokovanih vremenskim uvjetima. Zbog svega navedenog, smanjenje utjecaja nepovoljnih vremenskih uvjeta na željeznički sustav ima veliki potencijal za prevenciju ili smanjenje ozljeda i smrtnih slučajeva, te smanjenje ekonomske štete koja se može ostvariti pravovremenim i lokacijski određenim informacijama o okolišu prometnog entiteta, a sve sa svrhom potpore odlučivanju u upravljanju željezničkim sustavom prometovanja.

Na temelju statističkih podataka Federalne uprave za željeznice (Engl. Federal Railroad Administration - U.S. Department of Transportation, SAD, Washington) tijekom razdoblja 1995.-2005. dogodio se najmanje 861 željeznički incidenata povezanih s vremenskim uvjetima. Kao što je prikazano u tablici 1., iskakanje iz kolosijeka početna je posljedica u oko 75% svih željezničkih nezgoda povezanih s vremenskim uvjetima.

Preko polovice svih takvih iskliznuća povezano je s ekstremnim visokim temperaturama, prethodnim kišama i prethodnim uvjetima snijega i leda. Iskakanje iz kolosijeka također je generiralo više smrtnih slučajeva i ozljeda, nego druge vrste nesreća [55].

Tablica 1. Željeznički incidenti povezani s vremenskim uvjetima 1995.-2005. USA [55]

Primarna posljedica		Sekundarna posljedica						
Tip nesreće	Broj	Smrtni slučajevi	Ozljede	Vagoni koji voze opasan taret			Broj evakuiranih ljudi	Ukupna šteta ($)
				Ukupni broj	Oštećeni ili izbačeni iz kolosijeka	Oštećen opasan teret		
Iskliznuće iz kolosijeka	660	6	1,223	1,227	289	54	4,147	$163,588,208
Kolizija	46	4	10	43	6	1	0	$6,913,096
Opstrukcija	46	0	4	19	0	0	0	$3,586,681
Požar	1	0	3	0	0	0	0	$35,000
Ostalo	108	0	2	88	18	2	0	$8,726,050
Ukupno	861	10	1,242	1,377	313	57	4,147	$182,849,035

Vremenski uvjeti koji utječu na željezničke nesreće imaju i sezonske karakteristike kako je prikazano na slici 9. Slika ilustrira kako vremenski uvjeti prema godišnjim sezona utječu na željezničke nesreće. Grafikon prikazuje ukupan broj vremenskih nezgoda povezanih s mjesecima, kao i najčešći tip uzročnih događaja po mjesecima. Postoje dva godišnja vrhunca, jedan u siječnju i drugi u srpnju. Tijekom zimskih mjeseci od prosinca do ožujka, najveći broj nesreća nastao je zbog vremenskih uvjeta snijega i leda, koji uzrokuju nakupine, a koje posljedično uzrokuju neispravan rad skretnica i iskakanja iz kolosijeka.

Nesreće tijekom ljetnih mjeseci lipnja, srpnja i kolovoza uglavnom su uzrokovane visokim temperaturama i njihovim utjecajem na deformiranje (dilataciju) tračničkih segmenata. Prijelazni mjeseci poput travnja, rujna i listopada imaju najmanji broja nesreća, gdje kiša i vodom zasićeno tlo predstavljaju u ovom periodu vodeći uzrok željezničkih nesreća.

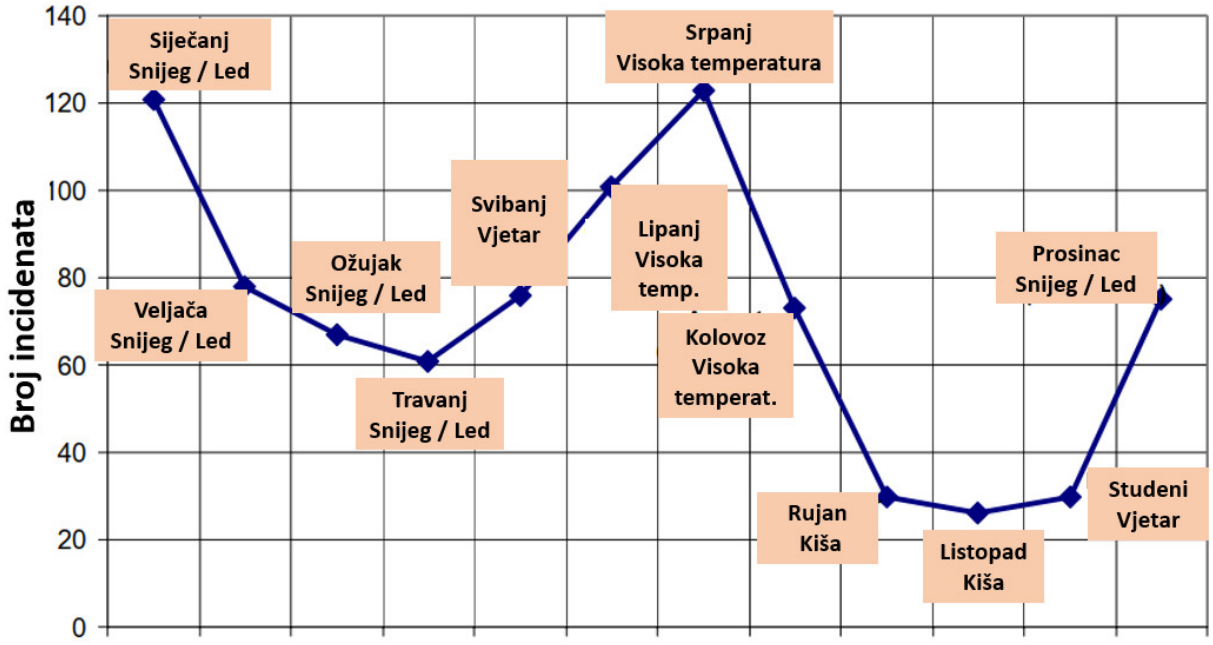

Slika 9. Željeznički prometni incidenti povezani s vremenskim uvjetima po mjesecima u godini i prema najčešćim vrstama uzročnih događaja po mjesecima u periodu 1995.-2005. USA [55].

Na slici 10. prikazana je raspodjela željezničkih incidenata prema dobu dana. Može se uočiti pojava tipičnih obrazaca, npr. od ranog poslijepodneva do 16:00 sati, ekstremna temperatura uzrokuje najveći broj incidenata, a ukupni dnevni maksimum za sve nesreće događa se u 15:00. Od vrlo kasnog poslijepodneva do 21:00, jaki vjetrovi postaju vodeći uzrok željezničkih nesreća. To vjerojatno odražava konvektivno vođenu aktivnost vjetra koja slijedi nakon razdoblja maksimalnog dnevnog zagrijavanja. Od kasne večeri do ranih jutarnjih sati ukupan broj nesreća opada, a neki od njihovih vodećih uzroka postaju prethodno navedeni snijeg i led, odnosno kiša. Kiše, poplave, zasićeno tlo visokom razinom vode, te uragani su u povijesti bili jedni od najistaknutijih čimbenika povezanih s vremenskim uvjetima s kojima se suočava željeznička industrija u SAD-u.

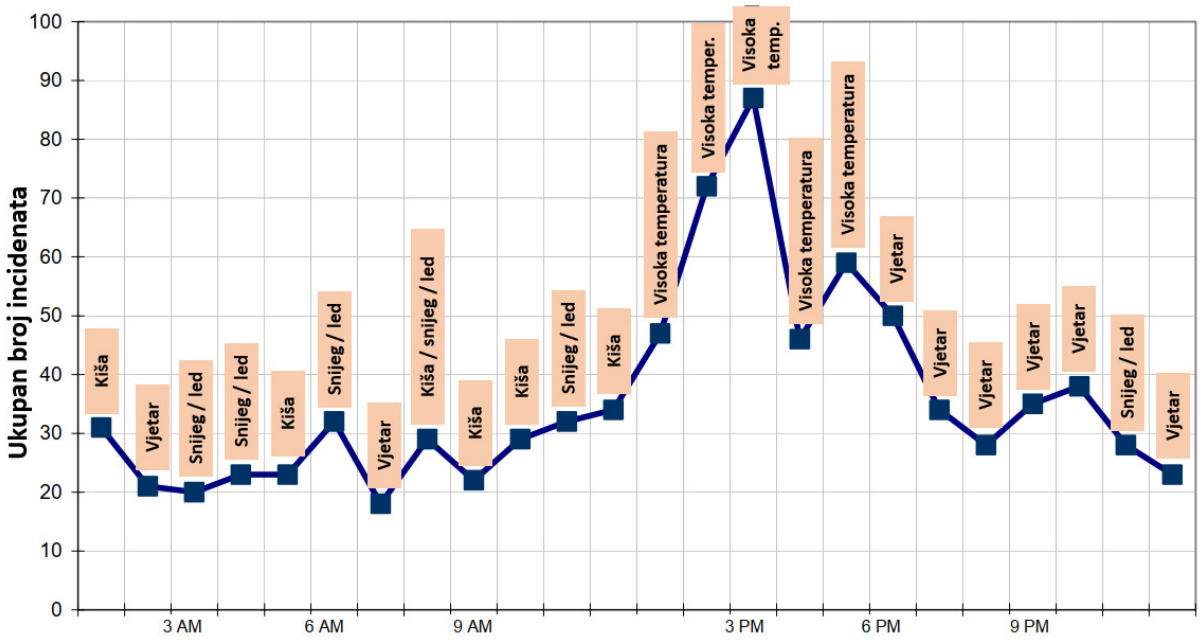

Slika 10. Ukupan broj željezničkih incidenata povezanih s vremenom po satima u danu i po najčešćim vrstama uzročnih događaja po satima u danima, 1995.-2005. USA [55].

Prema navedenom je vidljivo da vremenski uvjeti znatno utječu na željezničke operacije, zbog toga je potrebno znatnije uključiti pružatelje usluga meteoroloških informacija, te pronaći nove načine angažiranja kako bi se razvila rješenja koja će zadovoljiti operativne i sigurnosne potrebe željeznica. Značajan razvoj senzorskih i komunikacijskih 5G mreža mogao bi pridonijeti razvoju modela kojim bi se pravovremeno mogli dobiti kritični podaci o vremenskim uvjetima i integrirati u prometni sustav s ciljem povećanja otpornosti na klimatske promjene i njihove posljedice, tj. negativne vremenske uvjete za željeznički promet.

Maksimalna vučna sila vozila ograničena je maksimalnom karakteristikom adhezije kotača u odnosu na tračnice, te normalnom silom koja djeluje uslijed težine vozila i nagiba trase. Primjer krivulja vučne sile za dizel električnu lokomotivu iz reference [56] za različite položaje "Notch" komande akceleratora (poluge gasa) prikazane su na slici 11. Prikazane karakteristike uspoređuju se za karakteristikama idealne vuče za 100%, 75% i 50% adhezije u odnosu na nominalni slučaj (suhi kolosijek), što ilustrira da je efekt promjenjive adhezije na vučnu karakteristiku dominantan u režimima rada velike snage i pri velikim brzinama. S druge strane, na vozilo djeluju sile aerodinamičkog otpora i sile otpora kotrljanja koji također uključuju i gibanje po zakrivljenoj trajektoriji [57], a koji je specifičan za zakrivljenost trase i

ovisi o radijusu zakrivljenosti *r* i širini kolosijeka. Ovi utjecaji se detaljnije objašnjavaju u poglavlju 2.

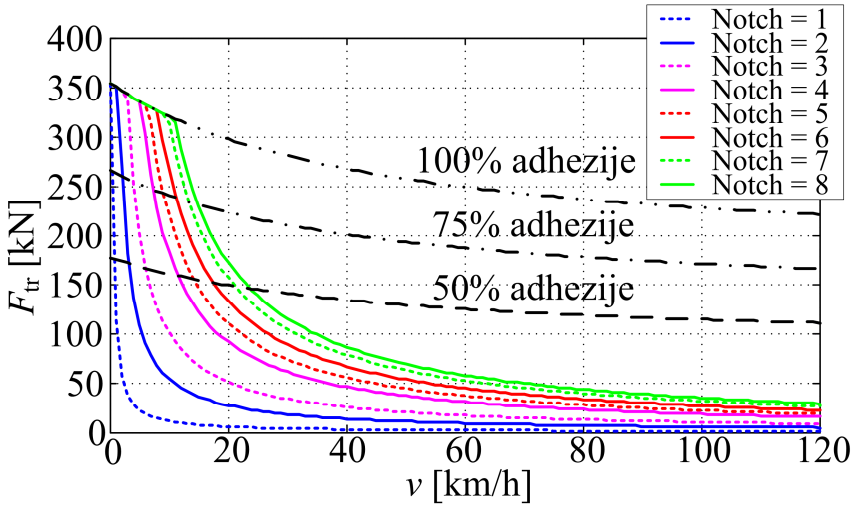

Slika 11. Krivulje maksimalne vučne sile u odnosu na brzinu s položajem akceleratora ('Notch') i adhezijom između kotača i tračnica kao parametrima [56].

Prema referenci [58], koeficijent trenja kontakta čelik-čelik značajno ovisi o temperaturi i relativnoj i apsolutnoj vlažnosti zraka. Štoviše, u referenci [58] pokazano je da postoji jasnija diskriminacija karakteristika koeficijenta trenja s obzirom na apsolutnu vlažnost zraka H_A (koncentraciju vodene pare u g/m^3) nego na relativnu vlažnost zraka H_R, čija je međuveza dana izrazom [58]:

$$H_A = \frac{13.2264 \cdot H_R \cdot e^{\left(\frac{17.67 \cdot T}{T+243.5}\right)}}{T + 273.15} \tag{1-1}$$

koji vrijedi u rasponu temperatura zraka T od –30°C do +35°C.

Budući da je relativna vlažnost zraka povezana s apsolutnom vlažnosti preko temperature T (dane u stupnjevima Celzijusa), odnosno relativna vlažnost je odnos koncentracije vodene pare u odnosu na zasićeno stanje kod kojeg dolazi do ukapljivanja na danoj temperaturi, prikaz koeficijenta trenja u funkciji relativne vlažnosti zraka može navesti na zaključak da se pri nižim temperaturama zraka može dobiti bolja trakcija nego pri višim, kako navodi referenca [58]. Ovo je ilustrirano na slici 12. gdje se prikaz koeficijenta trenja u funkciji relativne vlažnosti zraka rezultira preklapanjem krivulja uz intuitivno upitan rezultat većeg iznosa koeficijenta trenja pri nižim temperaturama. Tek se prikazom koeficijenta trenja

u funkciji apsolutne vlažnosti zraka (slika 13) dobije intuitivno kvalitetniji rezultat gdje se jasno vidi trend bržeg pada koeficijenta trenja pri nižim temperaturama i većim koncentracijama vlage u zraku (tj. vrijednostima apsolutne vlažnosti).

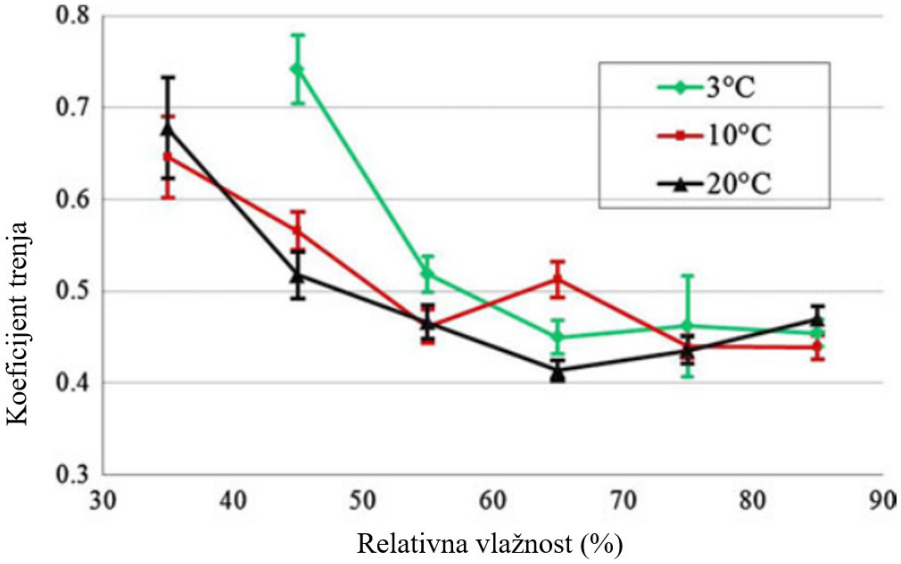

Slika 12. Ovisnost koeficijenta trenja o relativnoj vlažnosti zraka [58].

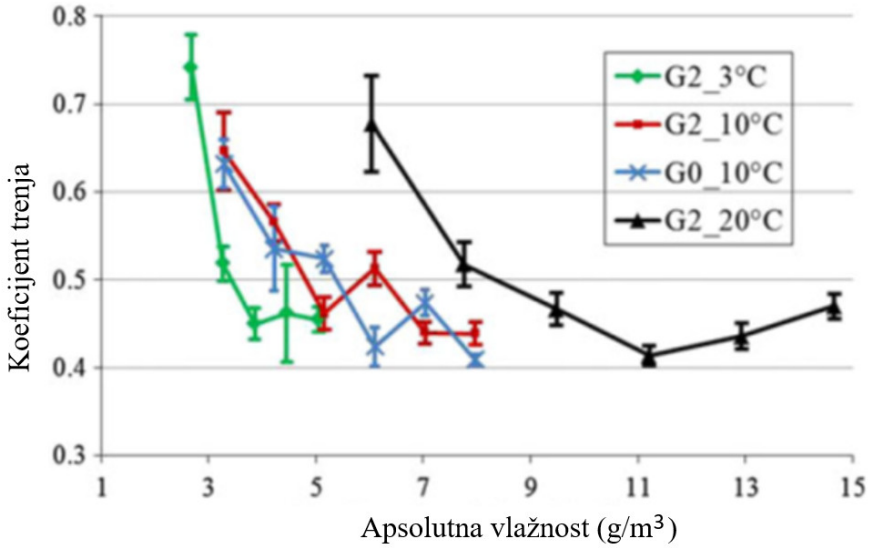

Slika 13. Ovisnost koeficijenta trenja o apsolutnoj vlažnosti zraka [58].

1.4.6. Otpornost na klimatske promjene sustava za upravljanje i optimizaciju željezničkoga prijevoza

Klimatske promjene mogle bi povećati učestalost i ozbiljnost ekstremnih vremenskih prilika, pa je u planiranju i razvoju ove čimbenike važno uzeti u obzir kako bi osigurali sigurnu i pouzdanu mrežu željezničkoga prometovanja.

Klimatske promjene već sada imaju sve veći utjecaj na željeznički promet. Na području Australije i SAD-a sve češći su zastoji zbog ekstremnim toplotnih valova koji bitno utječu na željezničku prometnu infrastrukturu i ugrožavaju sigurnost prometovanja.

Istraživanje koje je 2019 godine objavio prof. Paul Chinowsky (University of Colorado, Boulder, USA) u časopisu „Transport Policy“ predviđalo je da će kašnjenja uzrokovana pregrijanim ili iskrivljenim tračnicama u SAD rezultirati ekonomskim gubicima između 45 i 60 milijardi dolara do kraja stoljeća. Ova kašnjenja, također znače povećane troškove za gorivo (i druge energente) i brojne druge operativne troškove [59].

Prema istraživanju GISS instituta (Engl. GISS - Goddard Institute for Space Studies), New York, SAD - 18 od 19 najtoplijih zabilježenih godina dogodilo se od 2001 do 2020. godine [60]. kako je prikazano na slici 14.

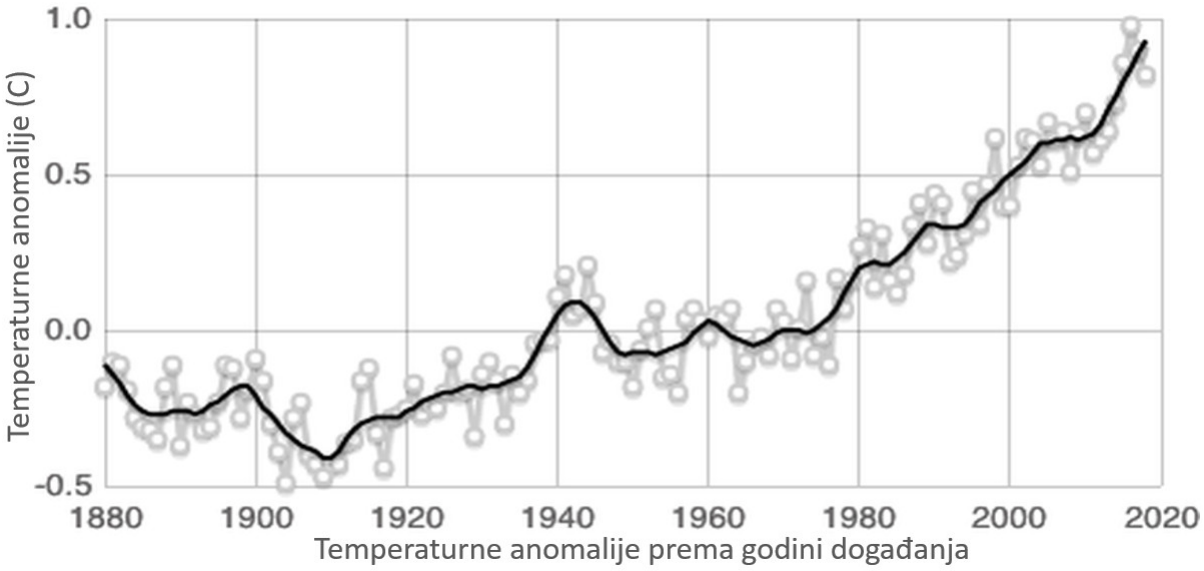

Slika 14. Trend povećanja temperaturnih anomalija od 1880 god. – NASA, GISS Institute, Columbia University, New York, SAD [60].

Ovi podaci istraživanja ukazuju na vrlo značajno povećanje incidencije temperaturnih anomalija s posljedicama na sigurnost i energetsku učinkovitost željezničkoga prijevoza, pa je stoga nužno uložiti istraživačke napore u traženju uspješnog odgovora na navedene klimatske izazove.

Česte i jake poplave posljednjih godina (slika 15.), usmjerile su pozornost na potrebu da se ključna prometna infrastruktura razvija uzimajući u obzir moguće vremenske ekstreme. Kao odgovor, pokrenut je niz istraživačkih projekata s ciljem boljeg razumijevanja rizika promjenjivosti klime i prijedloga na poboljšanju otpornosti i prilagodbi utjecajima okoline na upravljanje željezničkim prometom i njegove efikasnosti.

Slika 15. Zbog iznenadnih olujnih naleta vjetra i poplave zaustavljanje prometovanja vlaka na trasi Totnesa – Plymoutha, UK [61].

Profesori Abkowitz i Hornberger sa Sveučilišta Vanderbilt u Nashvilleu, Tennessee, USA, u svom istraživanju navode sljedeće: utjecaji klimatskih promjena na željezničke transportne operacije su povećani troškovi i odgođeni rokovi isporuke [62]. Transporti tereta osjetljivih na vremenske (meteorološke) uvjete mogu ugroziti vitalnost poslovne zajednice i optimizirane transportne operacije, pa je potrebno primijeniti različite tehnike kako bi se infrastruktura i transportni procesi prilagodili klimatskim događajima.

Procjena utjecaja ekstremnih vremenskih uvjeta na prometne sustave otkriva visoke troškove na određenim mjestima. Istaknuti primjeri za Europu su ekonomske posljedice oštrih zimskih razdoblja 2009/2010 i 2010/2011 te poplave u Austriji, Istočnoj Europi, Njemačkoj i Ujedinjenom Kraljevstvu 2005. i 2007.

Na osnovu istraživanja predložene su tehničke i organizacijske mjere, posebno u alpskom željezničkom prometu, koje imaju velik potencijal za ublažavanje troškova povezanih s vremenskim nepogodama. U velikoj mjeri koriste se napredni informacijski i komunikacijski sustavi [62].

Mjere za ublažavanje klimatskih promjena su energetska učinkovitost pri potrošnji, ali i efikasnija proizvodnja električne energije i naravno pojačano korištenje obnovljivih izvora energije. Korištenje energije iz obnovljivih izvora je vrlo izazovno za prometni sektor, jer se uglavnom zelena energija najviše troši na mjestu proizvodnje.

Istraživački projekt "FLIRT Akku" u suradnji Stadler Rail AG, Tehničko sveučilište u Berlinu i EWE AG istraživali su mogućnosti korištenja baterijskih vlakova. U sjevernoj Njemačkoj, koja većinu zelene energije dobiva iz snage vjetra, na željeznicama se koristi i dalje pretežno koristi diesel-električna propulzija vlakova jer su željezničke pruge uglavnom neelektrificirane.

Slika 16. Stadler „FLIRT Akku“ vlak na baterijski pogon za željezničke rute bez emisije CO_2 [63]

Cilj istraživačkog projekta je bio istražiti mogućnosti upotrebe željezničkih vozila bez emisije CO2, sukladno klimatskim ciljevima EU. Izazovi su bili ograničenja instaliranog kapaciteta baterije i korištenje novih digitalnih tehnologija za upravljanje.

Evelyn Thiel, voditeljica istraživačkog projekta je prenijela sljedeće: ispitivana vožnja vlaka s napajanjem samo iz baterija (slika 16) dosegla je nevjerojatnih 185 km. Testiranje je vršeno uz prometne događaje sustizanja neplaniranih kašnjenja na ruti, te korištenje u ekstremnim vremenskim uvjetima od vrlo niskih zimskih temperatura (ispod -10°C), do ljetnih temperatura koje uključuju i val vrućine gdje su temperature prelazile 40 °C uz punu upotrebu klima uređaja u vlaku [64].

1.4.7. Primjena umjetne inteligencije i neizrazite (fuzzy) logike u automatizaciji željezničkoga prometa

Umjetna inteligencija (eng. Artificial Intelligence - AI) je znanstvena disciplina koja se bavi oblikovanjem računalnih sustava koji primjenjuju inteligentna svojstva ljudskog ponašanja i koji bi trebali uspješno odrađivati zadatke koje trenutno bolje obavljaju ljudi [65].

Može se definirati da je umjetna inteligencija sposobnost tehničkog sustava da interpretira podatke iz vanjskih utjecaja, tj. okoline, te da iz istih podataka uči i upotrebljava ih za postizanje zadanih ciljeva. Napredne strojne mogućnosti, klasificirane kao umjetna inteligencija, danas uključuju uspješno razumijevanje ljudske komunikacije, nadmetanje na strateškoj i taktičkoj razini, autonomno upravljanje pokretnim prometnim entitetima ako postoje podaci o okolini, te inteligentno usmjeravanje u mrežama za dostavu sadržaja. Ovo su vrlo zahtjevne sposobnosti koje se koriste u upravljanju sustavima, pa su zbog toga brojni istraživački projekti upotrebe umjetne inteligencije u prometnim sustavima.

Pod referencom [66] u istraživačkom radu: „Simulacija potrošnje energije u željezničkim sustavima pomoću umjetne inteligencije“ razmatraju se simulacije potrošnje energije u željezničkim sustavima različitim metodama. Rezultati istraživanja su pokazali da testirane metode umjetne inteligencije: neizrazita (fuzzy) neuronska mreža, AI neuronska mreža te vektorsko strojno učenje mogu znatno povećati točnost matematičkih modela.

Metode temeljene na umjetnoj inteligenciji korištene su za izradu modela potrošnje električne energije u odabranim željezničkim sustavima. Dobiveni rezultati sugeriraju da su se pokazatelji točnosti u svim slučajevima pokazali višima nego kada se primjenjuju regresijskih modeli. Najučinkovitijim su se pokazali primjenom neizrazitih (fuzzy) neuronskima mreža (engl. FNN - Fuzzy neural networks) i AI neuronskih mreža (engl. ANN - Artificial neural networks). Dobiveni rezultati sugeriraju da metode umjetne inteligencije omogućuju povećanje

točnosti modela potrošnje električne energije i poboljšavaju upravljanje željezničkim sustavima [66].

Pod referencom [67] opisana je izgradnja matematičkih modela potrošnje električne energije u željezničkom prijevozu korištenjem umjetne neuronske mreže i neizrazite (fuzzy) neuronske mreže. Ovi se modeli temelje na statističkim metodama i teoriji umjetne inteligencije, uključujući umjetne neuronske mreže i neizrazite neuronske mreže, a rezultati predloženih rješenja testirani su na željeznicama i predstavljeni u radu.

Na temelju realiziranog modela prognoze potrošnje električne energije na željezničkim sustavima u periodu od tri mjeseca uspoređujući stvarnu i predviđenu potrošnju za modele ANN i FNN utvrđena je veća preciznost FNN-a (engl. FNN - Fuzzy neural networks) [67].

Jedan od načina povećanja energetske učinkovitosti željezničkog prijevoza je poboljšanje metoda kontrole, racionalizacije i upravljanja postupkom potrošnje električne energije. Rješenje ovog problema podrazumijeva potrebu za razvojem matematičkih modela potrošnje električne energije na željeznicama. Prema literaturi su se pokazale uspješne metode temeljene na umjetnoj inteligenciji, poglavito algoritmi temeljeni na neizrazitoj logici.

Primjer upotrebe neizrazite (fuzzy) logike u željezničkom prijevozu je dan u istraživačkom radu: „Sustav upravljanja brzinom vlaka zasnovan na neizrazitom logičkom kontroleru“, pod referencom [68]. Cilj istraživanja je implementirati neizraziti logički kontroler koristeći Madani i metodu defuzzifikacije centroida, kao regulator brzine vlaka. Rezultati simulacije vlakova s dodatnim otporom pokazali su da sustav koji koristi neizrazite logičke kontrolere ima prosječnu vrijednost pogreške samo 2%.

U radu pod referencom [69] predstavljen je dizajn algoritma upravljanja prometnim entitetima temeljen na neizrazitoj (fuzzy) logici i usmjerenog na smanjenje prometnih kolizija u slučaju djelomičnog ograničenja jedne od dviju trasa prometnog koridora, što je tipičan problem u željezničkom prometu i sustavima osobnog brzog prijevoza s unaprijed definiranim i fiksnim prometnim koridorima. Predloženi neizraziti algoritam upravljanja uspoređen je s konvencionalnim automatom za kontrolu prometa koji ima fiksna trajanja intervala prolaznosti u simulacijskom okruženju za četiri različite vjerojatnosne distribucije stohastičkih prometnih tokova na svakom kraju razmatranog prometnog koridora. Primjena neizrazite (engl. fuzzy) logike može se vidjeti u ekspertnim sustavima, gdje se stručno znanje može predstaviti u obliku lingvističkih pravila AKO-ONDA (engl. IF-THEN). Blokovski dijagram na slici 17. prikazuje

sustav upravljanja zasnovan na neizrazitoj logici koji se sastoji od dva identična neizrazita (fuzzy) regulatora proporcionalno-derivativnog (PD) tipa koji se razmatraju za minimiziranje duljina redova čekanja vozila N_1 i N_2 sa svake strane, unutar razmatranog prometnog koridora. Oba regulatora dobivaju informacije o duljinama redova, odnosno brojevima vozila N_1 i N_2 koja čekaju na suprotnim stranama djelomično zapriječenog koridora (prikupljanje informacija sustavom senzora za detekciju dolaska vozila) i pomoću tih podataka izračunavaju signal razlike u duljinama redova čekanja $e_1(k)$ i $e_2(k)$ za oba smjera prometa (gdje je k korak iteracije koji definira omogućenje prolaska na pojedinom kontrolnom službenom mjestu primjenom jednostavne digitalne logike):

$$\begin{aligned} e_1(k) &= N_1(k) - N_2(k), \\ e_2(k) &= -e_1(k) = N_2(k) - N_1(k). \end{aligned} \tag{1-2}$$

Vremenske diferencije signala razlike duljina u redovima čekanja $\Delta e_1(k)$ i $\Delta e_2(k)$, koje su potrebne za uspostavljanje djelovanja vremenskog derivata unutar neizrazitog regulatora, izračunavaju se na sljedeći način:

$$\begin{aligned} \Delta e_1(k) &= e_1(k) - e_1(k-1) = N_1(k) - N_2(k) - N_1(k-1) + N_2(k-1), \\ \Delta e_2(k) &= e_2(k) - e_2(k-1) = N_2(k) - N_1(k) - N_2(k-1) + N_1(k-1). \end{aligned} \tag{1-3}$$

Na temelju navedenih ulaznih signala svaki neizraziti regulator prilagođava unaprijed definirano trajanje propusnosti T0 svojim doprinosom, prikazanim na slici 17. kao aditivnim vremenskim intervalima $\Delta T_1(k)$ i $\Delta T_2(k)$ koji se izračunavaju za svaki smjer i korak iteracije k u pripadajućim neizrazitim regulatorima. Konkretno, neizraziti regulator za smjer 1 je aktivan (omogućen) za parni korak iteracije k, dok je neizraziti regulator za smjer 2 aktivan za neparni korak iteracije k, pri čemu se parnost i neparnost jednostavno određuju dijeljenjem koraka iteracije k (mod(k, 2) blok na slici 17. Isti se rezultat koristi i za određivanje u kojem će smjeru kretanja vozila dobiti propusnost za određeni korak iteracije upravljačkog algoritma.

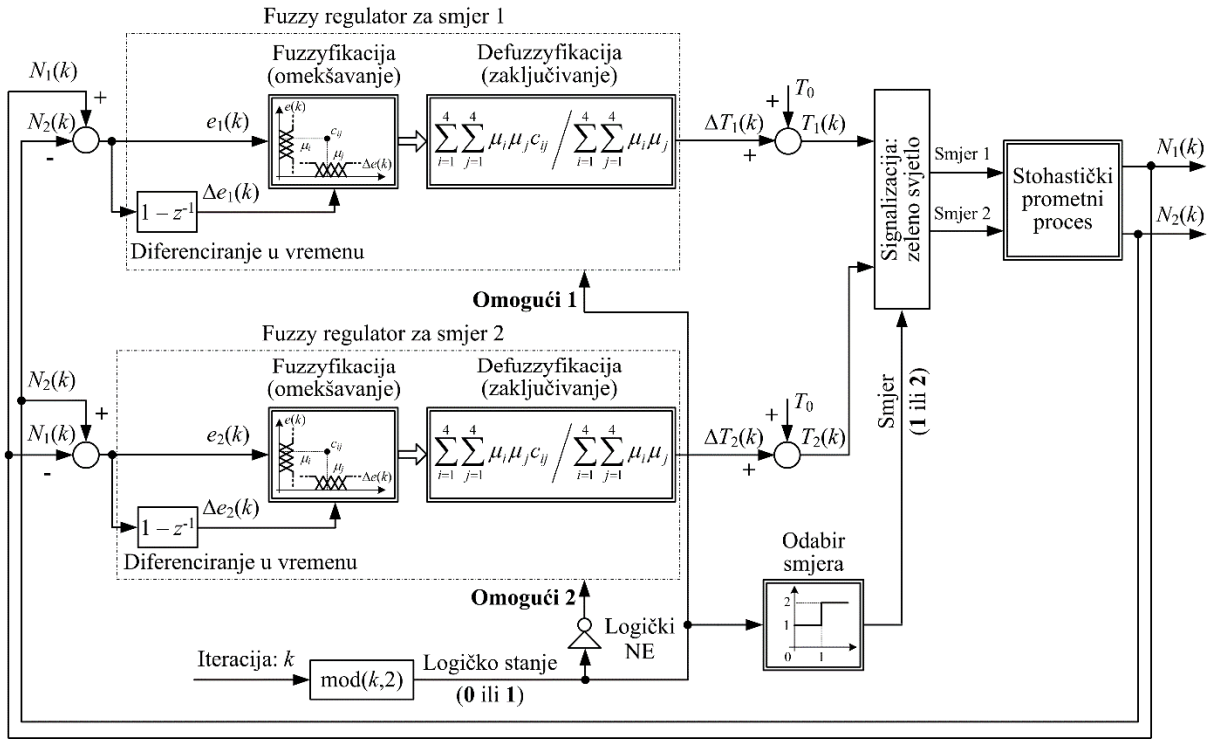

Slika 17. Prikaz blokovskog dijagrama sustava za upravljanje prometom temeljenog na neizrazitoj logici za slučaj zapreke na jednoj jednosmjernoj prometnoj trasi [69].

Lingvistička pravila koja definiraju ulazni dio neizrazitog zakona upravljanja (takozvana fuzzyfikacija ili omekšavanje ulaznih podataka) daju se kako slijedi:

$$\begin{aligned} &\textbf{AKO } e(k) \in \mu_i(e(k)) \ \ \textbf{I} \ \ \Delta e(k) \in \mu_j(\Delta e(k)) \\ &\textbf{ONDA} \ \ \ y(i,j) = g_{ij}(e(k), \Delta e(k)), \end{aligned} \tag{1-4}$$

gdje su $\mu_i(e(k))$ i $\mu_j(\Delta e(k))$ funkcije pripadnosti signala razlike u duljinama redova i njihove vremenske diferencije, a $g_{ij}(\cdot)$ su vrijednosti izlazne funkcije u dijelu neizrazitog regulatora koji provodi zaključivanje (ili defuzifikaciju), a koje su ovdje definirani kao konstantni težinski faktori u izlaznom skupu pravila, tzv. „solitoni“ s konstantnom vrijednošću ($g_{ij}(\cdot) = c_{ij}$). Izlaz svakog PD neizrazitog regulatora izračunava se pomoću sljedeće ponderirane (otežane) sume u bloku defuzzifikacije svakog od neizrazitih regulatora na slici 17 :

$$y_{1,2}(k) = \Delta T_{1,2}(k) = \frac{\sum_{i=1}^{4}\sum_{j=1}^{4} \mu_i(e_{1,2}(k))\mu_j(\Delta e_{1,2}(k))c_{ij}}{\sum_{i=1}^{4}\sum_{j=1}^{4} \mu_i(e_{1,2}(k))\mu_j(\Delta e_{1,2}(k))} \tag{1-5}$$

gdje $\Delta T_{1,2}(k)$ predstavlja prilagodljiva trajanja prolaznosti, kako je prije objašnjeno.

Funkcije pripadnosti $\mu_i(e_{1,2}(k))$ i $\mu_j(\Delta e_{1,2}(k))$ i težinski koeficijenti (solitoni) c_{ij} predloženog dvostrukog neizrazitog regulatora prikazani su na slici 18, 19, 20. i odgovaraju sljedećim skupovima vrijednosti ulaznih signala regulatora $e_{1,2}(k)$ i $\Delta e_{1,2}(k)$: ZN (nula ili negativan), SMP (mali do srednji pozitivan), MLP (srednji do veliki pozitivni) i LP (veliki pozitivni). Funkcije pripadnosti su ili trapezne (ZN i LP skupovi) ili trokutaste (SMP i MLP skupovi), kao što je prikazano na slikama 18 i 19. Solitoni cij u izlaznom dijelu neizrazitog zakona upravljanja (slika 20) dodjeljuju veće težine većim vrijednostima razlika u redovima čekanja vozila ($e_{1,2}(k)$) i njegovim vremenskim diferencijama $\Delta e_{1,2}(k)$, i obratno.

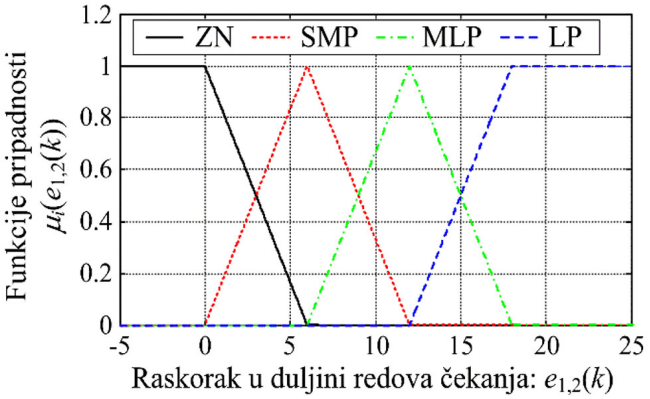

Slika 18. Funkcije pripadnosti neizrazitog regulatora s obzirom na signal razlike reda čekanja [69].

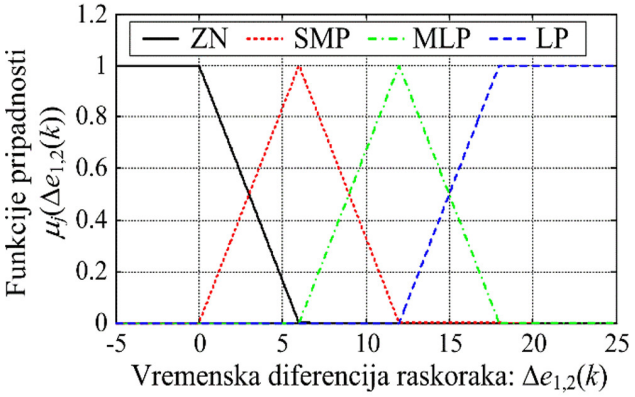

Slika 19. Funkcije pripadnosti neizrazitog regulatora s obzirom na njegovu vremensku diferenciju [69].

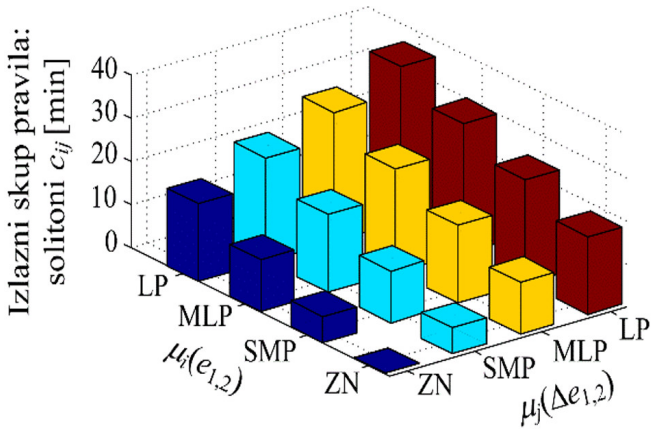

Slika 20. Solitoni u izlaznom skupu pravila pripadnosti neizrazitog regulatora [69].

Navedeni dualni regulator dvosmjernog prometa zasnovan na neizrazitoj logici za slučaj upravljanja u ograničenim prometno-infrastrukturnim okolnostima, verificiran je i uspoređen s konvencionalnim sustavom upravljanja prometom, primjenom računalnih simulacija u programskom paketu Matlab, pri čemu su stohastička vremena dolaska vozila modelirana pomoću četiri različita modela vjerojatnosnih distribucija.

Usporedni rezultati simulacija za prethodno razmatrane stohastičke procese karakterizirane odgovarajućim vjerojatnosnim distribucijama vremena dolazaka vozila, prikazani su na slici 21. Prikazani su usporedni rezultati neizrazitog regulatora i konvencionalnog regulatora prometa za slučaj normalne (Gaussove) vjerojatnosne distribucije vremena dolaska vozila. Rezultati na slici 21. pokazuju značajan pomak oba reda čekanja vozila prema većim duljinama reda, kao i sve veće razlike između duljina redova čekanja vozila N1 i N2 u slučaju kada se koristi konvencionalni regulator prometa. S druge strane, regulator zasnovan na neizrazitoj logici sposoban je značajno smanjiti duljinu reda vozila, kao i učinkovito suzbiti prethodno navedeni trend porasta duljine reda vozila (slika 21b). To se postiže prilagodbom trajanja propusnosti za oba smjera kretanja (vidi graf na slici 21b). Također je vrijedno napomenuti da smjer 1 (karakteriziran prekidom trase) zahtijeva znatno dulje trajanje propusnosti (vidi graf na slici 21b) što je izravno povezano sa zahtjevom preusmjeravanja povezanog dolaznog prometnog toka [69].

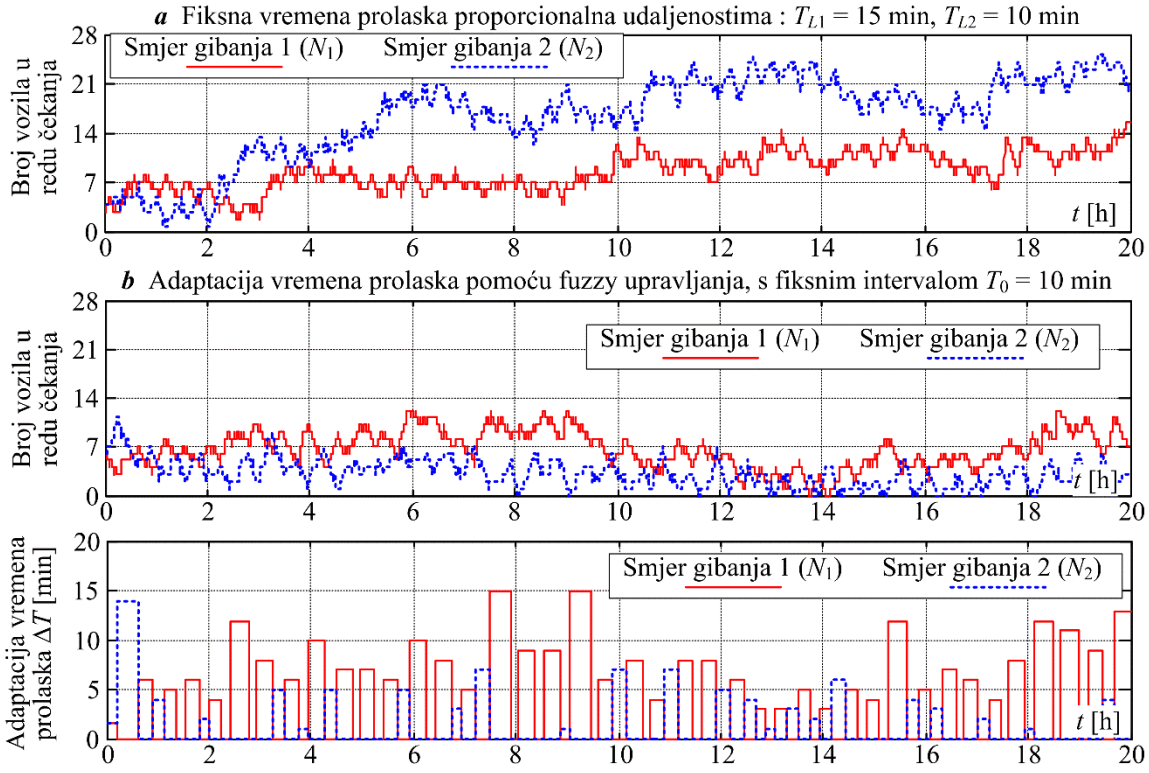

Slika 21. Rezultati dobiveni s konvencionalnim regulatorom (a) i neizrazitim regulatorom (b) za normalnu vjerojatnosnu distribuciju vremena dolazaka vozila [69].

Prethodni rezultati istraživanja ukazuju na superiorne performanse dualnog neizrazitog regulatora za upravljanje prometnim sustavom, koji se može učinkovitije nositi sa stohastičkim dolascima vozila od konvencionalnog upravljanja prometom s fiksnim trajanjem intervala propusnosti. Ovo se poboljšanje sveobuhvatno postiže odabirom prikladnih lingvističkih pravila u ulaznom dijelu zakona upravljanja i izlaznih indeksa. Adaptivni algoritam upravljanja stohastičkim prometnim tokovima temeljen na neizrazitom proporcionalno-derivativnom regulatoru ima prednosti u odnosu na konvencionalno pravilo upravljanja. Upravljanje prometnim tokovima zasnovano na neizrazitoj logici može značajno smanjiti zastoje u oba smjera kretanja prometnih entiteta, te smanjiti raskorak između duljina čekanja za pojedine smjerove kretanja.

Navedena poboljšanja u provedbi upravljanja prometovanjem primarno su posljedica sposobnosti zakona upravljanja temeljenog na neizrazitoj logici da na odgovarajući način klasificira stanje redova čekanja vozila i shodno tome prilagodi duljinu trajanja intervala propusnosti prometnih entiteta. U tom smislu njegov rad podsjeća na proces odlučivanja prometnog eksperta, te će se to svojstvo iskoristiti u radu kasnije, u procesu odlučivanja vezanom za stanje željezničke trase u slučaju promjenjivih vremenskih uvjeta.

2. MODELIRANJE ŽELJEZNIČKOGA PRIJEVOZA NA TRASI BRDSKO-PLANINSKE PRUGE

2.1. Konfiguracija brdsko planinske željezničke pruge

Ovaj odjeljak prikazuje pojednostavljeni profil željezničke rute između Zagreba i Splita, a koja sadrži odsječak trase između Oštarija i Knina, analiziran detaljnije u ovom radu za potrebe procjene energetske učinkovitosti i sigurnosti prometovanja uz primjenu naprednih baterijskih sustava za pohranu energije, te inteligentnih senzora i algoritama upravljanja. Pojednostavljeni profil željezničke rute za longitudinalno gibanje vlaka opisan je u referenci [70], a koja predstavlja službene podatke o ruti koje pruža tvrtka Hrvatske Željeznice (HŽ). Segment željezničke trase od grada Oštarije do grada Knina, a koji odgovara ciljnoj trasi u regiji Like, prikazan je na slici 22a.

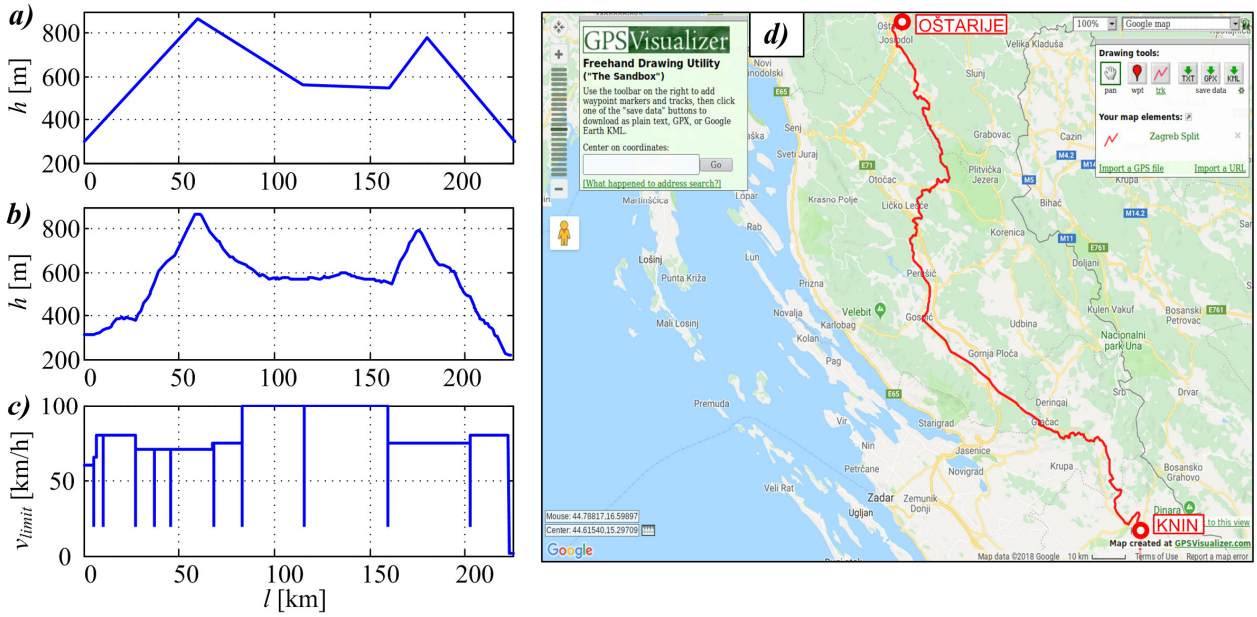

Slika 22. Službeno dostupni pojednostavljeni profil [70], nadmorske visine (a), profil visine generiran iz softvera GPS visualizer (b), profil ograničenja brzine (c) i geografska karta razmatrane željezničke rute (d).

Kako bi se dobio detaljniji i precizniji profil nadmorske visine ključan za proračun otpora gibanju, korišteni su dostupni podaci iz mrežnog programskog paketa GPS Visualizer [71], koji podržava izvoz podataka o ruti koji se odnose na duljinu i nadmorsku visinu u

odgovarajući tablični format. Budući da razmatrana željeznička ruta uključuje mostove, vijadukte i tunele, potrebna je naknadna obrada tako dobivenih podataka kako bi se korigirali podaci o nagibu željezničke pruge. Slika 22b prikazuje konačni profil nadmorske visine dobiven pomoću softvera GPS Visualizer. Ograničenje brzine preuzeto je iz dostupnog internetskog izvora [72], a uključena su i dodatna ograničenja brzine od 20 km/h prilikom prolaska vlaka kroz postaje i kolodvore na danoj ruti, pružajući tako realnije uvjete vožnje vlaka. Konačni profil ograničenja brzine dan je na slici 22c, dok je cjelokupna ruta naznačena na karti prikazanoj na slici 22d.

2.2. Definiranje željezničke rute i vozne misije

U ovom odjeljku opisuje se brdsko-planinska željeznička ruta iz reference [73] koja se i koristi za provedbu simulacijskih scenarija u kojima se ispituju različite konfiguracije pogona teretne lokomotive, kako će biti ilustrirano u poglavlju 3:

- konvencionalnu dizel-električnu lokomotivu
- baterijsku hibridnu dizel-električnu lokomotivu
- potpuno baterijsku lokomotivu
- tandemski rad konvencionalne dizel-električne i baterijske lokomotive

Glavne karakteristike brdsko-planinske željezničke rute između gradova Oštarija i Knina u pogledu visinskog profila (nadmorske visine) i ograničenja brzine koji se koriste u simulacijskom modelu prikazane su na slici 23, gdje crna krivulja predstavlja profil nadmorske visine na ruti (h), dok zelena isprekidana krivulja predstavlja ograničenja brzine željezničkog vlaka (v_{limit}). Navedene su veličine definirane u referenci [73] korištenjem slobodnog internetskog softvera GPS Visualizer [71] i internetskog izvora [72] koji navodi ograničenje brzine na kolosijeku [72]. Dodatne informacije na slici 23 odnose se na relativni koeficijent adhezije između kotača i tračnica k_{va}, odnosno omjer raspoložive adhezije s obzirom na nominalni slučaj, a koji utječe na ukupnu trakciju (svojstva vuče) teretnog vlaka.

Ovisno o simulacijskom scenariju, informacija o relativnom koeficijentu adhezije može ili ne mora biti dostupna modelu vlakovođe (strojovođe), gdje se dostupnost pretpostavlja na temelju podataka s bežične mreže udaljenih senzora (vidi raspravu u sljedećim odjeljcima). Konkretno prikazane vrijednosti relativnog koeficijenta adhezije približno odgovaraju uvjetima adhezije na suhim i mokrim tračnicama.

Budući da se varijabilni koeficijent adhezije μ_a u modelu teretnog vlaka može izraziti množenjem teorijskog rezultata iz [74] s relativnim koeficijentom adhezije k_{va}, to rezultira sljedećim izrazom za koeficijent adhezije:

$$\mu_a = \left(\mu_{\min} + \frac{\beta}{v + \gamma} \right) k_{va} \tag{2-1}$$

gdje μ_{min} = 0,161 predstavljaju minimalnu vrijednost koeficijenta adhezije, a ostale konstante povezane s brzinom parametrirane su kao β = 7,5 km/h i γ = 44 km / h prema referenci [74].

Konačno, plava krivulja na slici 23 predstavlja profil prosječne brzine čeonog vjetra (v_{wind}), za koji se također pretpostavlja da može biti dostupan iz mreže distribuiranih udaljenih senzora (vidi sljedeće odjeljke).

Prema referenci [75], ova dodatna relativna brzina vjetra u odnosu na gibanje vlaka utječe na specifični otpor gibanju (w_{k0}) [N/t]. Zbog iste konfiguracije vlaka kao one korištene u referenci [76], specifični otpor kretanju za teške teretne vlakove može se u ovoj studiji definirati kao:

$$w_k = 25 + 0.0025(v + v_{wind})^2 \tag{2-2}$$

Valja imati na umu da je u minimalna vrijednost aditivne komponente brzine vjetra u gore navedenom modelu v_{wind} = 12 km / h (slika 23), što je prema referenci [75] uobičajena vrijednost u navedenom modelu aerodinamičkog otpora koji se koristi u željeznici.

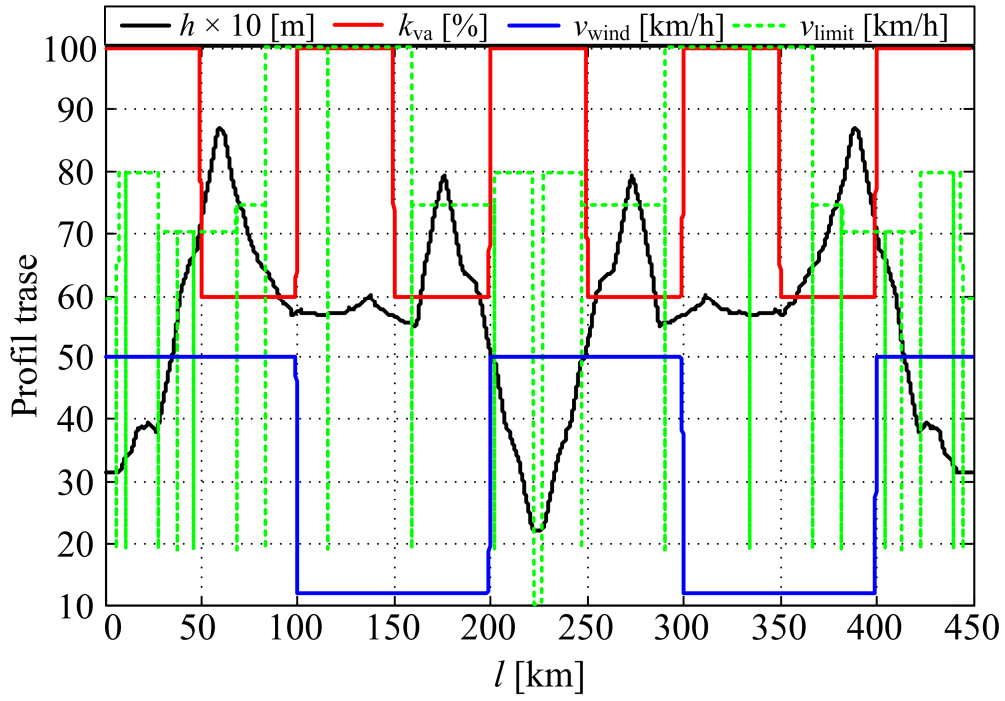

Slika 23. Nadmorska visina, trakcijski koeficijent, brzina vjetra i profili ograničenja brzine vlaka za trasu razmotrenu u ovom radu.

Prema referenci [75], kretanje vlaka također je podložno utjecaju radijusa zakrivljenosti željezničke pruge i širine kolosijeka. Radi jednostavnosti, ovdje je usvojen ekvivalentni konstantni prosječni otpor zakrivljenosti (w_r = 4,99 [N/t]), kako je predloženo u [76].

2.3. Model konvencionalne diesel-električne lokomotive

Željeznički prijevoz neelektrificiranim prugama danas se pretežno temelji na dizel-električnim lokomotivama, čiji se sustav vuče sastoji od dizelskog motora povezanog s glavnim generatorom električne energije, čijom izlaznom snagom (naponom i strujom) se upravlja kako bi se proizveo odgovarajući okretni moment na vučnim motorima (vidi sliku 24.) [75]. Takav prijenos električne energije unutar dizel-električnih lokomotiva karakterizira sustav napona / struje, koji može biti istosmjerni (DC), izmjenični (AC) ili njihova kombinacija, kao što je prikazano u [77], odnosno moguće su sljedeće kombinacije:

• Glavni istosmjerni generator i istosmjerni vučni motori (DC-DC sustav vuče),

• Glavni generator izmjenične struje i istosmjerni vučni motori (AC-DC sustav vuče),

• Glavni izmjenični generator i izmjenični vučni motori (AC-AC sustav vuče).

Međutim, svi prethodno spomenuti sustavi koriste zajedničku istosmjernu sabirnicu za prijenos električne energije između glavnog generatora i vučnih motora [78], a koji mogu biti opremljeni dodatnim energetskim pretvaračima (DC/AC pretvaračima) u slučaju izmjeničnih vučnih motora [79]. Ovakva topologija sa zajedničkom DC sabirnicom je povoljna sa stajališta dodavanja sustava za pohranu energije baterija u svrhu hibridizacije vučnog sustava lokomotive, jer se na taj način olakšava spajanje inherentno istosmjernog baterijskog sustava za pohranu energije, koji se detaljnije opisuje u idućem poglavlju.

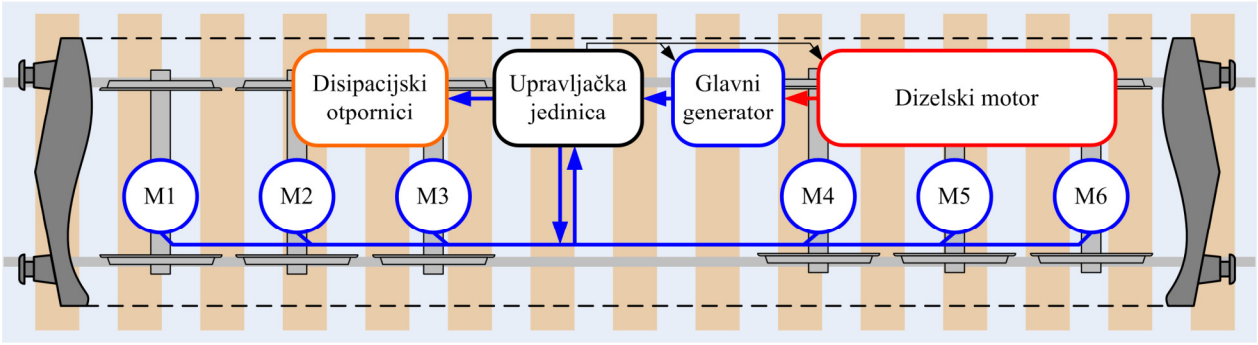

Slika 24. Pojednostavljeni shematski prikaz pogonskog sklopa dizel-električne lokomotive [75].

2.3.1. Karakteristike i statičko ponašanje pogonskih strojeva

Prema referenci [80], dizel-električne lokomotive serije HŽ 2062 obično se koriste preko ličkih željezničkih trasa. Ove lokomotive proizvela je 1970. godine tvrtka General Motors Corporation pod oznakom G26CW, a naknadno su modernizirane početkom 2000-ih. Navedene lokomotive imaju masu od 103 t, a pokreće ih 1641 kW 16-cilindarski dvotaktni dizelski motor (EMD 16-645-E) u sklopu agregata koji može isporučiti električnu energiju za šest vučnih elektromotora spojenih na vučne osovine preko transmisije s fiksnim omjerom prijenosa [80].

2.3.1.1. *Potrošnja goriva i emisije ispušnih plinova*

Realistični podaci o potrošnji goriva i emisijama dizel-električne lokomotive za svaki položaj ručice akceleratora (engl. „Notch“) preuzeti su iz [81]. Ova referenca predstavlja

sveobuhvatan pregled ispitivanja emisija slične dizel-električne lokomotive za tešku vuču iz serije GP38-2, koju je također proizvodila tvrtka General-Motors Electro-Motive Division (EMD) od 1973. nadalje, a primarni izvor energije bio je 2000 KS dizelski motor EMD 16-645-E. Referenca [81] također predstavlja sveobuhvatan pristup provedbi ispitivanja ispušnih plinova lokomotive za četiri različite vrste goriva, a uključuje i detaljan tehnički opis lokomotive odabrane za ispitivanje, kao i mjerenje snage motora, potrošnje goriva i emisije ispušnih plinova. Zbirni podaci temeljnog testa iz [81] navedeni su u tablici 2 nakon pretvorbe iz imperijalnih jedinica (npr. gal., ft., lb. i sl.) u njihove ekvivalentne SI mjerne jedinice.

Tablica 2. Eksperimentalni podaci lokomotive GP38-2 [81].

Položaj akcele-ratora	Snaga glavnog motora P_{mg}(kW)	Brzina glavnog motora ω_e (rad/s)	Snaga električ-ne vuče P_t(kW)	Potrošnja goriva motora $\dot{m}_f$ (g/s)	Emisije ispušnih plinova (g/s)			
					HC	CO	NO_X	CO_2
Pr. hod	7.83	27.02	0	3.1247	0.0364	0.0531	0.1836	9.7154
Notch 1	61.82	33.09	48.69	6.4259	0.0397	0.0653	0.3372	20.4256
Notch 2	283.33	40.84	208.86	16.8837	0.0481	0.1256	0.7861	53.3554
Notch 3	437.28	52.36	386.01	28.7275	0.0792	0.1194	1.4817	90.8920
Notch 4	769.19	60.11	688.62	49.6431	0.1014	0.1828	2.9736	157.3038
Notch 5	956.88	67.75	843.79	62.7469	0.1381	0.3714	3.9292	198.5396
Notch 6	1174.18	76.65	1026.93	78.1186	0.1936	1.1792	4.8725	245.8126
Notch 7	1412.21	86.50	1221.39	96.7663	0.3133	2.7028	5.9336	302.4819
Notch 8	1596.00	94.88	1363.59	114.9010	0.4031	5.0500	6.3678	356.1055

Za odabrani tip dizelsko-električne lokomotive strojovođa upravlja polužnim mehanizmom akceleratora (upravljačem motora) s 8 položaja (tzv. „Notch“). Svaki „Notch“ odgovara konstantnoj snazi na glavnom istosmjernom generatoru, čiji je uzbudni strujni krug podešen kako bi se održala unaprijed definirana snaga dizelskog motora (brzina i okretni moment) [75] (oznake „x“ na slici 2). Praznom hodu, odnosno neutralnom položaju akceleratora odgovara vrijednost „Notch“ = 0. Slika 25a prikazuje postotak generirane snage na svakom položaju poluge akceleratora navedenom u tablici 2, za koji se pretpostavlja da je isti za bilo koju veličinu motora.

Iako se većina mehaničke snage koju generira dizelski motor koristi za pogon glavnog generatora kako bi se osigurala električna snaga za vučne motore, manji postotak se koristi za napajanje različitih pomoćnih uređaja (npr. pumpi, ventilatora i zračnog kompresora) [77]. U ovom radu ukupna učinkovitost pretvorbe mehaničke u električnu snagu opisana je nominalnim koeficijentom učinkovitosti povezanim s postotkom nazivne snage $\eta_{el}(\%P)$, radi lakše

preglednosti prikaza rezultata. Ovaj koeficijent neovisan je o veličini motora i može se definirati kao omjer između izlazne snage $P_o(\%P)$ i ulazne snage $P_i(\%P)$ kako slijedi:

$$\eta_{el}(\%P) = \frac{P_o(\%P)}{P_i(\%P)} \tag{2-3}$$

čime se implicitno uključuje i potrošnja snage na pomoćnim uređajima.

Na slici 25b. prikazana je vrijednost koeficijenta iskoristivosti izvedenog iz omjera snage električne vuče uzete iz 4. stupca i snage glavnog motora iz 2. stupca tablice 2 za svaki „Notch“ položaj akceleratora, uzimajući u obzir odnos između „Notch“ položaja akceleratora i postotka snage prikazanih na slici 25a.

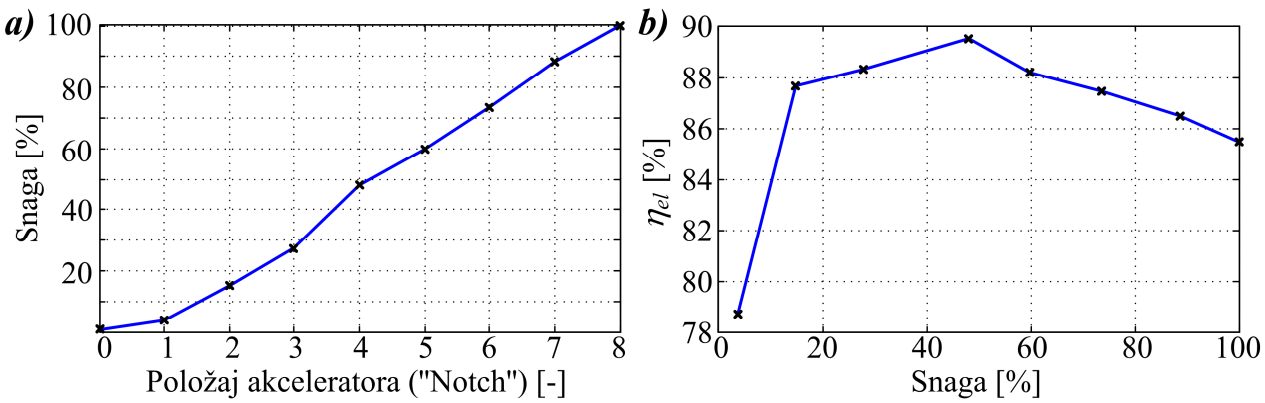

Slika 25. Snaga lokomotive u odnosu na položaj poluge akceleratora (a) i učinkovitost pretvorbe električne energije (b).

2.3.1.2. *Opći pristup skaliranju pogonskih komponenata*

Prema podacima u tablici 2., maksimalna snaga glavnog motora (povezana s krajnjim položajem akceleratora „Notch“ = 8) razmatrane dizel-električne lokomotive (P_{mgMAX} = 1641 kW) neznatno se razlikuje od maksimalne snage referentne lokomotive (P_{mgMAX0} = 1596 kW). Kako bi se razvio sveobuhvatni pristup skaliranju veličine glavnog pogonskog dizelskog motora (dizelskog agregata) za bilo koju lokomotivu, u ovom je odjeljku predložen skalabilni model glavnog generatora. U tu se svrhu potrošnja goriva dizelskog motora u stacionarnom stanju može parametrirati pomoću statičke mape potrošnje goriva, pri čemu protok goriva ovisi o radnoj točki motora (tj. brzini motora ω_e i okretnom momentu motora τ_e):

$$\dot{m}_f = f(\omega_e, \tau_e) \tag{2-4}$$

Kako bi se dobila skalabilna karta potrošnje goriva, predlaže se aproksimacija na temelju takozvanih Willansovih linija. U referenci [82] se toplinska snaga motora P_f (tj. maseni protok goriva pomnožen s donjom graničnom ogrjevnom vrijednosti goriva) aproksimira polinomom drugog reda za svaku radnu točku brzine vrtnje motora, dok se okretni moment motora i ukupni gubici linearno skaliraju s faktor skaliranja s_{mg}. Ovaj pristup je dovoljno precizan ako je veličina skaliranog motora bliska izvornom, kako sugerira referenca [83]. Konkretno, aproksimacija masenog protoka goriva može se zapisati kao:

$$\dot{m}_f(\omega_e, \tau_e) = c_2(\omega_e)\frac{\tau_e^2}{s_{mg}} + c_1(\omega_e)\tau_e + c_0(\omega_e)s_{mg} \tag{2-5}$$

gdje su $c_2(\omega_e)$, $c_1(\omega_e)$ i $c_0(\omega_e)$ koeficijenti kutne brzine prethodno navedene polinomske aproksimacije. Faktor skaliranja s_{mg} predstavlja omjer između snage skaliranog motora P_{mgMAX} i snage izvornog motora P_{mgMAX0}, definirane kako slijedi:

$$s_{mg} = \frac{P_{mg\mathrm{MAX}}}{P_{mg\mathrm{MAX0}}} \tag{2-6}$$

Stoga metoda aproksimacije primjenom Willansove linije prvo treba pronaći odgovarajuće vrijednosti koeficijenata aproksimacije polinoma drugog reda c_0, c_1 i c_2 za svaku vrijednost kutne brzine ω_e i okretnog momenta τ_e, te za faktor skaliranja $s_{mg} = 1$ u jednadžbi (2-5). To se može postići numeričkim rješavanjem sustava jednadžbi za svaku točku podataka o okretnom momentu i brzini vrtnje u izvornoj statičkoj mapi potrošnje goriva motora, na primjer, primjenom metode najmanjih kvadrata [84]. Zbog nedovoljnih podataka, mapu potrošnje goriva EMD-645-E trebalo je rekonstruirati na temelju mape potrošnje goriva za sličan dizelski motor, preuzete iz reference [75]. Ova se statička mapa zatim prilagođava da zadovolji poznate vrijednosti potrošnje goriva u petom stupcu u tablici 2, a rezultirajući konačni koeficijenti aproksimacije ovisni o brzini za ciljni motor EMD-645-E prikazani su na slici 26a. Umetanjem dobivenih koeficijenata polinomske aproksimacije (slika 26a) u jednadžbu (2-5), maseni protok

goriva može se predstaviti kao stopa goriva potrošnje (slika 26b) ili specifična potrošnja goriva po jedinici proizvedene energije (slika 26c), pri čemu oznake '+' označavaju pojedinačne položaje akceleratora ("Notch" pozicije), kao što je objašnjeno u prethodnom odjeljku.

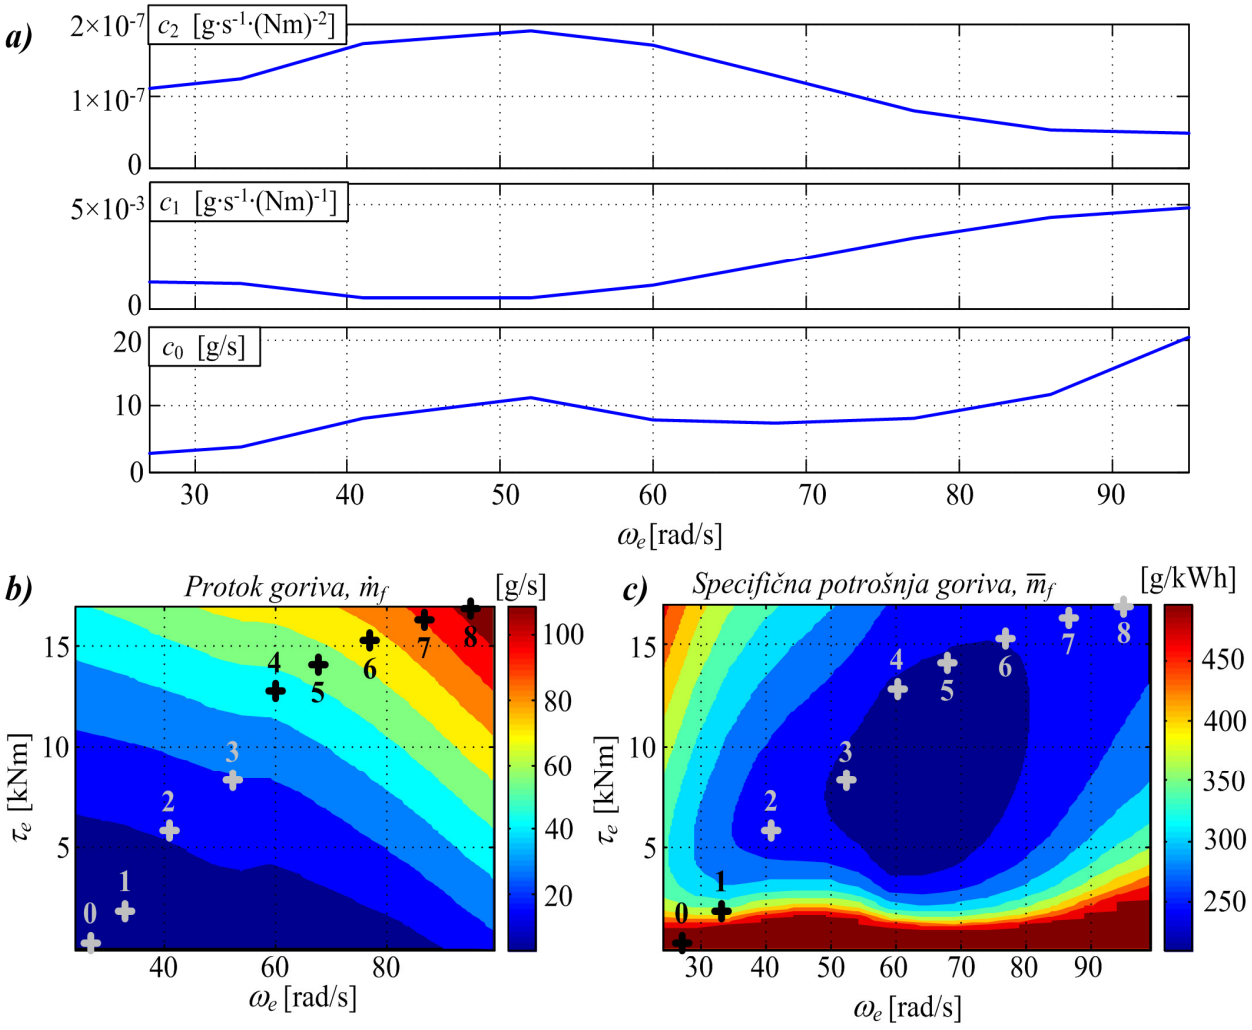

Slika 26. Koeficijenti polinomske aproksimacije u ovisnosti o kutnoj brzini motora (a), mapa trenutne potrošnja goriva u g/s (b) i specifična potrošnja goriva izražena u g/kWh (c).

2.3.1.3. *Emisije plinova*

Referenca [81] prikazala je analizu emisija ispušnih plinova lokomotiva, uključujući ugljikovodike (HC), ugljični monoksid (CO), ugljični dioksid (CO_2) i dušikove okside (NO_X). Vrijednosti ovih stopa emisije za svaki položaj akceleratora („Notch“) i stacionarno stanje dizelskog motora dane su u tablici 2. Kako bi se ove vrijednosti koristile u skalabilnom modelu dizelskog motora, stope emisije za svaki položaj akceleratora iz tablice 2 izražene su kao

funkcije postotka maksimalne snage i normalizirane s obzirom na maseni protok goriva (koji je također povezan s postotkom maksimalne snage), što rezultira sljedećom definicijom koeficijenta emisije:

$$\varepsilon_{HC,CO,NO_X,CO_2}(\%P) = \frac{\dot{m}_{HC,CO,NO_X,CO_2}(\%P)}{\dot{m}_f(\%P)} \tag{2-7}$$

Slika 27. prikazuje vrijednosti svakog od koeficijenata (za HC, CO, CO_2 i NO_x) u odnosu na postotak maksimalne snage motora. Općenito govoreći, koeficijenti emisije ugljičnog monoksida i dušikovih oksida pokazuju značajan porast s povećanjem snage motora (slike 27b i 27c), dok u slučaju ugljikovodika i ugljičnog dioksida ovaj trend porasta ili nije naglašen (slika 27a), ili pokazuje blagi pad (slika 27d). Za veće vrijednosti izlazne snage motora, trend smanjenja krivulje emisije ugljičnog dioksida korelira s trendom porasta krivulje ugljičnog monoksida, što sugerira da nepotpuno izgaranje može biti primarni uzrok takvog odstupanja emisija CO_2 pri postavkama velike snage. S druge strane, krivulje emisija za male vrijednosti snage također malo odstupaju od idealnih (gotovo konstantnih) vrijednosti, što se može objasniti povećanjem emisija čestica (čađe) u ispuhu motora. To se obično događa kod većih iznosa masenih protoka goriva kada dizelski motor radi s malom izlaznom snagom, odnosno pri malim brzinama vrtnje [85].

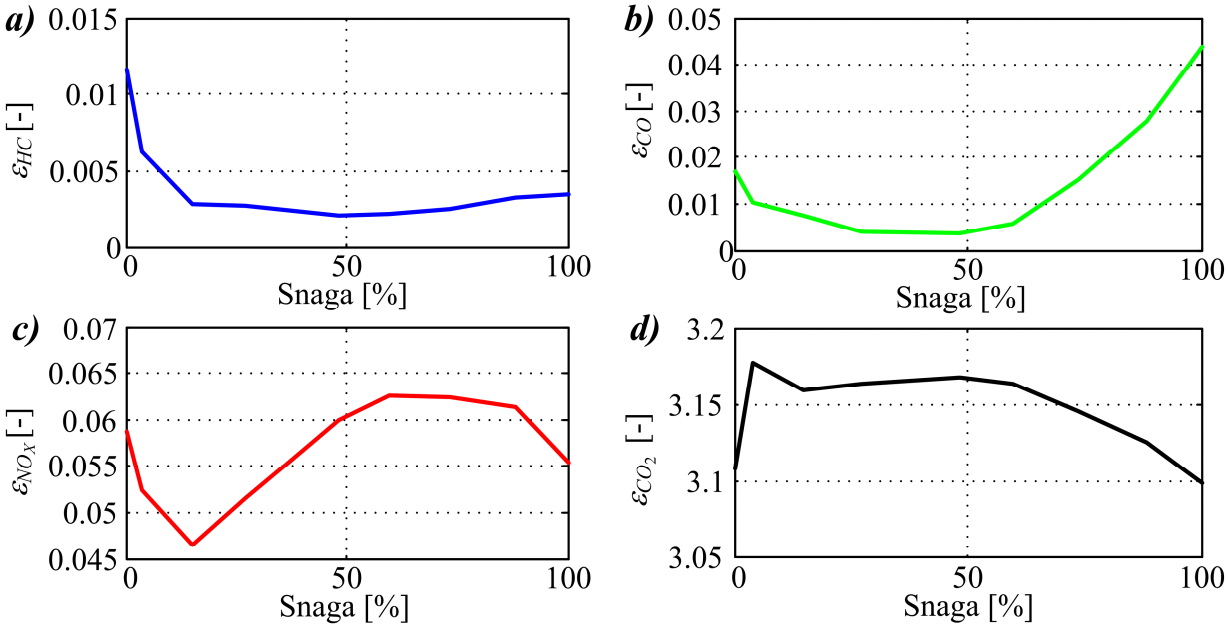

Slika 27. Normalizirane emisije ispušnih plinova lokomotive za (a) ugljikovodike (HC), (b) ugljik-monoksid (CO), (c) dušikove okside (NO_X) i (d) ugljik-dioksid (CO_2).

2.3.1.4. *Procjena mase podvozja i cijene agregata lokomotive*

Primjenom gore opisanog postupka aproksimacije na podatke mjerenja u tablici 2. za sličnu dizel-električnu lokomotivu [81], uzimajući pritom vrijednost koeficijenta skaliranja $s_{mg} = P_{mgMAX}/P_{mgMAX0} = 1641/1596 = 1{,}02823$ (vidi jednadžbu (2-6)), konačni rezultati aproksimacije dani su u tablici 3. Rezultirajuća masa glavnog motora i agregata je $m_{mg} = 22{,}52$ t, izračunata prema jednadžbi (2-8), pa je bazna težina (podvozja) lokomotive $m_{lb} = m_l - m_{mg} = 80{,}48$ t (gdje je masa lokomotive $m_l = 103$ t kao što je prethodno navedeno).

Referenca [86] daje težinu (masu) glavnog dizelskog motora EMD-645. Međutim, kako bi se uzeo u obzir kompletni sklop glavnog motora, uključujući i generator i upravljačku jedinicu, podaci o nekoliko agregata u rasponu snaga od 400 kW do 800 kW preuzeti su iz kataloga [87]. Na temelju kataloških podataka dobiva se sljedeća linearna regresija odnosa snage i težine:

$$m_{mg} = a \cdot P_{mg\mathrm{MAX}} - b \quad [\mathrm{t}] \tag{2-8}$$

gdje je P_{mgMAX} maksimalna snaga glavnog motora u kW (što odgovara položaju poluge akceleratora „Notch“ = 8), dok su u gore navedenom izrazu vrijednosti koeficijenata linearne regresije $a = 0.014$ t/kW i $b = 0.45$ t.

Prema jednadžbi (2-8), masa dizelskog motora snage 1596 kW koji se nalazi unutar lokomotive obrađene u referenci [81] iznosi 21.89 t, dok masa 16-cilindarskog EMD motora prema referenci [86] iznosi 16.5 t. Stoga se može pretpostaviti da se uočena razlika odnosi na masu glavnog generatora i jedinice za upravljanje sustavom električne vuče.

Za izračunavanje ukupnih troškova glavnog motora i agregata korišteni su podaci o specifičnim troškovima iz reference [88], pri čemu se specifični troškovi motora procjenjuju na $C_e = 15$ EUR/kW, dok se specifični troškovi električnog generatora procjenjuju na $C_g = 30$ EUR/kW, što daje sljedeću procjenu troškova:

$$C_{mg} = \left(C_e + C_g\right) \cdot P_{mg\mathrm{MAX}} \quad [\mathrm{EUR}] \tag{2-9}$$

Tablica 3. Približni podaci za G26CW dizel-električnu lokomotivu

Položaj akcelera-tora	Snaga glavnog motora P_{mg} (kW)	Snaga električne vuče P_t (kW)	Trenutna potrošnja goriva $\dot{m}_f$ (g/s)	Emisije ispušnih plinova (g/s)			
				HC	CO	NO_X	CO_2
Prazni hod	8.05	0	3.2131	0.0374	0.0546	0.1888	9.9810
Notch 1	63.56	50.02	6.6242	0.0409	0.0673	0.3476	21.0561
Notch 2	245.05	214.71	17.3520	0.0494	0.1290	0.8079	54.8354
Notch 3	449.62	396.92	29.3608	0.0809	0.1221	1.5143	92.8959
Notch 4	790.90	708.11	51.0394	0.1042	0.1879	3.0572	161.7280
Notch 5	983.90	867.66	64.5594	0.1420	0.3821	4.0427	204.2746
Notch 6	1207.33	1055.88	80.3542	0.1992	1.2129	5.0119	252.8473
Notch 7	1452.07	1255.92	99.7743	0.3231	2.7868	6.1181	311.8848
Notch 8	1641.00	1402.08	118.0862	0.4142	5.1896	6.5438	365.9487

2.3.2. Model električne trakcije lokomotive

Električna vučna snaga lokomotive (treći stupac u tablici 3) razvija se na vučnim elektromotorima, koji posljedično generiraju vučnu silu na kotačima. Budući da se prethodno navedeno odnosi na pretvorbu električne u mehaničku snagu, tijekom analize također treba uzeti u obzir i učinkovitost ove pretvorbe. Radi jednostavnosti, pretpostavlja se da je ova učinkovitost jednaka učinkovitosti η_{el} pretvorbe mehaničke u električku snagu na generatoru. Prema tome, električna snaga vučnog pogona za svaki položaj poluge akceleratora stvara sljedeću vučnu silu:

$$F_t = \frac{3.6 \cdot \eta_{el}(\%P) P_t}{v} \tag{2-10}$$

gdje je v uzdužna brzina lokomotive zadana u km/h, a P_t električna snaga sustava vuče izražena u vatima (W).

Međutim, gornji izraz podliježe dodatnom ograničenju vezanom uz maksimalnu vučnu silu zbog karakteristike prianjanja kotača u odnosu na željezničke tračnice. Prema referenci [89], koeficijent adhezije može se izraziti kao (vidi jednadžbu (2-1) uz $k_{va} = 1$):

$$\mu_a = \mu_{\min} + \frac{\beta}{v + \gamma} \tag{2-11}$$

s minimalnim koeficijentom prianjanja u gornjoj jednadžbi $\mu_{min} = 0.161$, te konstantama vezanim uz brzinu gibanje čiji su iznosi $\beta = 7{,}5$ km/h i $\gamma = 44$ km/h.

Prema tome, vučna sila ograničena je okomitom (normalnom) silom uslijed težine lokomotive $m_l \times g$ kako slijedi:

$$F_{t\max} = \mu_a m_l g \cos(\alpha) \approx \mu_a m_l g \tag{2-12}$$

gdje je α nagib kolosijeka koji se tipično nalazi unutar ±2.5 stupnjeva [70], što opravdava gornju aproksimaciju ($\cos \alpha \approx 1$ vrijedi u tom slučaju).

Iz prethodnih jednadžbi dobivene su krivulje maksimalne vučne sile za svaki položaj akceleratora („Notch“) koje su prikazane na slici 28a, gdje se za slučaj regenerativnog kočenja pretpostavljaju iste vrijednosti sila kočenja, samo s negativnim predznacima. Odgovarajuće krivulje snage električne vuče prikazane su na slici 28b.

U slučaju regenerativnog kočenja (negativne vrijednosti snage), vrijednosti električne snage su manje, jer treba uzeti u obzir i odgovarajuću učinkovitost pretvorbe. Naime, režim regenerativnog kočenja učinkovit je samo pri većim brzinama gibanja (npr. iznad 20 km/h) jer je tada inducirana elektromotorna sila u vučnim motorima dovoljno velika da generira dovoljnu struju kočenja. Stoga područje kočenja ispod 20 km/h karakterizira smanjeni potencijal regenerativnog kočenja, što u tom slučaju zahtijeva istodobnu primjenu mehaničkih kočnica. Svakako treba imati na umu da se u slučaju konvencionalne dizel-električne lokomotive ta kočna snaga rasipa na opteretnim (disipacijskim) otpornicima [77].

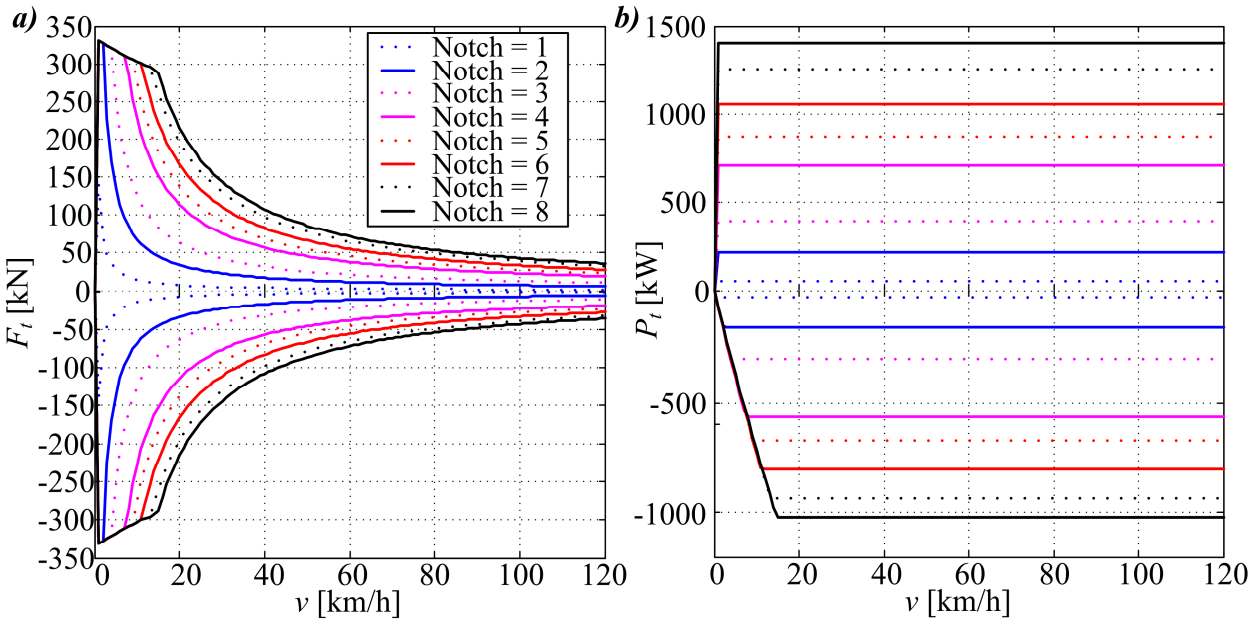

Slika 28. Statičke mape maksimalne vučne sile (a) i maksimalne snage (b) sustava vuče.

2.3.3. Modeliranje uzdužne dinamike gibanja

Budući da dinamika vlaka za uzdužno gibanje ovisi o vučnoj sili lokomotive, kočnoj sili vlaka, topografiji i radijusu zakrivljenosti kolosijeka, vrsti lokomotive i vagona i njihovoj povezanosti, takav složeni dinamički sustav može se općenito opisati sustavom diferencijalnih jednadžbi [77]. U ovom se radu uzdužna dinamika vlaka pojednostavljuje na gibanje koncentrirane mase vlaka. Tako pojednostavljeni dinamički model uzdužne dinamike uključuje aerodinamičke otpore, sile otpora kotrljanja kotača i gravitacijske sile zbog nagiba kolosijeka koje treba nadvladati ukupnom vučnom silom lokomotive F_t [75], što je opisano sljedećom dinamičkom jednadžbom:

$$F_t - F_b = \frac{dv}{dt} m_a + m_a g \sin\alpha + \frac{m_a}{1000}\left(w_k + w_r\right) \tag{2-13}$$

gdje je F_b sila koja djeluje na kočnice (jednaka 0 tijekom normalnih uvjeta vožnje). Član na desnoj strani $(dv/dt)\ m_a$ je sila (u njutnima) uslijed ubrzanja ukupne mase vlaka m_a (izražene u kg), dok drugi član odgovara gravitacijskoj sili zbog nagiba kolosijeka, gdje se $\sin\alpha$ može izraziti kao omjer između promjene nadmorske visine i s njome povezane prijeđene udaljenosti ($\sin\alpha = (h_{n+1} - h_n) / (l_{n+1} - l_n)$). Konačno, treći član s desne strane sadrži članove w_k i w_r koji

predstavljaju specifične koeficijente otpora gibanju u uzdužnom smjeru, odnosno po zakrivljenoj putanji. Prema referenci [75] specifični otpor uzdužnom gibanju definiran je kao:

$$w_k = w_{k0} + k\left(\frac{v + v_d}{v_0}\right)^2 \quad [\text{N/t}] \tag{2-14}$$

uz w_{k0} = 25 N/t, v_0 = 10 km/h, i gdje je k koeficijent konfiguracije tipa vlaka (u ovom radu pretpostavlja se k = 0.25 N/t, što vrijedi za brze vlakove i teške teretne vlakove [75]), dok je vd doprinos brzine čeonog vjetra u km/h (v_d =12 km/h se obično koristi, kako je dano u [75]).

Otpor specifičan za zakrivljenost trase prema referenci [75] ovisi o radijusu zakrivljenosti r i širini kolosijeka. Za standardnu širinu kolosijeka ovaj se koeficijent može izraziti kao:

$$w_r = \frac{w_{r0}}{r - r_0} \quad [\text{N/t}] \tag{2-15}$$

Kako bi se pojednostavilo računanje otpora gibanju povezanog sa radijusom zakrivljenosti, pretpostavlja se konstantna prosječna vrijednost radijusa zakrivljenosti. Ova vrijednost se izračunava iz poznatih granica radijusa zakrivljenosti koje se kreću od R_1 = 250 m što odgovara minimalnom propisanom radijusu krivulje trase željeznice [90] do maksimalne vrijednost R_2 = 4250 m, koristeći sljedeću formulu za osrednjavanje:

$$\overline{w_r} = \frac{1}{R_2 - R_1}\int_{R_1}^{R_2} \frac{w_{r0}}{r - r_0}\,dr = \frac{w_{r0}}{R_2 - R_1}\ln\frac{R_2 - r_0}{R_1 - r_0} = 4.99 \quad [\text{N/t}] \tag{2-16}$$

2.3.4. Ukupni model teretnog vlaka i model strojovođe

Na slici 29. prikazan je blokovski dijagram kvazi-statičkog modela teretnog vlaka opremljenog konvencionalnom dizel-električnom lokomotivom, gdje su specifični pod-modeli uokvireni isprekidanim linijama. Pod-model dinamike vlaka za uzdužno gibanje je prethodno opisan, dok je pod-model pogonskog sklopa modeliran korištenjem statičkih karakteristika (statičkih mapa) izvedenih u prethodnom odjeljku. Blok vučne sile (vidi sliku 28a) daje na izlazu vučnu silu F_t povezanu s brzinom vlaka v preko odgovarajuće statičke mape i odabirom

položaja akceleratora na temelju modela strojovođe (modela vozača) kao ulaznih podataka statičke mape. Blok statičke mape vučne snage (vidi sliku 28b) koristi iste ulaze za izračunavanje električne snage sustava vuče P_t, dok blok modela motora izračunava maseni protok goriva i masene protoke (trenutne vrijednosti) emisija ispušnih plinova za odabrane vrijednosti položaja akceleratora („Notch“).

Model strojovođe (model vozača) izračunava komande gasa (akceleratora) i kočenja na temelju razlike između referentne brzine v_{ref} i stvarne brzine vlaka v (vidi na primjer model strojovođe u referenci [91]). Zakon upravljanja gasom (akceleratorom), a koji predstavlja ponašanje realnog vozača, modeliran je kao jednostavni proporcionalni član (regulator) s vrijednošću proporcionalnog pojačanja K_{Dr} = 8, što osigurava da pogreška slijeđenja brzine bude manja od 1 km/h u stacionarnom stanju. Izlaz modela vozača kvantizira se kako bi njegov rezultat bile cjelobrojne vrijednosti povezane s položajima poluge akceleratora, te je njegov izlaz također ograničen („Notch“ se može naći u rasponu između –8 i +8 na slici 29).

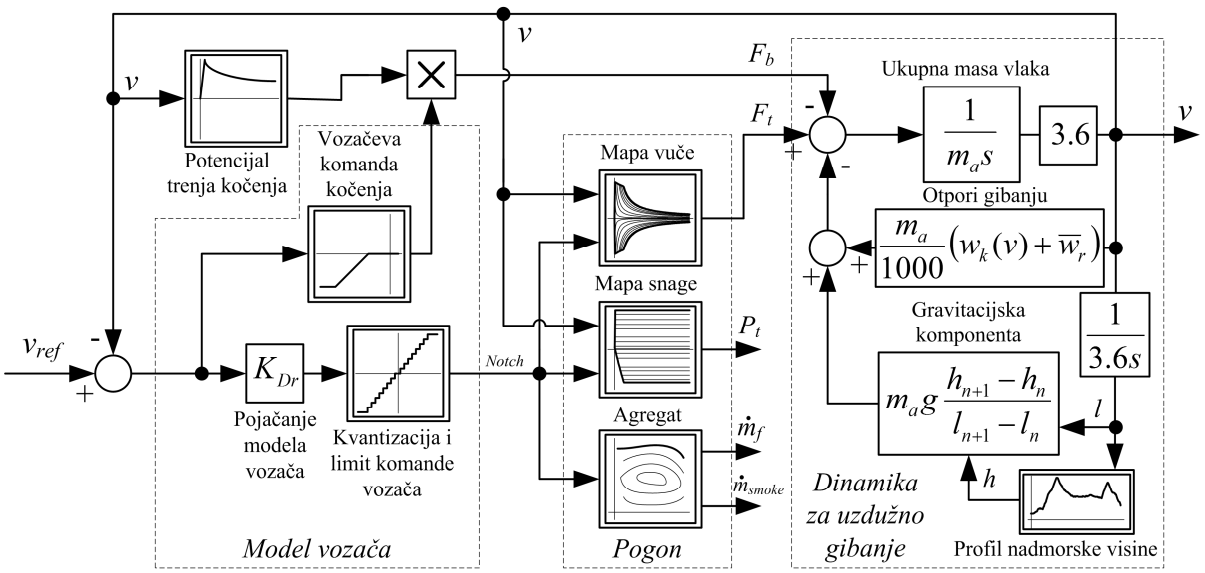

Slika 29. Blokovski dijagram kvazi-statičkog modela vlaka s modelom strojovođe (vozača) koji upravlja konvencionalnom dizel-električnom lokomotivom.

Rezultirajuća particija odgovara 8 pozitivnih vrijednosti akceleratora za normalnu vožnju (vidi sliku 26.), jedan neutralni položaj akceleratora (Notch = 0) za slučaj praznog hoda dizelskog motora i 8 negativnih vrijednosti za slučaj elektro-dinamičkog kočenja primjenom disipacijskih (opteretnih) otpornika. U slučaju usporavanja, kada elektro-dinamičko kočenje ne može održavati brzinu vlaka unutar granica od 5 km/h iznad željene vrijednosti, potrebno je primijeniti dodatno kočenje mehaničkim kočnicama, što je također modelirano kao proporcionalna naredba kočenja strojovođe, koja je vezana za potencijal kočenja na kotačima, a koji je izražen kao ukupna težina vlaka pomnožena s gravitacijskom konstantom i koeficijentom adhezije između kotača i tračnica prema jednadžbi (2-11).

2.4. Model hibridne diesel-električne lokomotive

U ovom poglavlju opisuje se predložena baterijsko-hibridna dizelsko-električna konfiguracija lokomotive u kojoj se baterija odgovarajuće veličine i kapaciteta koristi za pohranu procijenjenog potencijala povrata energije kočenja. Zbog dodatne snage baterije, glavni dizelski motor može se do neke mjere reducirati, pri čemu baterijsko-hibridna lokomotiva zadržava iste vučne performanse, dok se masa (težina) lokomotive također zadržava unutar zadanih granica.

2.4.1. Kvazistatistički model baterije

Zbog iznimne gravimetrijske gustoće energije i trajnosti, litij-ionska (Li-Ion) tehnologija baterija uzima se u obzir za naknadnu ugradnju u baterijsko-hibridne dizel-električne lokomotive. Model baterije izveden je iz modela ekvivalentnog strujnog kruga baterijske ćelije prikazanog na slici 10a, što rezultira sljedećim poznatim izrazom koji veže snagu baterije i stanje napunjenosti baterije (pohranu energije) [92]:

$$\frac{dSoC}{dt} = \frac{\sqrt{U_{oc}^2(SoC) - 4R(SoC,i)P_{batt}} - U_{oc}(SoC)}{2Q_{\max}R(SoC,i)} \tag{2-17}$$

gdje je $0 \leq SoC \leq 1$ stanje napunjenosti baterije, Q_{max} je nabojski kapacitet baterije, a P_{batt} je električka snaga na bateriji. Unutar predloženog modela baterije, napon otvorenog kruga U_{oc} i unutarnji otpor R ovise o stanju napunjenosti (SoC), dok unutarnji otpor ovisi i o smjeru struje (tj. ovisi o tome puni li se baterija ili se prazni) [52].

Za slučaj pražnjenja i relativno malog otpora baterije, gornji izraz pojednostavljuje se u sljedeći tip integracijskog modela SoC baterije:

$$\frac{dSoC}{dt} = \frac{\sqrt{U_{oc}^2(SoC) - 4R(SoC,i)P_{batt}} - U_{oc}(SoC)}{2Q_{\max}R(SoC,i)} \tag{2-18}$$

pri čemu je brzina promjene SoC baterije omjer između trenutne potrebe za snagom Pbatt i trenutne uskladištene energije (član u nazivniku izraza s desne strane).

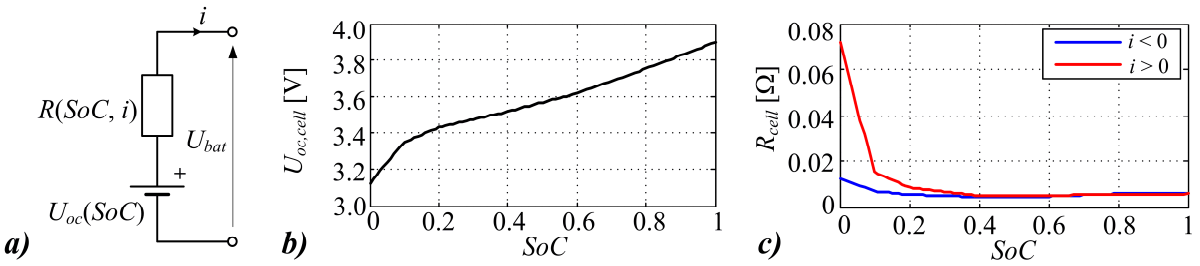

Slika 30. Model ekvivalentnog strujnog kruga baterije (a), napon otvorenog kruga u odnosu na stanje napunjenosti (b) i unutarnji otpor u odnosu na stanje napunjenosti i smjer struje (c).

Karakteristike napona i unutarnjeg otpora otvorenog kruga, preuzete iz programskog paketa Autonomie, prikazane su na slikama 30b i 30c za jednu Li-Ion baterijsku ćeliju. Pretpostavlja se da je baterija spojena izravno na zajedničku istosmjernu sabirnicu, pa se snaga baterije u izrazu (2-18) izračunava na sljedeći način:

$$P_{batt} = P_t - P_g \tag{2-19}$$

gdje je P_g snaga glavnog generatora. Također treba imati na umu da pozitivne vrijednosti P_{batt} odgovaraju pražnjenju baterije i obratno.

Veličina i kapacitet pohrane energije u bateriji imaju dominantni utjecaj na domet i performanse vozila [94]. Prvi redak u tablici 4 prikazuje parametre Li-Ion ćelija (poput energije

jedne ćelije E, nabojskog kapaciteta Q_{max}, maksimalne snage P_{max} i mase m), koji se dobivaju iz podataka Li-Ion baterije korištene u [95] s obzirom na broj ćelija u razmatranom baterijskom sustavu. Kako bi se izračunao potreban broj ćelija za baterijsko hibridnu dizel-električnu lokomotivu, može se koristiti maksimalna vrijednost potencijala povrata energije tijekom kočenja sa slike 9c, što rezultira približno 500 kWh kapaciteta pohrane energije. Međutim, potrebno je dodatno predimenzionirati bateriju radi 50% rezerve energije (750 kWh) kako bi se osiguralo da je njena energija dovoljna da pokrije različite zahtjeve u vožnji, a također i da bi se izbjeglo duboko pražnjenje baterije. Štoviše, kako bi se uzelo u obzir neizbježno smanjenje kapaciteta uzrokovano starenjem komponenata (ćelija), također je uključeno i dodatnih 20% rezerve energije, što konačno rezultira sa 900 kWh konačnog kapaciteta pohrane energije baterije. Ovaj iznos kapaciteta pohrane zahtijeva N = 15000 baterijskih ćelija, a koje su raspoređene u 75 paralelnih blokova od po 200 ćelija spojenih u seriju (kako bi se dobio željeni operativni napon na zajedničkoj DC sabirnici između 620 V i 780 V). Konačno, množenjem mase i kapaciteta ćelije s brojem ćelija N, izračunavaju se ukupna masa i kapacitet baterije koji su navedeni u tablici 4.

Tablica 4. Parametri Li-Ion baterijske ćelije i predloženog baterijskog sustava za pohranu energije.

	N	E (kWh)	Q_{max} (Ah)	P_{max} (kW)	m (kg)
Ćelija	1	0.06	15.9	0.4	0.63
Baterija	15000	900	1192.5	6000	9450

Kako bi se izračunao trošak nabave predložene Li-Ion baterije, najprije treba procijeniti njezin specifični trošak koji ovisi o aspektima korištenja baterije i same baterijske tehnologije, a koji je posljednjih godina pokazao snažan trend pada cijena baterija. Prema referenci [96], u 2016. godini ukupni troškovi ugradnje sustava za pohranu energije za Li-Ion baterijski sustav za priključak na elektroenergetsku mrežu (stacionarne baterije) bili su između 200 USD/kWh i 1260 USD/kWh, a što približno odgovara rasponu između 177 EUR/kWh i 1113 EUR/kWh za trenutni omjer EUR/USD od 1/1.132. Referenca [96] također predviđa da bi troškovi baterijskih sustava i dalje nastavili opadati, te bi se vjerojatno našli u rasponu između 77 USD/kWh i 574 USD/kWh do 2030. godine. Prema referenci [97], troškovi sustava baterija za primjene u električnim vozilima (EV) u 2016. godini također su se kretali između 203 i 415 USD/kWh, s predviđanjem trenda smanjenja njihovih cijena tijekom sljedećih nekoliko godina do 200 USD/kWh (177 EUR/kWh).

U svrhu modeliranja troškova baterijskog sustava za pohranu energije u ovom radu, specifična cijena predložene baterije procijenjena je na c_{batt} = 200 EUR/kWh, što odražava opadajuće trendove troškova baterijskih sustava i činjenicu da je prikazano istraživanje usmjereno na buduće projekte naknadne ugradnje, odnosno modernizacije dizel-električnih lokomotiva. Ova niža procjena troškova posebno zadovoljava oba raspona troškova (to jest, ona koja se odnose na stacionarne baterije i baterijske sustave u vozilima) jer se budući troškovi baterije procjenjuju na 200 EUR/kWh ili manje prema podacima navedenim u referencama [96] i [97]. Stoga se trošak baterije izračunava prema sljedećem izravnom izrazu:

$$C_{batt} = c_{batt} \cdot E_{batt} \quad [\text{EUR}] \tag{2-20}$$

gdje je E_{batt} kapacitet pohrane energije u bateriji.

2.4.2. Skaliranje glavnog agregata hibridne baterijske dizel-električne lokomotive

Koristeći postupak skaliranja agregata opisan u prethodnom odjeljku za slučaj glavnog motora i generatora, a koji se može modificirati pomoću koeficijenta skaliranja s_{mg}, identičan postupak može se primijeniti na baterijsko-hibridnu lokomotivu u sklopu razmatranog teretnog vlaka. Maksimalna snaga električne vuče koju generira glavni generator za razmatranu lokomotivu je P_{tmax} = 1402.08 kW. Navedena vrijednost je odabrana i za baterijsko-hibridnu lokomotivu kako bi se zadržale iste vučne karakteristike i vozne performanse. Međutim, prema jednadžbi (2-19), električna vučna snaga baterijsko-hibridne lokomotive sada predstavlja zbroj snaga baterije i glavnog generatora. Dakle, odabrani korisni energetski kapacitet baterije (500 kWh) može se koristiti tijekom intervala vuče, a glavni motor i generator mogu se posljedično smanjiti. Pretpostavlja se da lokomotiva može raditi na maksimalnom položaju akceleratora dva sata, tako da tijekom tog razdoblja baterija može pružiti električnu snagu od P_{batt2h} = 250 kW. U tom je slučaju potrebna snaga glavnog generatora $P_g = P_{tmax} - P_{batt2h}$, pa se agregat (motor + generator) može smanjiti s omjerom $P_g / P_{tmax} \approx 0.8$. Korištenjem ovog omjera s podacima o lokomotivi G26CW dobiva se konačni koeficijent skaliranja $s_{mgh} = 0.8 \times s_{mg} = 0.8226$, a rezultirajući približni podaci za smanjeni glavni motor i generator dani su u tablici 5. Ukupna masa predložene baterijsko-hibridne lokomotive postaje 107,85 t (što je još uvijek u istoj kategoriji opterećenja od 18 t po osovini), a obuhvaća masu podvozja lokomotive G26CW m_{lb}, masu baterije m_{batt} i smanjenu težinu agregata (m_{mg}^{*} = 17.93 t prema jednadžbi (2-8)).

Tablica 5. Podaci za umanjeni glavni motor i generator (agregat)

Položaj akcele-ratora	Snaga glavnog motora P_{mg} (kW)	Snaga generatora P_g (kW)	Potrošnja goriva $\dot{m}_f$ (g/s)	Emisije ispušnih plinova (g/s)			
				HC	CO	NO_X	CO_2
Pr. hod	6.43	0	2.5704	0.0299	0.0436	0.1510	7.9910
Notch 1	50.81	40.01	5.2994	0.0326	0.0538	0.2781	16.8449
Notch 2	196.00	171.77	13.8816	0.0395	0.1032	0.6463	43.8683
Notch 3	359.71	317.54	23.4887	0.0647	0.0977	1.2115	74.3167
Notch 4	632.77	566.49	40.8315	0.0834	0.1503	2.4458	129.3824
Notch 5	787.15	694.13	51.6475	0.1136	0.3057	3.2341	163.4197
Notch 6	965.83	844.70	64.2834	0.1593	0.9703	4.0096	202.2778
Notch 7	1161.70	1004.73	79.8195	0.2585	2.2294	4.8944	249.5078
Notch 8	1312.80	1121.67	94.4690	0.3314	4.1517	5.2350	292.7589

2.4.3. Upravljački sustav hibridnog pogona

Slika 31. prikazuje blokovski dijagram kvazi-statičkog modela baterijsko-hibridne dizel-električne lokomotive, pri čemu su specifični pod-modeli uokvireni isprekidanim crtama. Model uzdužne dinamike, model strojovođe (vozača), statička mapa vučne sile i snage pogonskog sklopa jednaki su kao i za konvencionalnu lokomotivu. Ponovno se koristi model strojovođe za izračunavanje položaja poluge akceleratora („Notch“) i komande kočenja („Brk“) na temelju razlike između ciljne (referentne) i stvarne brzine vlaka. Ključna razlika je u modelu pogonskog sklopa, koji iako i dalje sadrži pod-model agregata pomoću kojeg se izračunava potrošnja goriva i emisije plinova (kao u konvencionalnom modelu lokomotive na slici 29.), ovdje razlika između snage električnog generatora P_g i snage sustava vuče P_t ulazi u model baterije ($P_{batt} = P_t - P_g$), te prema jednadžbi (2-19), definira ulaznu snagu punjenja ili pražnjenja koja određuje stanje napunjenosti baterije (SoC) na temelju ulazne snage P_{batt} i poznatih parametara baterije (vidi sliku 30).

Zakon upravljanja zasnovan na bazi pravila (prema konceptima predloženima u [98] i [91]) kombinira potrebnu snagu sustava vuče P_t i zahtjev snage P_{bR} iz regulatora stanja napunjenosti baterije kako bi izračunao potrebnu snagu glavnog agregata (generatora) P_{gR}, čime se definira nova postavka položaja poluge akceleratora $Notch_{RB}$ preko mape za odabir *Notch* položaja akceleratora, koja je prilagođena maksimalnoj snazi skaliranog dizelskog motora

(glavnog agregata). Nadalje, uvodi se dodatno pravilo koje provjerava je li tražena snaga P_{gR} niža od snage koja se generira kada je odabrana komanda $Notch_{RB} = 4$. U tom slučaju pogonski dizelski motor se automatski dovodi u prazni hod kako bi se izbjegao rad motora s niskom učinkovitošću (vidi radne točke na slici 26c za prva dva *Notch* položaja akceleratora). Ovo dodatno pravilo moglo bi se koristiti i za isključivanje motora umjesto da ga se prevodi u prazni hod kako bi se dodatno poboljšala ušteda goriva. Međutim, zbog spore dinamike velikog dizelskog motora, prikladnije je motor ostaviti u praznom hodu u situacijama kada se zahtijeva mala izlazna snaga agregata, nego ga često uključivati i isključivati. Potreba za energijom (komanda snage P_{bR}) *SoC* regulatora izračunava se prema razlici $e_{SoC} = SoC_R - SoC$, gdje se referentna vrijednost stanja napunjenosti SoC_R može odabrati da bude konstantna (SoC_{RC}) ili promjenjiva, odnosno adaptivna (SoC_{RV}).

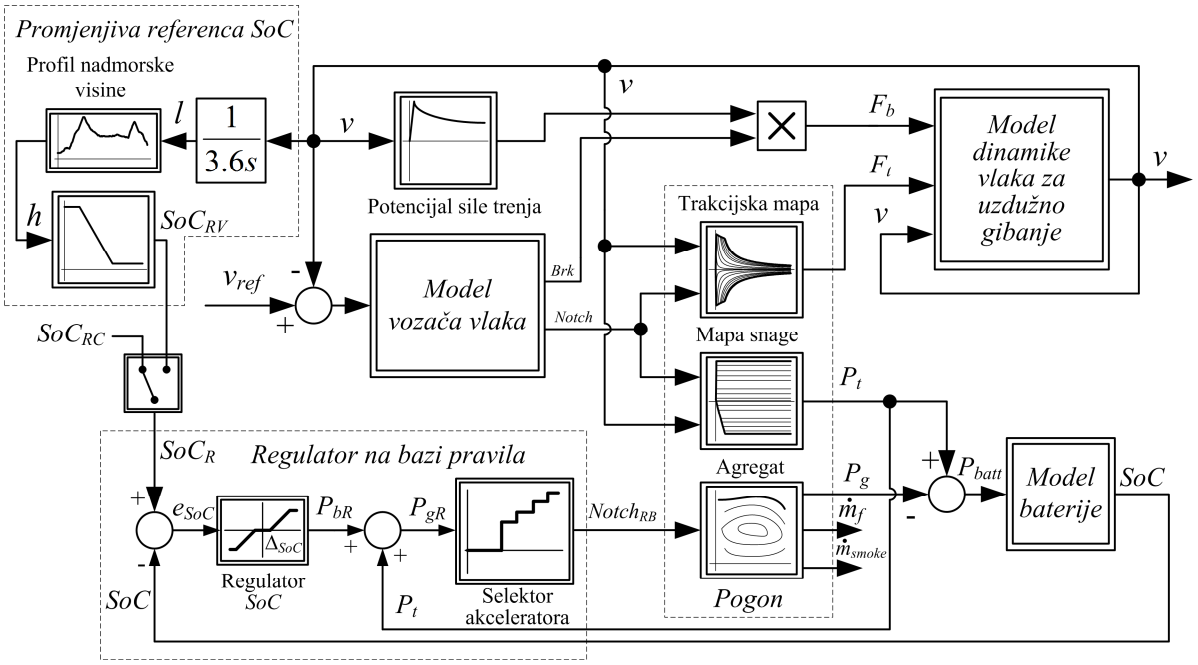

Slika 31. Blokovski dijagram kvazi-statičkog modela predložene baterijsko-hibridne lokomotive.

Konstantna referentna vrijednost stanja napunjenosti baterije čest je izbor u hibridnim električnim vozilima [78]. Međutim, zbog specifičnog profila planinske rute koju karakteriziraju značajne varijacije nadmorske visine, dolazi do značajnih varijacija potencijalne energije vlaka, te bi bilo prikladnije koristiti varijabilnu referencu stanja napunjenosti baterije kako bi se iskoristio ovaj potencijal dodatnog punjenja baterije kroz iskorištavanje kinetičke

energije vlaka prilikom spuštanja [99]. Imajući navedeno na umu, adaptivna referentna vrijednost stanja napunjenosti baterije SoC_{RV} može se izračunati kako je izvorno predloženo u [99]:

$$SoC_{RV}(h) = SoC_{bh} - \frac{h - h_{\min}}{h_{\max} - h_{\min}} \cdot (SoC_{bh} - SoC_{bl}) \tag{2-21}$$

gdje su h_{min} i h_{max} minimalna i maksimalna nadmorska visina za određenu rutu, a SoC_{bl} i SoC_{bh} su donja i gornja granica promjene reference stanja napunjenosti (SoC).

Nadmorska visina h može se lako odrediti primjenom navigacijskih sustava temeljenih na GPS-u, ili se može jednostavno rekonstruirati na temelju a-priori poznatog profila trase na unaprijed definiranoj željezničkoj ruti.

2.4.4. Parametarsko optimiranje regulatora na bazi pravila

Regulator stanja napunjenosti također sadrži mrtvu zonu ΔSoC kako bi se izbjeglo često izmjenjivanje režima punjenja i pražnjenja u blizini ciljane vrijednosti SoC-a, dok je njegovo pojačanje K_{SoC} odabrano je da osigura stabilno ponašanje zatvorene petlje sustava regulacije *SoC*, uz istovremeni zahtjev za održavanjem približno konstantnog *SoC* baterije kada se dosegne područje duboke ispražnjenosti baterije (tj. kada se *SoC* baterije smanji na približno 20%). U referenci [99], parametri regulatora izvedeni su iterativnim traženjem za prethodno definirani scenarij vožnje koji karakterizira potpuno napunjeni vlak i nova baterija. Ponovljeno pretraživanje provedeno je s ciljem postizanja stabilnog ponašanja ukupnog sustava upravljanja, istovremeno izbjegavajući duboko pražnjenje baterijskog sustava za pohranu energije, što je povezano s malim vrijednostima pojačanja regulatora stanja napunjenosti K_{SoC}. Očito je da takav pristup možda neće rezultirati optimalnim skupom parametara *SoC* regulatora, te je u programskom okruženju Matlab™ implementiran takozvani DIRECT algoritam pretraživanja iz [100] kako bi se pronašle optimirane vrijednosti parametara regulatora, gdje, u teoriji, za beskonačni broj iteracija, DIRECT algoritam konvergira prema globalnom optimumu [101]. Iako DIRECT algoritam može pronaći globalno optimalno rješenje, glavni je nedostatak da se, ako postoje lokalni optimumi, vrijeme izvršavanja se drastično produljuje zbog potrebe za iscrpnim pretraživanjem u cijeloj domeni definicije. U ovoj studiji, problem optimiranja temeljen na DIRECT algoritmu, jest pronaći parametre SoC regulatora (K_{SoC}, ΔSoC, SoC_{bl},

SoC_{bh}) koji minimiziraju ukupnu potrošnju goriva lokomotive za određeni scenarij vožnje, a što je podložno donjoj ogradi SoC od 20%. Za slučaj konstantne reference SoC optimiraju se samo vrijednost reference SoC_R i širina mrtve zone ΔSoC.

Optimizacija je provedena za različite scenarije simulacije, koji odgovaraju potpuno i djelomično opterećenom vlaku. Treba imati na umu da svaki optimizacijski ciklus, koji odgovara određenoj konfiguraciji i opterećenju vlaka (nula vagona do sedam potpuno opterećenih vagona), rezultira vlastitim skupom lokalno optimalnih parametara *SoC* regulatora, što bi zahtijevalo njegovu adaptaciju ovisno o konfiguraciji vlaka i stanju ispravnosti baterije. Dakle, kako bi se pojednostavila parametrizacija regulatora, traži se približno optimalan (pod-optimalan) rezultat koji bi minimizirao potrošnju goriva uz istodobno ostvarivanje zadovoljavajućih performansi regulacije stanja napunjenosti baterije. Pritom je potrebno zadovoljiti uvjet čvrsto ograničenje stanja ispražnjenosti baterije (odnosno $SoC > 20\%$) za različita opterećenja (od 0 do 7 potpuno natovarenih 90-tonskih teretnih vagona) i dva scenarija potpuno nove i ostarjele baterije, gdje je potonja karakterizirana kapacitetom pohrane smanjenim za 20% i unutarnjim otporom povećanim za 100% u odnosu na nominalni slučaj (to jest nove baterije). Usporedni rezultati optimiranja (optimirani parametri regulatora *SoC* baterije) dobiveni za slučaj potpuno natovarenog teretnog vlaka i drugih konfiguracija opterećenja vlaka sažeti su u tablici 6. Konkretno, rezultati optimizacije dobiveni za širok raspon konfiguracija vlakova i slučajeve nove i ostarjele baterije (četvrti i šesti redak u tablici 6.) općenito ukazuju na potrebu za većim pojačanjima regulatora stanja napunjenosti K_{SoC} i većim širinama mrtve zone ΔSoC, te većim rasponima između maksimalne i minimalne referentne vrijednosti stanja napunjenosti, odnosno SoC_{bl} i SoC_{bh}, u usporedbi sa scenarijem potpuno opterećenog vlaka i potpuno nove baterije (treći i peti redak u tablici 6).

Tablica 6. Parametri SoC regulatora baterijsko-hibridne lokomotive.

Vrsta SoC reference		Parametri				
		K_{SoC}	Δ_{SoC}	SoC_R	SoC_{bl}	SoC_{bh}
(SoC_{RC})	*Samo puni teret*	3866	0.13%	63.13%	-	-
	Svi tereti	8500	4.33%	64.79%	-	-
(SoC_{RV})	*Samo puni teret*	26796	0.26%	-	41.51%	53.63%
	Svi tereti	48786	1.34%	-	42.08%	65.12%

Budući da bi rezultat optimizacije koji pokriva širok raspon mogućih scenarija bio robusniji u usporedbi sa specifičnim slučajem potpuno napunjenog vlaka i potpuno nove baterije, ovaj općenitiji skup optimiranih parametara regulatora koristi se u daljnjoj analizi.

2.5. Model baterijske lokomotive

Pretpostavlja se da se baterijsko-električna lokomotiva može realizirati naknadnom ugradnjom baterijskog sustava za pohranu energije dovoljno velikog kapaciteta pohrane koji se koristi na osnovnom podvozju dekomisionirane (rashodovane) konvencionalne dizel-električne lokomotive (tj. s uklonjenim blokom motora-generatora, odnosno dizelskog agregata), a koja predstavlja glavni oslonac dizel-električne teretne vuče nacionalne željezničke tvrtke [80].

Kvazistatički model takve baterijsko-električne lokomotive predstavljen je blokovskim dijagramom na slici 32. Zbog slične konfiguracije baterijsko-električne lokomotive u usporedbi s dizelsko-električnom (iako bez dizelskog agregata), podmodeli uzdužne dinamike, model strojovođa i mape vuče i električnog vučnog pogona identični su onima za konvencionalnu lokomotivu (slika 29). Dakle, model strojovođe izračunava "Notch" položaj akceleratora i komandu kočenja (Brk) na temelju razlike između ciljne i stvarne brzine vlaka.

Ključna razlika je u tome što se snaga vuče P_t sada definira kao crpljenje snage P_{batt} iz baterije ili njeno punjenje tijekom postupka regenerativnog kočenja.

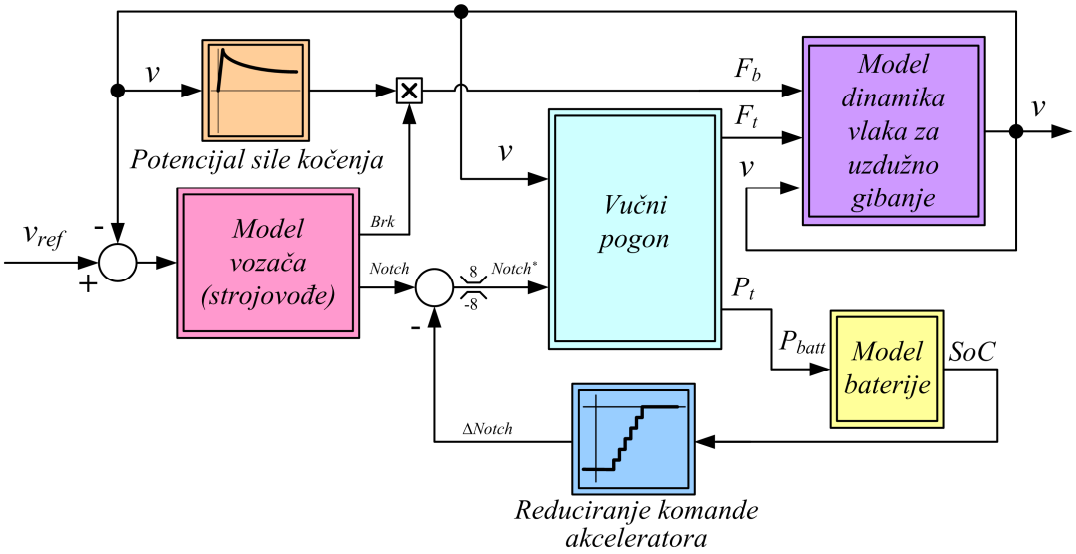

Slika 32. Blokovski dijagram kvazistatičkog modela baterijsko-električne lokomotive.

Model stanja napunjenosti (SoC) zasnovan na tokovima energije baterije prikazan je na slici 33, pri čemu snaga baterije (ulazna) $P_{batt} > 0$ odgovara režimu pražnjenja baterije (pražnjenje energije), dok snaga baterije $P_{batt} < 0$ odgovara režimu punjenja baterije (regenerativno kočenje). Predstavljeni model stanja napunjenosti baterije (SoC) izveden je u prethodnom poglavlju iz modela ekvivalentnog strujnog kruga baterije (jednadžba (2-17)). Kao što je opisano u prethodnom poglavlju parametri jedne ćelije litij-ionske baterije preuzeti su iz programskog paketa Autonomie, te su korišteni za skaliranje modela baterije s obzirom na zahtijevani kapacitet pohrane energije (što je također opisano u prethodnom poglavlju).

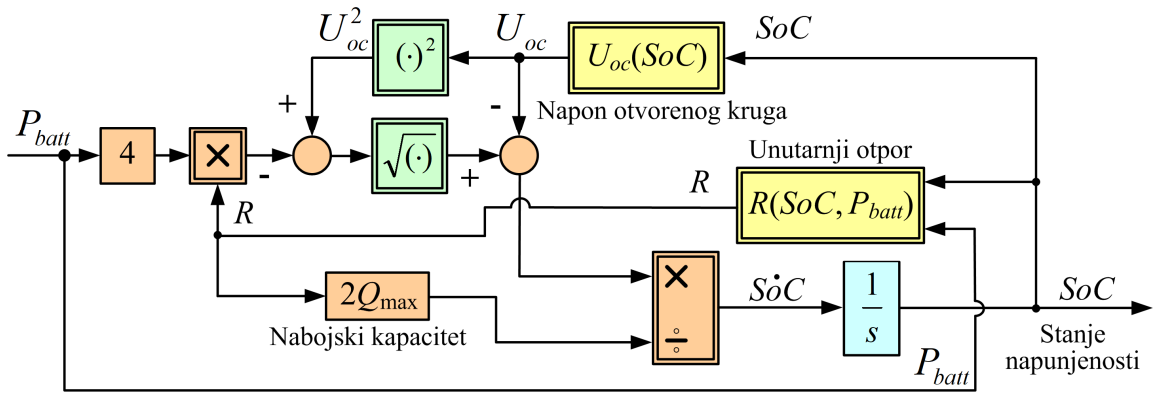

Slika 33. Blokovski dijagram dinamičkog modela baterije temeljenog na tokovima snage koji je pogodan za simulacijske analize.

Dodatno pravilo uvedeno je u model baterijsko-električne lokomotive (slika 32), a koje smanjuje vrijednost "Notch" komande strojovođe pomoću odgovarajuće statičke mape za redukciju kada SoC baterije padne ispod 50% (baterija se napola isprazni). U tom slučaju, kod daljnjeg pražnjenja ispod 50% za svaki pad vrijednosti SoC akumulatora od 3,33% uvodi se dodatno smanjenje "Notch" komande akceleratora za 1 dok se ne dostigne 30% SoC akumulatora. Ova vrijednost stanja napunjenosti (SoC = 30%) odgovara maksimalnom smanjenju "Notch" komande $\Delta Notch = 6$, što bi rezultiralo ukupnim stanjem akceleratora gasa $Notch^* = 2$ kada vozač zada maksimalni iznos komande akceleratora Notch = 8.

Ovo dodatno pravilo ima dvostruku svrhu: (a) sprečava preopterećenje i preveliko ispražnjenje baterije uslijed prekomjerne potražnje za snagom pogonskog sklopa kada je baterija već ionako prazna, i (b) istovremeno omogućuje iskorištavanje pune snage regenerativnog kočenja, čime se povećava ukupni električni domet vlaka. U tandemskom radu

s konvencionalnom dizel električnom lokomotivom, ovo dodatno pravilo pomaže održavanju SoC akumulatora na održivim razinama sličnim regulatoru koji se temelji na bazi pravila u hibridno-električnoj lokomotivi opremljenoj baterijskim sustavom za pohranu energije [78]. Također treba napomenuti da je za svaki scenarij simulacije donja sigurna granica SoC baterije postavljena na 20%, što znači da se simulacija prekida kad SoC baterije padne ispod ovog iznosa, a što bi odgovaralo sigurnosnim značajkama upravljačkih sustava u suvremenim baterijama namijenjenih sprečavanju prekomjernog pražnjenja i s time povezanih učinaka starenja baterija [102].

SoC baterije obično se procjenjuje na temelju složenih izračuna koji uključuju bilancu naboja baterije i procjenu zasnovanu na nadomjesnom modelu strujnog kruga baterije, a koji se obično izvode u okviru nelinearnog estimatora tipa Kalmanovog filtra [103]. Pogreška procjene SoC-a može se okarakterizirati posmakom (konstantnom pogreškom) i sporo promjenjivim trendovima (drift), čije granice ovise o kvaliteti i točnosti modela baterije [103]. Ako se te granice uzmu u obzir u algoritmu upravljanja stanjem napunjenosti baterije, bilo bi moguće izbjeći duboko pražnjenje i prekomjerno punjenje baterije. To se može učiniti jednostavnim ograničavanjem referentne vrijednosti SoC-a kako bi se izbjegao rad u režimu prekomjernog punjenja ili dubokog pražnjenja.

Dimenzije baterije imaju glavni utjecaj na domet lokomotive, njene performanse i ukupnu težinu, te zapreminu lokomotive. Kako bi se zadovoljilo ograničenje težine po osovini od 18 t po osovini (što odgovara tračnicama B kategorije), maksimalna težina šestosovinske lokomotive je 108 t [78]. Približna težina glavnog motora i agregata konvencionalne dizelsko-električne lokomotive iznosi m_{mg} = 22,52 t, pa je bazna težina podvozja lokomotive tada m_{lb} = m_l - m_{mg} = 80,48 t (masa lokomotive m_l je 103 t, kao što je prethodno spomenuto) [78]. Stoga je maksimalna moguća težina sustava baterije $m_{battMAX}$ = 27,52 t. Drugo ograničenje je maksimalni volumen baterije koji bi trebao biti manji od dostupnog volumena unutar prostora gdje bi se inače nalazio agregat i pomoćna oprema lokomotive. Zbog činjenice da litij-ionske baterije imaju približno gotovo dvostruko veću volumetrijsku gustoću energije u usporedbi s gravimetrijskom gustoćom energije [104], potrebni volumen za bateriju od 27,52 t iznosi oko 14 m^3, što se lako može uklopiti unutar lokomotive. Stoga se ovo ograničenje vezano za volumen može zanemariti u daljnjoj analizi.

Veličina baterije određena je kao kombinacija serijski i paralelno povezanih ćelija, a koje su raspoređene na takav način da ukupna težina baterije usko odgovara gornjoj teorijskoj

$m_{battMAX}$. U ovom konkretnom slučaju, baterija posjeduje $N = 43600$ ćelija, koje su raspoređene u 218 paralelnih blokova od po 200 serijski spojenih ćelija, što omogućuje željeni operativni napon istosmjerne sabirnice između 620 V i 780 V koji se izračuna iz raspona napona jedne ćelije u radu. Kako bi se održala sigurnost i pouzdanost predložene konfiguracije ćelija unutar baterije, kao i pravilno uravnoteženje napona ćelija, također treba razmotriti primjenu sustava upravljanja i nadzora baterije (engl. Battery Management System, BMS) [105]. Za zadanu konfiguraciju baterije, ukupna masa i kapacitet izvedeni su i navedeni u tablici 2.

Tablica 7. Li-Ion ćelija i baterija i ukupni za baterijsku električnu lokomotivu

	N	*E (kWh)*	*Qmax (Ah)*	*Pmax (kW)*	*m (kg)*
Ćelija	1	0.06	15.9	0.4	0.63
Baterija	43600	2616	3466.2	17440	27468

2.6. Model optimizacije i klasifikacije podataka iz udaljenih senzorskih mreža

Trend automatizacije i digitalizacije prometnih sustava je rezultirao generiranjem izrazito velike količine podataka, kako interno u pokretnim prometnim entitetima, tako i na prometnoj infrastrukturi. Interoperabilnost i multifunkcionalnost uporabe podataka iz senzorskih mreža pokazao se kao veliki izazov, poglavito za različite generacije prometnih vozila. U ovom poglavlju se razrađuje postupak prikupljanja, validacije, optimizacije, klasifikacije i uspješne integracije u realnom vremenu prikupljenih podataka u model upravljanja željezničkog prometnog entiteta s ciljem povećanja energetske učinkovitosti i prometno-tehnološke sigurnosti.

2.6.1. Senzorski sustavi na željezničkoj infrastrukturi

Željeznički promet je visoko regulirana djelatnost zbog rizika u prometovanju pa je pripadajuće tehničke sustave potrebno planirati i implementirati u skladu s preporukama i pravilnicima o tehničkim uvjetima za prometno-upravljačke i signalno-sigurnosne željezničke infrastrukturne sustave (NN 97/2015). Na prugama europskih željezničkih uprava uspostavljaju se automatizirana praćenja voznih karakteristika željezničkih vozila (prema smjernici 440/EC/91). Na primjer, preveliko osovinsko opterećenje i druge nepravilnosti na željezničkim vozilima mogu izazvati velika oštećenja na pruzi, što posljedično rezultira povećanim

troškovima održavanja. Mjerni uređaj koji omogućuju praćenje, mjerenje i dojavu promatranih tehničkih karakteristika vozila sadrži odgovarajuće senzore, čije se izmjerene vrijednosti šalju se u središnju jedinicu koja može biti koncipirana u obliku koncentratora podataka u mjernoj postaji u kojoj su ugrađeni pojedini mjerni uređaji ili se podaci o mjerenju mogu slati u lokalni ured za upravljanje prometom u najbližem kolodvoru [106]. Senzori, zajedno s pratećim uređajima za obradu podataka, električno napajanje i mehaničku konstrukciju čine sustav za automatsku kontrolu željezničkih vozila, kao na slici 34.

Slika 34. Senzorska mjerna postaja za nadzor gabarita željezničkih vozila [106].

Osnovi kriteriji za određivanje lokacija za postavljanje senzorsko-mjernih postaja su:

- prometno-tehnološki uvjeti
- opseg prometa na željezničkoj mreži
- blizina graničnih kolodvora
- blizina glavnih željezničkih čvorišta
- pruga u pravcu duljine min. 200 (150) m
- blizina trase s većim uzdužnim nagibima (>20 ‰)
- blizina specifičnih pružnih građevina (mostovi većih raspona, dugački tuneli i sl.),
- raspoloživost elektrotehničkih instalacija
- mogućnost pristupa terenskim vozilom [106].

U tehnološko-prometnom procesu upravljanja željezničkim prometom koriste se razni senzori od kojih su od posebne važnosti senzori za detekciju vlaka (slika 35). Induktivni senzori željezničkih kotača koriste se kao brojači osovina i detektori nailaska vlaka. Brojači osovina također se sve više koriste umjesto detekcije vlaka putem izoliranih odsjeka, a mogu se koristiti i u nizu aplikacija gdje imaju ulogu davanja informacije o poziciji vlaka. Elektrotehnička oprema instalirana uz prugu sastoji se od senzora kotača i odgovarajuće opreme uz prugu smještene u odgovarajućem elektro-ormariću, dok je oprema za centraliziranu analizu pristiglih podataka smještena na udaljenoj lokaciji.

Slika 35. Induktivni senzori detekcije kotača željezničkih vozila prema standardu CENELEC SIL 4 [106].

Karakteristika prethodno navedenih senzorskih sustava je da zahtijevaju elektro-energetsko napajanje i dostupnost za održavanje, a uglavnom se instaliraju na prilazima željezničkim postajama, cestovno-željezničkim križanjima ili ranžirno-logističkim lokacijama. Problemi nastaju na željezničkim prugama na udaljenim lokacijama izvan naseljenih zona, a poglavito na prugama koje nisu elektrificirane, te se zbog toga u ovom radu predlaže tehničko rješenje koje je pogodno i za takve lokacije.

2.6.2. Uskopojasne senzorske mreže s malom potrošnjom energije

Europska konferencija poštanskih i telekomunikacijskih uprava (engl. CEPT- European Conference of Postal and Telecommunications Administrations) je prema izvješću 66/18/CEPT definirala tehnologije za bežični internet stvari ili strojeva [107], koje je nedavno definirao Europski institut za telekomunikacijske norme (engl. ETSI - European Telecommunications

Standards Institute), a to su: GSM IoT proširene pokrivenosti (engl. Extended Coverage GSM IoT), LTE strojna komunikacija (LTE Machine Type Communications), evoluirana LTE strojna komunikacija (LTE evolved Machine Type Communications) i uskopojasni IoT (Narrowband IoT).

Pojmovi "uskopojasni" i "širokopojasni" odnose se na širinu pojasa radio kanala. Definicija uskopojasne komunikacije prema ETSI je kada se za radijski kanal koristi frekvencijski pojas širine 25 kHz ili manje. Međutim, potrebno je naglasiti da je snažnim razvojem industrijskih i strojnih komunikacija terminologija „uskopojasnih“ komunikacija uvedena čak i za širinu pojasa od 180 kHz, kao na primjer za LTE NB-IoT. S druge strane, LoRa tehnologija (engl. LoRa - Long Range, low-power wide area network) se ne smatra uskopojasnom jer se temelji na širini frekvencijskog pojasa rasponu većoj od 100 kHz [108].

Prilikom izbora najpogodnije tehnologije za udaljene senzore kojima će se prikupljati podaci okoline željezničke infrastrukture analizirana je opsežna literatura. Definirani su osnovni tehničko-ekonomski uvjeti koji su sukladni postojećim tehničkim uvjetima i mogućnostima željezničke infrastrukture, te je zahtijevana mogućnost pokrivanja velikih područja komunikacijskim signalom uz istodobno značajno smanjenje potrošnje energije u odnosu na konvencionalne bežične komunikacijske sustave jer se željeznička infrastruktura često nalazi na nenaseljenim područjima gdje nema mogućnosti električnog napajanja iz javne mreže. Nadalje, za prometne sustave je vrlo važna mikro rasterska pokrivenost mjerenja okoline. Za primjer možemo navesti različite prometne uvjete na mostovima, te ispred i iza mosta na udaljenostima od svega 400-500 metara, iz čega proizlazi potreba za gustom pokrivenošću senzorima meteoroloških veličina, odnosno visokom gustoćom geografskog „rastera“ podataka. Ovo pak posljedično uvjetuje potrebu za takvom tehnologijom prijenosa podataka koja omogućuje slanje podataka putem mobilne mreže velikom broju uređaja. Također je potrebno sagledati i ekonomski aspekt primjene senzorskih mreža za udaljene i izolirane lokacije, što znači da senzori trebaju biti cjenovno prihvatljivi s mogućnošću integracije na postojeće komunikacijske mreže. Sigurnost prijenosa podataka također treba biti zajamčena, za što je pogodna tehnologija koja koristi licencirani frekvencijski spektar gdje nema mogućnosti interferencije s drugim uređajima. Navedenim zahtjevima najviše odgovaraju mreže za komunikaciju strojeva na velikim udaljenostima s malom potrošnjom energije tzv. LPWA senzorske mreže (engl. LPWA - Low Power Wide Area). U LPWA mreže spadaju Sigfox, LoRa, te NB-IoT, pa je u nastavku naveden kratki komparativni prikaz tehnologija kako

bih se definirao najpogodniji sustav za primjenu u modelu upravljanja željezničkim prometnim entitetima.

Sigfox je francuski globalni mrežni operator koji je izgradio privatnu bežičnu mrežu za povezivanje senzora s vrlo malom potrošnjom energije. Za prijenos informacija koristi D-BPSK (engl. Differential Binary Phase-Shift Keying) modulaciju pri kojoj poruka ima fiksnu širinu pojasa od 100 Hz i brzinu od 100 bps ili 600 bps. Komunikacija se odvija u okviru nelicenciranog ISM frekvencijskog spektra na frekvencijama ispod 1 GHz, a koji za Europu iznosi 868 MHz. Ovu tehnika modulacije UNB (engl. Ultra-Narrow Band) signala, koja zahtijeva malu potrošnju energije, koriste još i LoRa sustavi, te NarrowBand sustavi [109].

Sigfox model komuniciranja je model „pošalji i zaboravi“ (engl. „fire and forget“) zbog čega ne može jamčiti da je poruka stvarno primljena, pa je na odašiljaču da učini točan prijenos. Na razini podatkovne veze (MAC sloj) svaki uplink okvir ima ukupnu duljinu od 208 bita (slika 36.) zajedno sa jedinstvenom identifikacijom - „ID senzora“ za svaki uređaju u Sigfox mreži [110].

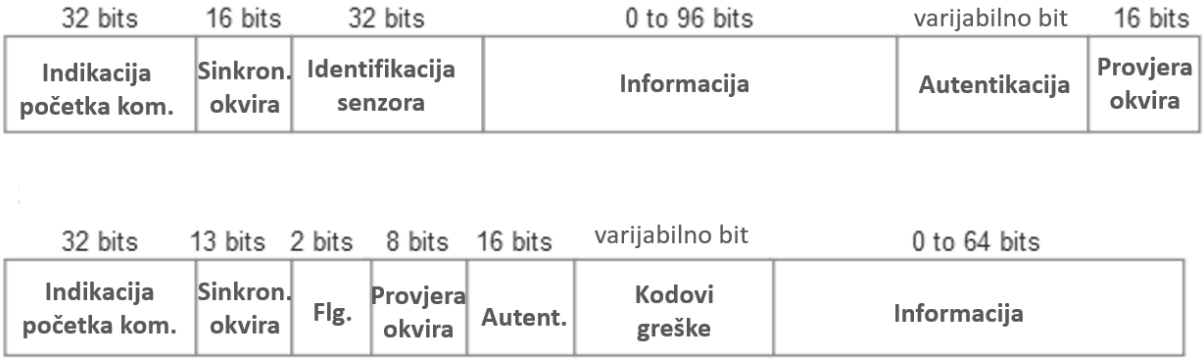

Slika 36. Sigfox format komunikacijskog okvira na MAC razini [110].

LoRa (engl. Long Range) je bežična tehnologija za komunikaciju strojeva na velikim udaljenostima i jedna od najraširenijih LPWAN (engl. low power wide area network) tehnologija u svijetu. Omogućuje povezivanje baterijski napajanih IoT uređaja, te dvosmjerni prijenos male količine podataka na veliku udaljenost od nekoliko kilometara. LoRa i LoraWAN spadaju u kategoriju nećelijskih protokola i bežičnih komunikacijskih LPWAN mreža, koje rade u nelicenciranom spektru [111]. Nedostatak primjene LoRa tehnologije za udaljene senzore na željezničkoj infrastrukturi je loša radio veza ako je senzor instaliran ukopavanjem u tlo, te znatnija investicija po komadu ako se dodaje baterijski dodatak.

Uskopojasni IoT (engl. NarrowBand Internet of Things, NB IoT) je celularna ili ćelijska tehnologija širokog dometa i male potrošnje energije tzv. LPWAN mreže. Životni vijek baterije u senzorima dulji je od 10 godina pa može podržati široki raspon aplikacija. Specifična prednost NB-IoT je dobra radijska pokrivenost i za senzore instalirane ispod razine zemlje. Također informacijska sigurnost je na razini 4G/5G mobilnih mreža, što je važno ako je potrebna podrška za povjerljivost korisničkog identiteta, autentifikaciju entiteta, integritet podataka i identifikaciju mobilne senzorske opreme, te udaljene nadogradnje i održavanja [112]. Prema prethodno navedenim podacima NB-IoT senzorska tehnologija je najprikladnija za korištenje u modelu za željeznički prijevoz, pa će njene karakteristike biti implementirane u model upravljanja željezničkim prometnim entitetima.

Prilikom izbora senzorske tehnologije, a koja će se koristiti u modelu za upravljanje željezničkim entitetom u pokretu, korištene su preporuke Europske komisije za digitalnu transformaciju prometnih sustava [113] i principi razvoja rješenja prema modelu Industrije 4.0 (engl. German Plattform Industrie 4.0) iz referenci [114, 115]. Na ovaj način je postignuto da se po završetku istraživanja predloženi model za unaprjeđenje energetske učinkovitosti i prometne sigurnosti željezničkog prijevoza može lakše prilagoditi realnoj aplikaciji i posljedično brže implementirati u potonjem procesu digitalizacije željezničkog prijevoza.

NB-IoT tehnologija je u okviru 5G komunikacijskih mobilnih mreža namijenjena za masivne komunikacije strojeva ili senzora (engl. massive machine-type communications - mMTC) [116]. NB-IoT senzori dizajnirani su za mogućnost priključenja velikog broja senzora na baznu stanicu i uz vrlo nisku cijenu krajnjih senzora. Pozicioniranje (lokacija) senzora ovisi o prometnoj infrastrukturi i o prometno-tehnološkim zahtjevima. NB-IoT senzori imaju mogućnost detekcije instalirane lokacije iz signalizacijskih mrežnih informacija, što znači da ne zahtijevaju dodatni GPS prijemnik, a što bi posljedično poskupilo cijelu senzorsku mrežu, što je od posebne važnosti ako je senzor instaliran na pokretnom prometnom entitetu. Ako se NB-IoT instalira na fiksnoj lokaciji, onda se pri instalaciji zabilježe GPS koordinate, što je učinjeno i u ovom istraživanju. Prije instalacije senzora potrebno je provjeriti radio pokrivenost lokacija. Na slici 37. prikazana je NB-IoT pokrivenost Hrvatske od strane operatora Hrvatskog Telekoma.

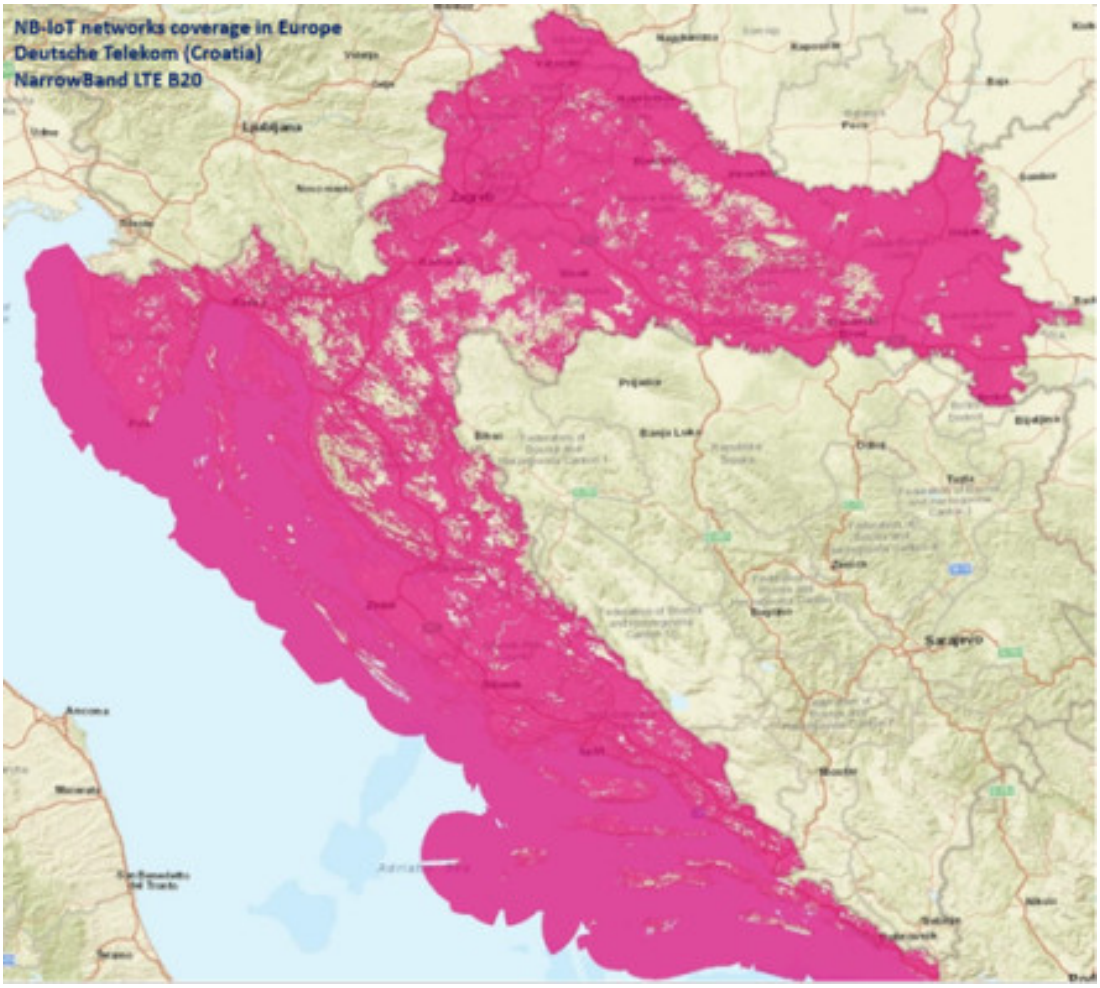

Slika 37. Stanično pokrivanje NB-IoT (LTE opseg 20) u Hrvatskoj [117].

Prilikom planiranja rješenja sa NB-IoT senzorima potrebno je detaljno uskladiti staničnu pokrivenost s prometno-tehnološkim zahtjevima (slika 38), a u slučaju ovog istraživanja uzeti su u obzir i klimatski uvjeti te nadmorska visina i nagibi željezničke trase kako bi rezultati istraživanja bili mjerljivi na manjem odsječku. U nedostatku tehničkih mogućnosti za terenska mjerenja, moguće su integracije povijesnih meteoroloških podataka, odnosno vremenskih prilika.

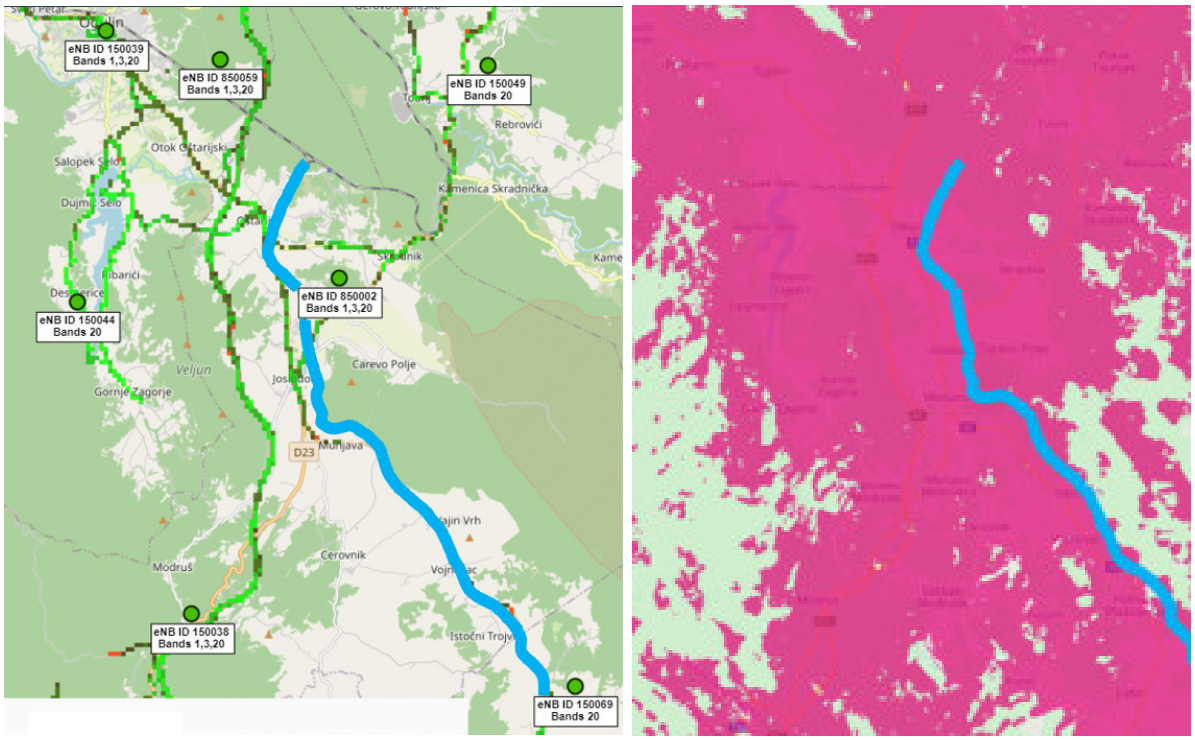

Slika 38. Prikaz baznih stanica LTE B20 (NB-IoT) – zeleno označene točke i polja radio pokrivanja ljubičasta boja, te svjetlo plavim označena testna dionica željezničke pruge: Oštarije (početak Ličke pruge) - Lički Podhum.

U fazi planiranja potrebno je provjeriti i potrebne senzorske kapacitete. Za NB-IoT senzore (3GPP Rel.13) sustav je dizajniran za sposobnost rada pod opterećenjem od 60.680 uređaja/km^2 [118]. Za mreže 5G (3GPP Rel.14) komunikacijski sustav može podnijeti opterećenje od 1.000.000 uređaja/km^2 [119]. Takva ekstremna opterećenja senzorskih mreža mogu se dogoditi jedino u gusto naseljenim urbanim sredinama s velikim prometnim opterećenjima, što nije slučaj s testnim slučajem ovog istraživanja, te stoga nije potrebno ćelijsko projektiranje kapaciteta.

Arhitektura NarrowBand senzorske mreže realizirana je na konvencionalnoj LTE mreži s proširenjima potrebnim za podršku IoT masivnim aplikacijama (engl. IoT Massive Applications), slika 39. Sastoji se od pristupne mreže (engl. Radio Access Network) i jezgrene mreže EPS paketskog sustava (engl. EPS - Evolved Packet Core). U operatorskom dijelu mreže dodan je novi mrežni element SCEF (engl. Service Capability Exposure Function) dizajniran za strojnu komunikaciju, provjeru autentičnosti i autorizacije, detekciju senzorskih uređaja i pristup mrežnim mogućnostima. Na senzorskoj strani mreže za senzore koji se instaliraju ispod razine zemlje potrebno je izvršiti mjerenja zbog optimizacije potrošnje energije.

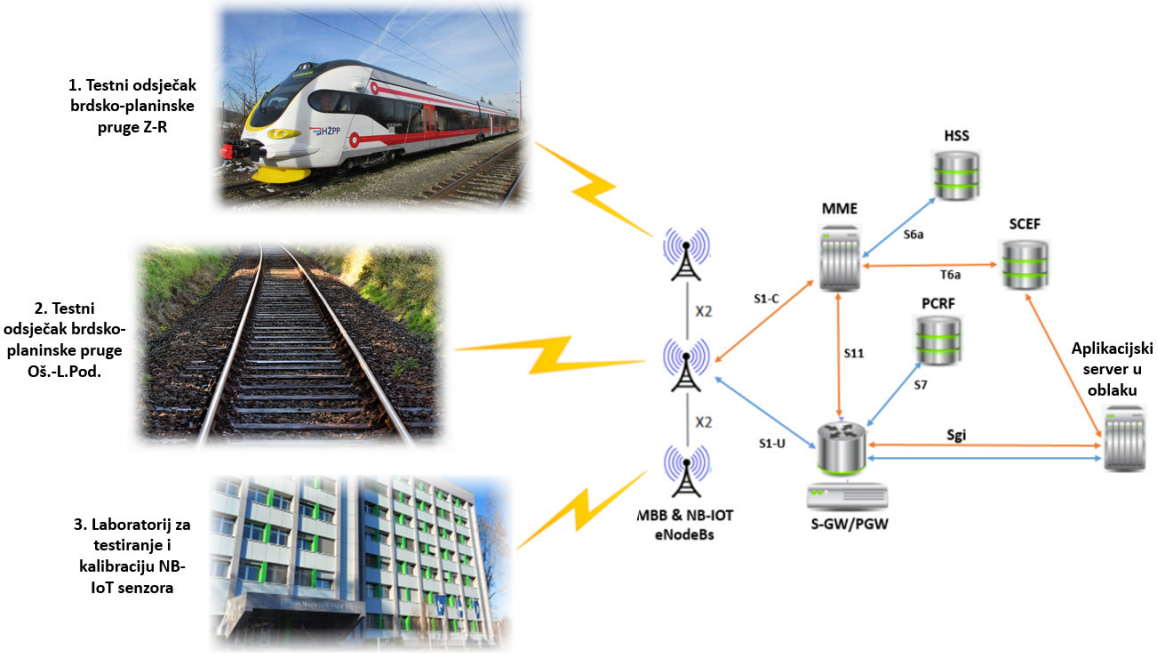

Slika 39. Arhitektura senzorske mreže NarrowBand - LTE (B20), prilagođeno [120].

2.6.3. Komunikacijski model i implementacija u simulacijskom okruženju

Ovaj odjeljak predstavlja simulacijski model mreže uskopojasnih distribuiranih senzora temeljen na mrežnoj ćelijskoj tehnologiji, a koja je integrirana s prethodno opisanim modelom teretnog vlaka pogonjenog baterijsko-hibridnom dizel-električnom lokomotivom, te je tako dobiveni cjelokupni model također opremljen izlaznim sučeljem za statističku vizualizaciju. Pomoćne varijable okoliša, potrebne su za učinkovit rad sustava za upravljanje vučom teretnog vlaka i SoC regulatora baterije su one povezane s uvjetima kolosijeka, tj. potencijalom adhezije kotača s obzirom na tračnice i čeonim vjetrom, a koje izravno utječu na vuču kotača i aerodinamički otpor gibanja vlaka. Ove varijable su na zadanoj trasi izravno povezane s atmosferskim uvjetima, posebice temperaturom i vlažnošću zraka, a koje su povezane s vučom kotača (koeficijentom trenja μ_a), dok brzina vjetra i njegov smjer definiraju čeoni vjetar, odnosno dodatni aerodinamički otpor kretanju vlaka kako je pokazano ranije. Prema tome, gore spomenute atmosferske varijable potrebno je izmjeriti nizom udaljenih senzora na trasi i u određenim vremenskim razmacima očitavati i prenositi na računalni poslužitelj (server) koji

sadrži središnju bazu podataka kojoj bi strojovođa pristupio kako bi dobio najnovija ažuriranja stanja pruge, te na temelju toga prilagodio strategiju upravljanja vlakom.

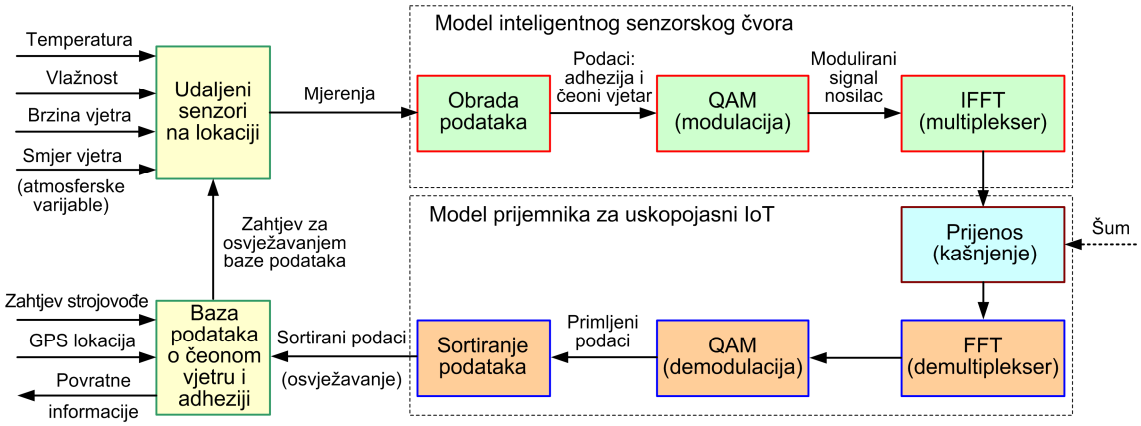

Slika 40. Blokovski prikaz veze jednog elementa NB IoT mreže udaljenih senzora s zahtjevanom bazom podataka o adheziji na kolosijeku i čeonom vjetru

Slika 40. prikazuje blokovski dijagram veze uskopojasnih (NB) IoT udaljenih senzora s centralnom bazom podataka koja sadrži podatke o adheziji i čeonom vjetru iz udaljene senzorske mreže jednoliko raspodijeljene duž istraživanog segmenta željezničke trase. Model pojedinačnog udaljenog senzora sastoji se od fizičkih senzora temperature i vlažnosti zraka te podataka brzine i smjera vjetra (atmosferskih varijabli), čija se mjerenja obrađuju kako bi se dobili korisni podaci o stanju kolosijeka (tj. adheziji i čeonom vjetru). Navedeni se digitalni podaci pripremaju za radio prijenos pomoću kvadraturno-amplitudne modulacije (engl. Quadrature Amplitude Modulation, QAM) signala nosioca [121]. Ovo je oblik multipleksiranja s ortogonalnom frekvencijskom podjelom (engl. Orthogonal Frequency Division Multiplex, OFDM), koji se tipično koristi u komunikacijskim mrežama LTE (engl. Long-Term Evolution) poznatijim kao mreže četvrte generacije ili 4G [122]. Kako bi se paralelni QAM izlazni podatak pretvorio u radio signale pogodne za prijenos, u tu se svrhu koristi inverzna brza Fourierova transformacija (engl. Inverse Fast Fourier Transform, IFFT) [123]. Prijenos signala sa senzorskog čvora u model NB IoT prijamnika može se unutar simulacijskog modela emulirati transportnim kašnjenjem (te, po potrebi, i sa vanjskim aditivnim izvorom šuma). Na strani prijamnika modulirane značajke radio signala ekstrahiraju se pomoću brze Fourierove transformacije (engl. Fast Fourier Transform, FFT) [123], koje se potom prosljeđuju QAM demodulatoru za izdvajanje korisnih podataka. Izdvojeni podaci sortiraju se (indeksiraju) prije

pohrane u središnju bazu podataka koja se može povremeno ažurirati prema unaprijed definiranom planu ili na zahtjev strojovođe s podacima o stanju kolosijeka relevantnim za određenu geografsku lokaciju (karakteriziranu pripadajućim GPS koordinatama).

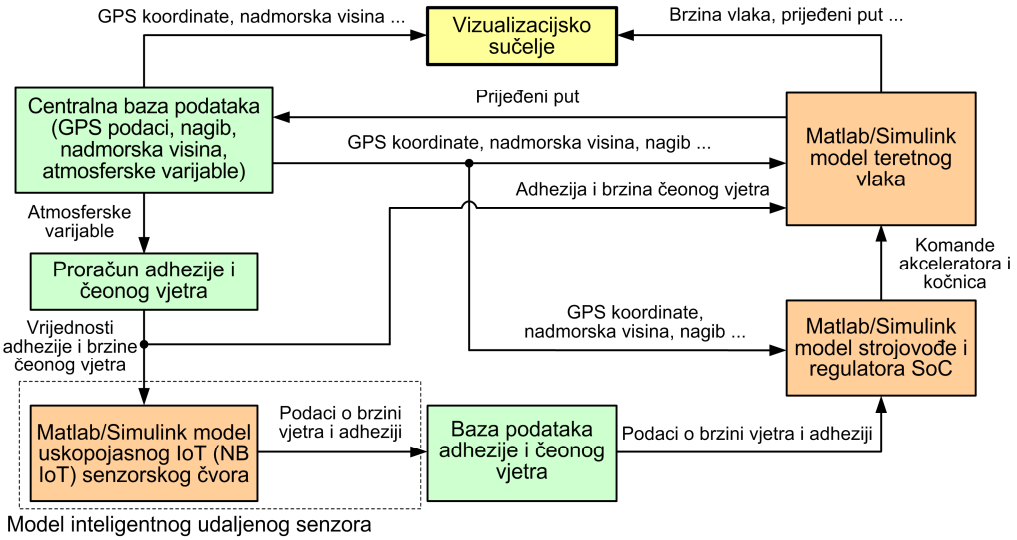

Slika 41. Blokovski dijagram integriranog simulacijskog modela koji obuhvaća teretni vlak i strojovođu, mrežu udaljenih inteligentnih senzora i podmodele za razmjenu podataka o stanju pruge na istraživanoj trasi.

Slika 41. prikazuje integraciju modela teretnog vlaka s geografskim podmodelom željezničke rute i modelom mreže udaljenih bežičnih senzora, pri čemu su pojedine komponente modela implementirane u programskom okruženju Matlab/Simulink [124] te se koriste u naknadnim simulacijskim analizama. Model teretnog vlaka dobiva podatke o visini i nagibu željezničke pruge iz GPS koordinata (geografskih podataka) iz baze podataka koja također sadrži odgovarajući skup podataka atmosferskih varijabli za svaku geografsku lokaciju. Na taj način svi dijelovi simulacijskog modela dobivaju relevantne podatke koji se ažuriraju na temelju udaljenosti koju je vlak prešao duž željezničke pruge. Isti geografski podaci dostavljaju se i upravljačkom modelu (te strategiji upravljanja stanjem napunjenosti baterijskog sustava za pohranu energije) u svrhu optimiranja potrošnje energije (vidi prethodno poglavlje). Na temelju geografskog položaja vlaka (položaja uz željezničku prugu), odabiru se relevantni podaci udaljenog senzora koji odgovaraju potencijalu adhezije za sustav vuče i čeonom vjetru, te se koriste u modelu strojovođe kako bi se odabrala odgovarajuća komanda akceleratora 'Notch' ili komanda kočenja 'Brk' koje podržavaju gibanje vlaka bez proklizavanja kotača (uz poštivanje

ograničenja modela teretnog vlaka). Isti se podaci koriste i u modelu teretnog vlaka za oponašanje realističnih varijacija aerodinamičkog otpora uslijed čeonog vjetra i vučne sile s promjenama karakteristike adhezije. Konačno, cjelokupni simulacijski model također sadrži sučelje za vizualizaciju dobivenih rezultata koje se može koristiti za praćenje ključnih varijabli teretnog vlaka (poput brzine, prijeđene udaljenosti, vučne sile i drugih).

2.7. Postupak obrade podataka iz senzorskih mreža namijenjen podršci upravljanja željezničkoga prijevoza

2.7.1. Metodologija anketiranja eksperata u području željezničkoga prijevoza

Anketiranje pomoću anketnih upitnika je jedan od najčešćih instrumenata istraživanja kako za znanstvene tako i za stručne analize. Anketni upitnik je nezaobilazni mjerni instrument pomoću kojeg se dobivaju ulazni podaci za različite analize, od kojih su najčešće one statističkog karaktera [125]. Prilikom pripreme znanstvenog istraživanja pomoću metodologije anketiranja, potrebno je uspješno odrediti svrhu i ciljeve istraživanja, čije ostvarenje dovodi do dokazivanja postavljene hipoteze. Svrha i ciljevi trebaju biti realno i jasno postavljeni [126]. Anketna pitanja se po načinu njihovog postavljanja mogu podijeliti u tri osnovne skupine: pitanja otvorenog tipa, pitanja zatvorenog tipa i pitanja kombiniranog tipa [127]. Otvorenim pitanjima ispitaniku se ne postavljaju čvrsti okviri za odgovor. Uz pitanja se ostavlja prazan prostor u koji ispitanik upisuje odgovor. Prednosti otvorenih pitanja su da ih je lako sastaviti, ne usmjeravaju ispitanika na određeni odgovor i odgovori imaju veću heurističku vrijednost. Nedostaci otvorenih pitanja su da zahtijevaju visoku stručnost i dobru pismenost ispitanika, imaju malu verifikacijsku vrijednost, stavljaju ispitanika pred teži zadatak, nije moguće postaviti veći broj pitanja i teža je obrada rezultata ovakvih anketa [127]. Zatvorenim anketnim pitanjima ispitanik je ograničen u mogućnostima za odgovor, jer pokraj pitanja stoje ponuđeni odgovori za koje se ispitanik odlučuje. Zatvorena pitanja mogu biti pitanja s ponuđenim odgovorima nabrajanja, koja imaju nekoliko ponuđenih odgovora, ili pitanja s ponuđenim odgovorima intenziteta. Prednosti zatvorenih pitanja su da ne zahtijevaju veću pismenost ispitanika, može se postaviti veći broj pitanja u anketi, lakše ih je obrađivati i veća im je verifikacijska vrijednost [127].

Za potrebe ovog rada je planirano anketiranje eksperata u području željezničkog prijevoza, što znači anketiranje ciljane fokus grupe radi podrobnog razmatranja prednosti i slabosti predloženih koncepta u području željeznice. Također planirana je i radionica sa prezentacijom postignutih rezultata istraživanja i uvodnih informacija za anketu kako bi se saznanja podijelila s zainteresiranim stručnjacima na suradnički način. Na žalost, zbog objektivnih okolnosti radionica se nije mogla provesti, te je anketa provedena pisanim putem.

Anketni upitnik dan je kao prilog na kraju rada i sadrži pitanja na hrvatskom i engleskom jeziku u obliku otvorenih i zatvorenih anketnih pitanja. Eksperti će temeljem vlastite prosudbe na svako pitanje odgovoriti zaokruživanjem ponuđenih odgovora ili dodatnim dopisivanjem na kraju pitanja. Rezultati anketnog istraživanja osigurat će prikupljanje ekspertnog znanja u području željezničke problematike, te će se na osnovu dobivenih statističkih podataka iz ankete uspješnije predložiti poveznica između ulaznih okolišnih parametara željezničke infrastrukture i parametara za uspješnije postavljanje strategije upravljanja željezničkim prijevozom.

2.7.2. Rezultati ankete

Prikazivanje rezultata istraživanja konačna je faza u provedbi anketnog upitnika. Nakon provedenog anketiranja potrebno je sustavno i sveobuhvatno obraditi i prikazati dobivene rezultate. Potrebno je izbaciti nevažne informacije i digresije, te se osvrnuti na značajnost podataka. Rezultati moraju biti specifično usmjereni na problem istraživanja [125].

Anketa je obuhvatila 28 ispitanika iz istraživačke domene od čega je 12 iz Hrvatske i 16 izvan (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija). Anketiranje stručnjaka provedeno je uz prethodne kraće konzultacije putem e-pošte ili video-konferencije. Rezultati anketnog upitnika su potvrdili polazne teze za dizajniranje modela u pogledu najprikladnijeg algoritma za opisivanje okoline željezničke infrastrukture, te parametara vlažnosti i temperature kao jednih od ključnih za prilagođavanje procesa upravljanja prema kriteriju energetske učinkovitosti i povećanja prometne sigurnosti željezničkog prijevoza.

U procesu anketiranja utvrđene su neke specifičnosti. Anketa je distribuirana na hrvatskom i engleskom jeziku, i prema toj podjeli mogu se vidjeti razlike koje proizilaze iz geografske raspodjele, a očituju se u definiranju važnosti različitih parametara koji utječu na

željeznički promet. Primjer je visina snježnog pokrivača za alpske željeznice, dok je u Hrvatskoj nekoliko puta naveden potres kao važan čimbenik, što je vjerojatno posljedica niza katastrofalnih potresa u Hrvatskoj (gradovi Zagreb, Petrinja, Sisak) u vrijeme provođenja ankete. Zaključak je da je prometni proces i geografski značajno određen ako se proces upravljanja željezničkim prijevozom želi maksimalno optimizirati u smislu energetske učinkovitosti. Stoga je model redizajniran s mogućnošću dogradnje i promjene parametara za podršku cjelovitom modelu upravljanja.

Zaključno, u anketnom procesu je potvrđena prethodno postavljena hipoteza i može se reći kako je anketni upitnik zaista kvalitetna metoda za dobivanje vjerodostojnih podataka u istraživanju.

Prikupljeni odgovori iz anketnog upitnika su prikazani numerički i grafički ispod u tablicama 8. - 13. i grafički na slikama 42. - 53.

Tablica 8. Prikaz odgovora ispitanika u Hrvatskoj na prvo pitanje u anketnom upitniku.

Broj ispitanika van HR	Broj odgovora /1 ispitanik	Ukupni broj odgovora
12	4	48

Pitanje	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
Odgovori	12	7	1	2	1	0	0	7	11	0	5	2	0	0	0
Postotci %	100,00	58,33	8,33	16,67	8,33	0,00	0,00	58,33	91,67	0,00	41,67	16,67	0,00	0,00	0,00

Tablica 9. Prikaz odgovora ispitanika u Hrvatskoj na drugo pitanje u anketnom upitniku.

Broj ispitanika HR	Broj odgovora /1 ispitanik	Ukupni broj odgovora
12	2	24

Pitanje	a	b	c	d	e	f	g
Odgovori	12	0	2	3	7	0	0
Postotci %	100,00	0,00	16,67	25,00	58,33	0,00	0,00

Tablica 10. Prikaz odgovora ispitanika u Hrvatskoj na treće pitanje u anketnom upitniku.

Broj ispitanika HR		Broj odgovora /1 ispitanik		Ukupni broj odgovora		
12		2		24		
Pitanje						
a	b	c	d	e	f	g
Odgovori						
0	0	12	2	10	0	0
Postotci %						
0,00	0,00	100,00	16,67	83,33	0,00	0,00

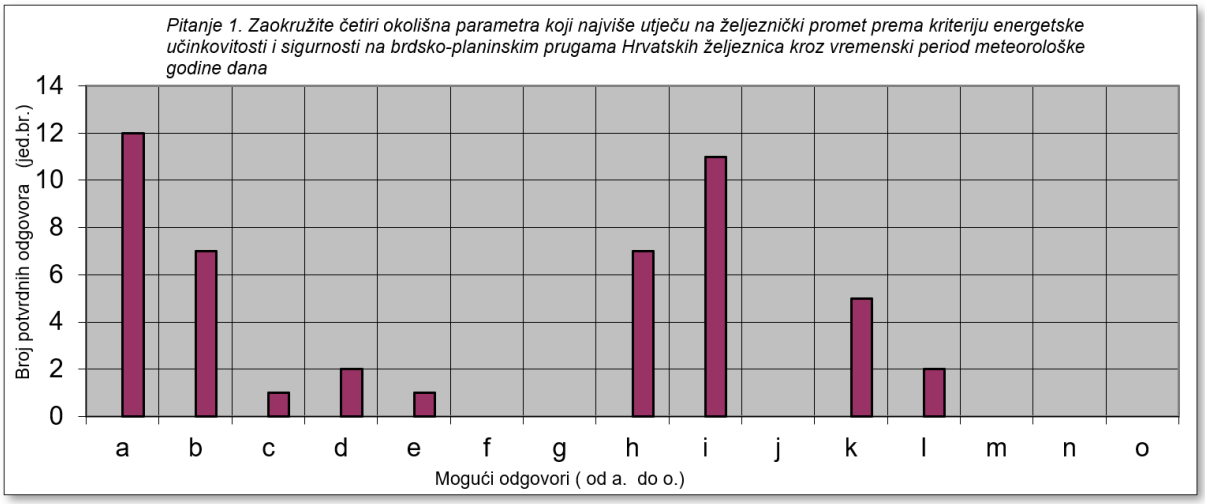

Slika 42. Prikaz distribucije odgovora ispitanika u Hrvatskoj na prvo pitanje u anketnom upitniku.

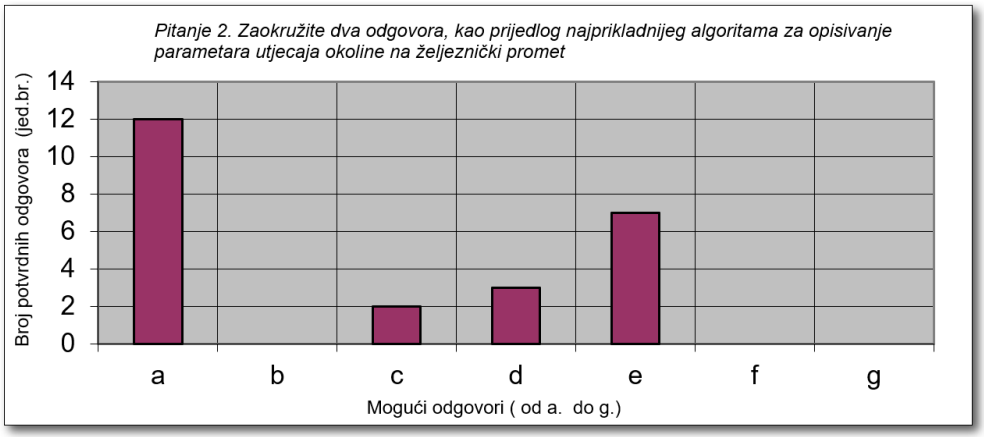

Slika 43. Prikaz distribucije odgovora ispitanika u Hrvatskoj na drugo pitanje u anketnom upitniku.

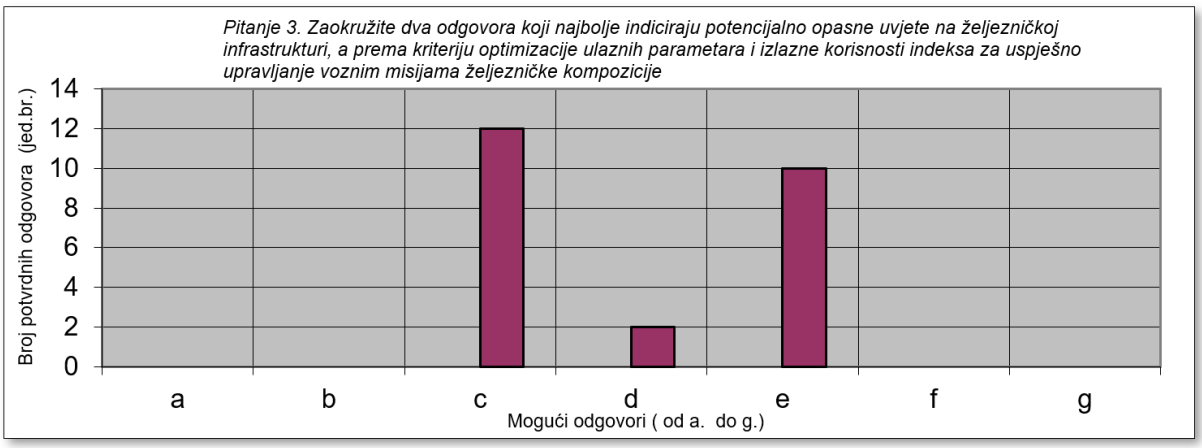

Slika 44. Prikaz distribucije odgovora ispitanika u Hrvatskoj na treće pitanje u anketnom upitniku.

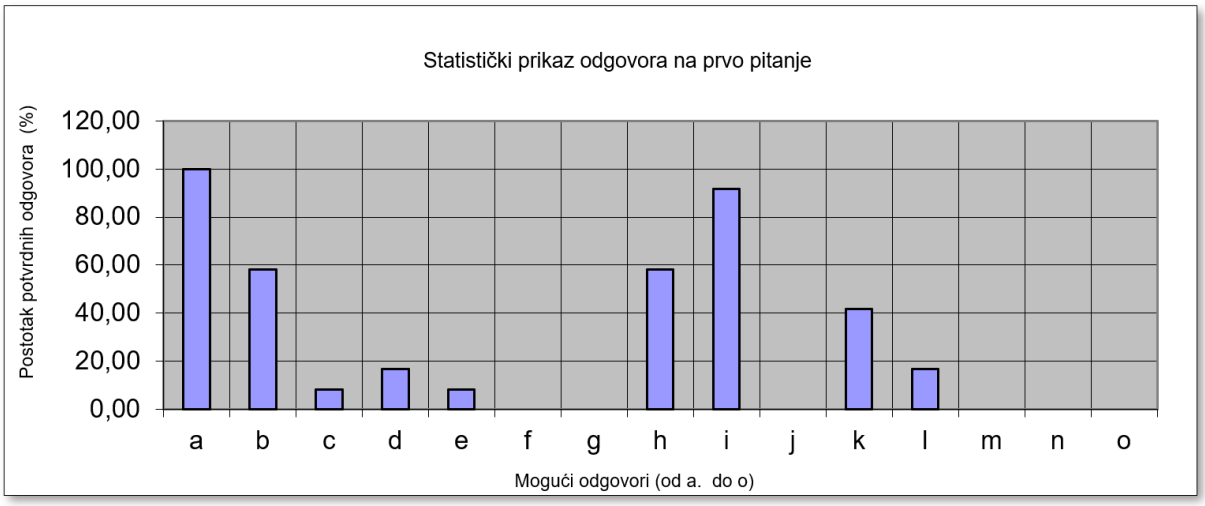

Slika 45. Grafički prikaz odgovora ispitanika u postotcima u Hrvatskoj na prvo pitanje u anketnom upitniku.

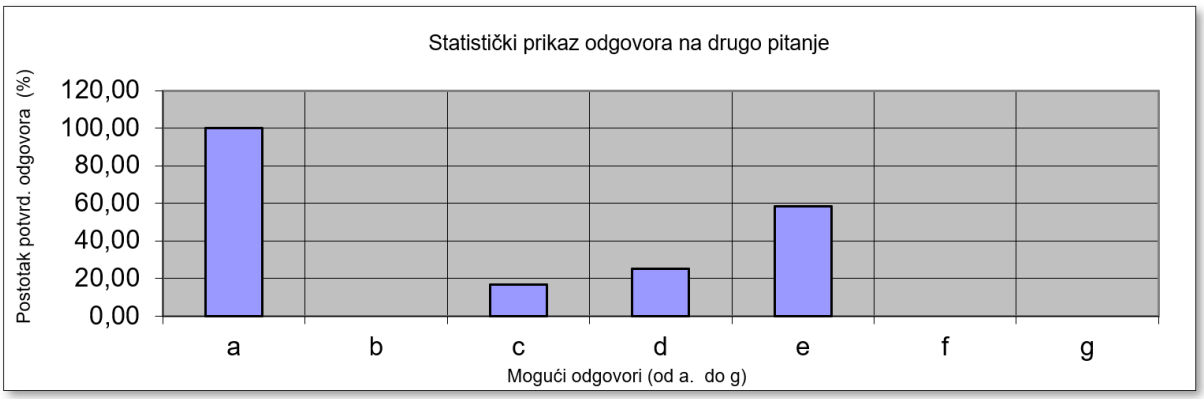

Slika 46. Grafički prikaz odgovora ispitanika u postotcima u Hrvatskoj na drugo pitanje u anketnom upitniku.

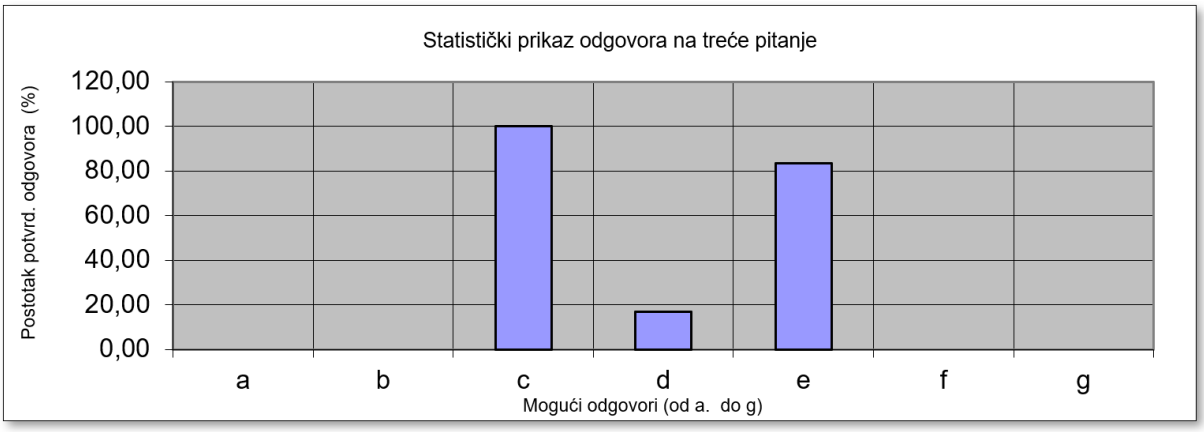

Slika 47. Grafički prikaz odgovora ispitanika u postotcima u Hrvatskoj na treće pitanje u anketnom upitniku.

Tablica 11. Prikaz odgovora ispitanika van Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na prvo pitanje u anketnom upitniku.

Broj ispitanika van HR		Broj odgovora /1 ispitanik		Ukupni broj odgovora										
16		4		64										
Pitanje														
a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
Odgovori														
16	13	0	4	3	0	0	12	13	0	0	3	0	0	0
Postotci %														
100,00	81,25	0,00	25,00	18,75	0,00	0,00	75,00	81,25	0,00	0,00	18,75	0,00	0,00	0,00

Tablica 12. Prikaz odgovora ispitanika van Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na drugo pitanje u anketnom upitniku.

Broj ispitanika van HR		Broj odgovora /1 ispitanik			Ukupni broj odgovora	
16		2			32	
Pitanje						
a	b	c	d	e	f	g
Odgovori						
15	0	1	8	8	0	0
Postotci %						
93,75	0,00	6,25	50,00	50,00	0,00	0,00

Tablica 13. Prikaz odgovora ispitanika van Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na treće pitanje u anketnom upitniku.

Broj ispitanika van HR		Broj odgovora /1 ispitanik			Ukupni broj odgovora	
16		2			32	
Pitanje						
a	b	c	d	e	f	g
Odgovori						
0	0	16	8	8	0	0
Postotci %						
0,00	0,00	100,00	50,00	50,00	0,00	0,00

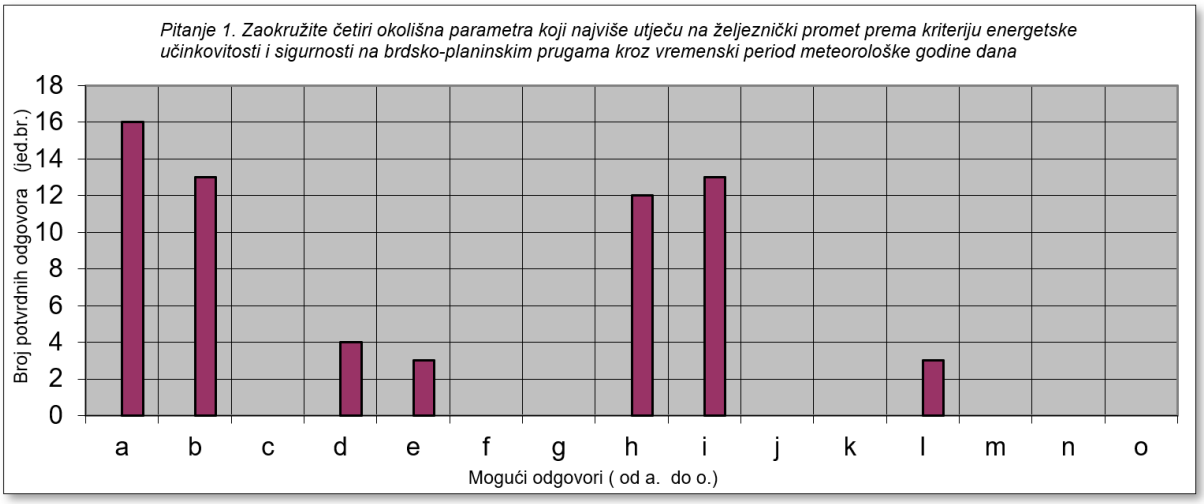

Slika 48. Prikaz distribucije odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na prvo pitanje u anketnom upitniku.

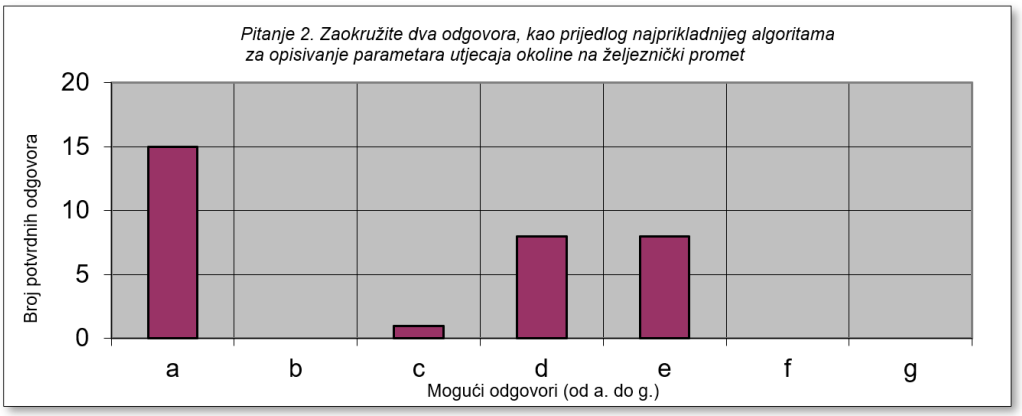

Slika 49. Prikaz distribucije odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na drugo pitanje u anketnom upitniku.

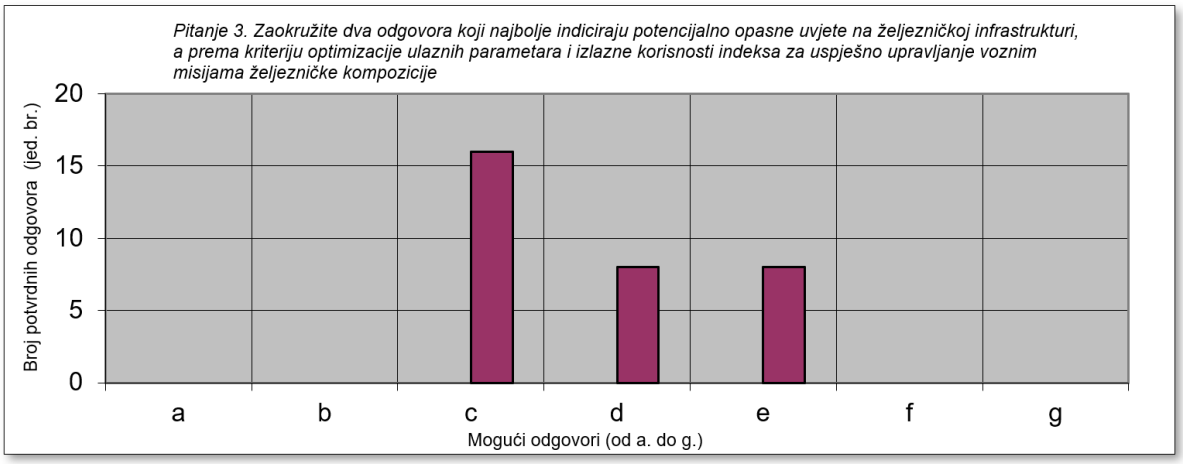

Slika 50. Prikaz distribucije odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na treće pitanje u anketnom upitniku.

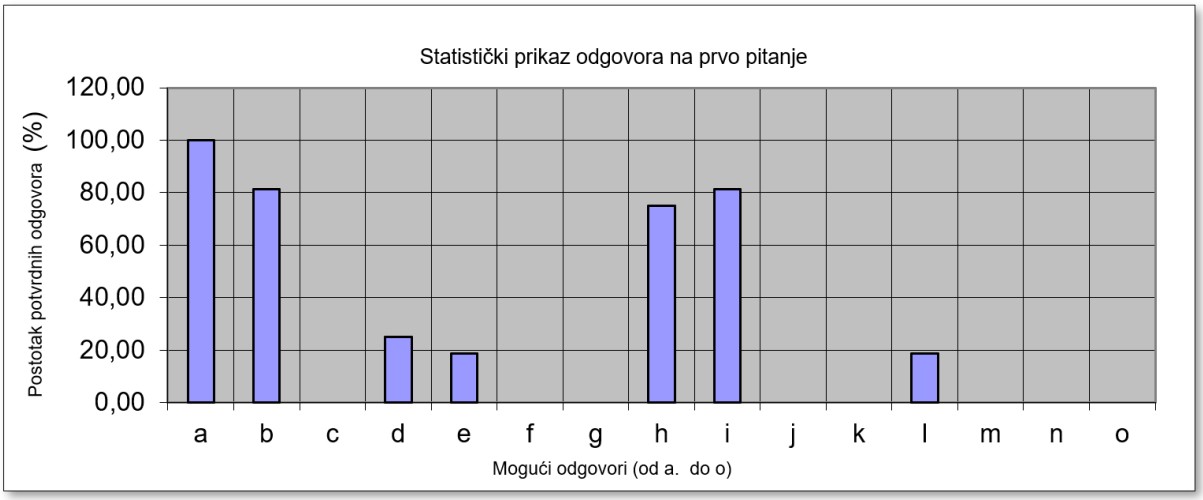

Slika 51. Grafički prikaz odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) u postotcima na prvo pitanje u anketnom upitniku.

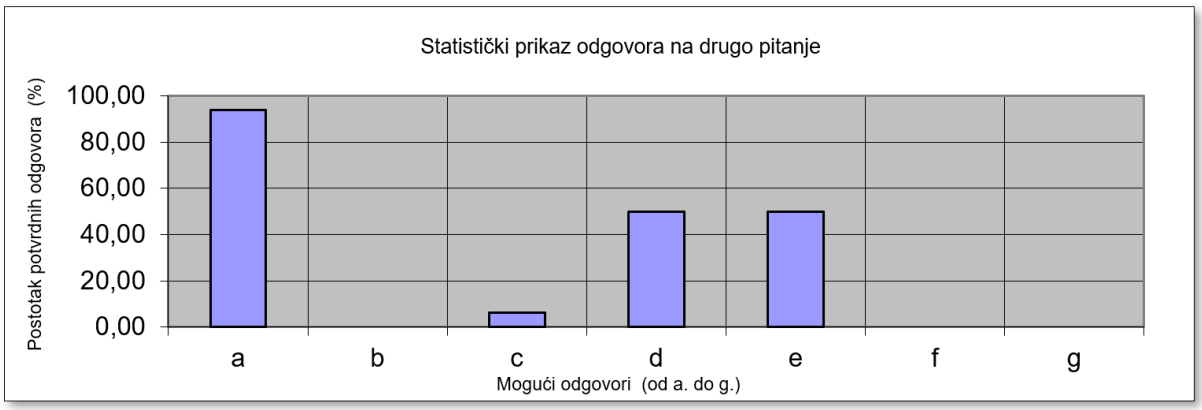

Slika 52. Grafički prikaz odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) u postotcima na drugo pitanje u anketnom upitniku.

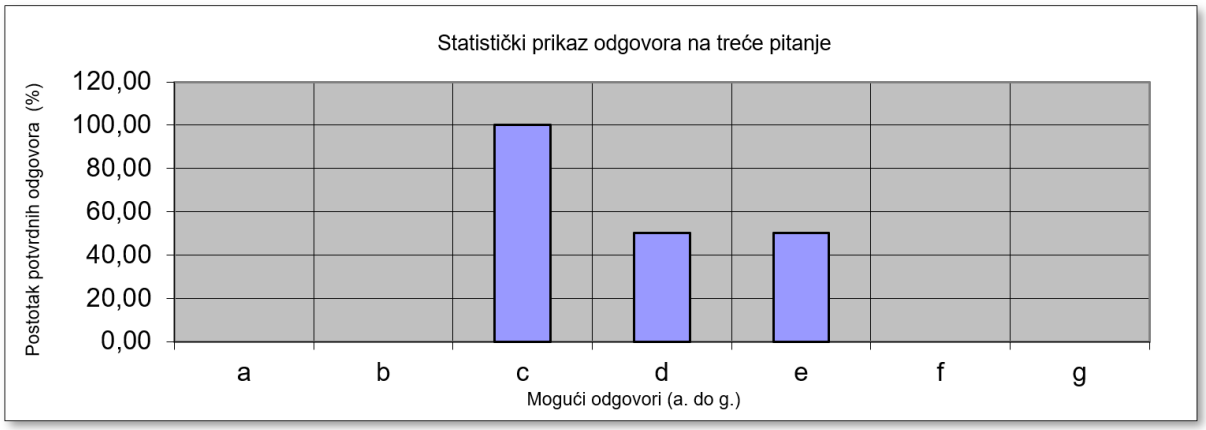

Slika 53. Grafički prikaz odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) u postotcima na treće pitanje u anketnom upitniku.

2.7.3. Ulazni podaci i validacija podataka

Prikupljanje, skladištenje i dinamičko korištenje prostorno i vremenskih distribuiranih podataka u prometnim sustavima povezano je s nizom izazova. Ovi podaci obično nisu statični i mijenjaju se tijekom vremena. Stoga je značajna karakteristika prirode prikupljanja prometnih podataka generiranje ogromne količine podataka, koji su vrlo složeni za analiziranje i primjenu.

Pod referencom [128] u radu „Prostorno vremenski model podataka zasnovan na događajima“ kaže se, prikupljene informacije sadržane u bazi podataka mogu se vremenom dodavati ili mijenjati, ali zapis promjene ili dinamike kroz vrijeme se ne zabilježava, pa sustav nije dovoljno optimiziran. Ovom ograničenju pridaje se značajna pažnja s obzirom na procese i uzročno-posljedične povezanosti promjenjivih ljudskih aktivnosti i zabilješki promjene okolišnih parametara [128].

U radu "Povijesni grafovi - konceptualno modeliranje prostorno vremenskih podataka" predložena je strategija utemeljena na model povijesnih grafova kako bi prikazala evolucija podataka koja proizlazi iz njihovih promjena tijekom vremena koristeći Petrijeve mreže. Na osnovi praćenja takvih promjena može se optimizirati sustav spremanja podataka te unaprijediti i ubrzati proces korištenja u drugim sustavima [129].

Za potrebe istraživanja u ovom radu skupovi ulaznih podataka za podmodele mogu biti generirani iz udaljenih senzora ili se mogu koristiti povijesni podaci iz dostupnih baza podataka. Za one podatke koji nisu strojno generirani, navedeni su vlasnici i uvjeti korištenja. Također je

provedena validacija ulaznih podataka uspoređivanjem vremenski određenih skupova iz različitih izvora koji opisuju isti događaj. Ovim postupkom je utvrđena valjanost senzora ili mjernog mjesta kao izvora vjerodostojnih podataka, ali i nekoliko različitih baza podataka.

Nekoliko vrsta senzora i mjernih uređaja je testirano u laboratorijskim uvjetima, kao što je prikazano na slici 54, te su nakon umjeravanja i uspoređivanja mjernih rezultata raspoređeni prema projektiranoj arhitekturi. Podaci su također prikupljani i iz željezničkog vozila u pokretu na relaciji: željeznička pruga M604 Oštarije - Knin - Split. Svi prikupljeni podaci su arhivirani i koriste se za testiranje modela u nekoliko verzija.

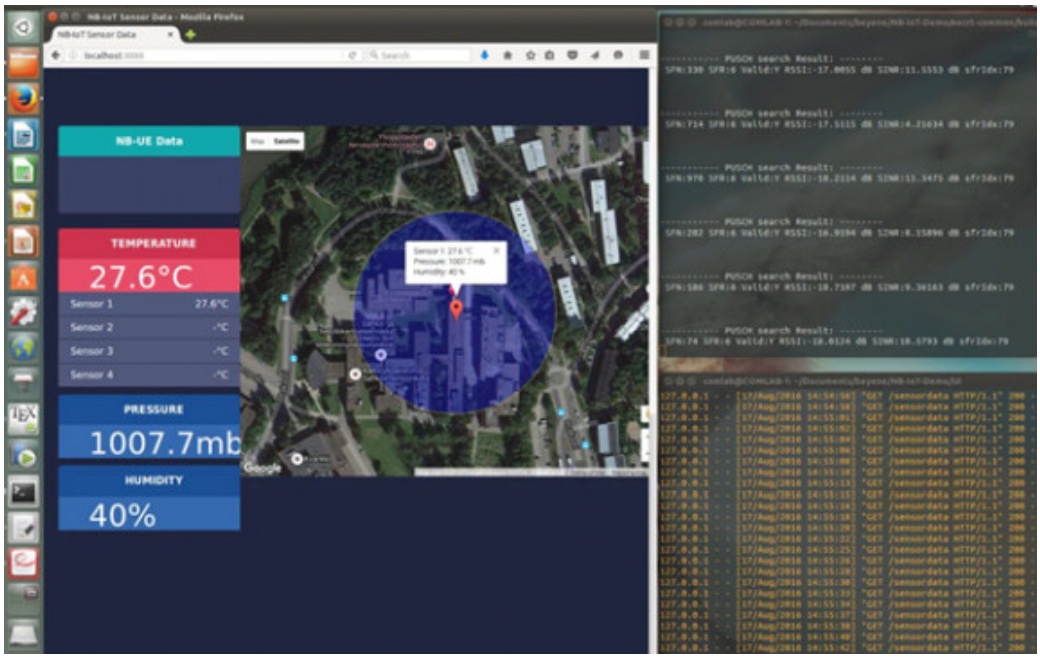

Slika 54. Testiranje, kalibracija i prikupljanje podataka mjerenja temperature i vlažnosti preko uskopojasnih NB-IoT senzora (engl. NarrowBand IoT) u Ericssonovom laboratoriju.

Na internet stranici DHMZ (Državni hidrometeorološki zavod), odnosno navedene podatkovne poveznice: https://meteo.hr/proizvodi.php?section=podaci&param=xml_korisnici mogu se preuzeti podaci u XML formatu, a koji se mogu koristiti za istraživačke namjene. DHMZ je kao uvjet korištenja naveo obavezno navođenje DHMZ-a kao izvora korištenih podataka. Ovim putem se zahvaljujem DHMZ na ustupljenim podacima s osnovnom svrhom korištenja predmetnih podataka u istraživačkom modelu za unaprjeđenje energetske učinkovitosti i prometne sigurnosti željezničkog prijevoza primjenom naprednih pogonskih tehnologija i udaljenih uskopojasnih senzorskih mreža.

Izvorni podaci na slici 55, ako se otvore u Internetskom pregledniku teško su čitljivi, no mogu se prevesti u tablični zapis pomoću uredske aplikacije LibreOffice-Calc [130]. Konverzijom ulaznih podataka i kreiranjem povezanih tablica podaci su pripremljeni za korištenje u modelu.

Slika 55. Izvorni DHZM podaci iz baze podataka.

Dodatni izvor mjerenih podataka je meteorološka mreža Pljusak [131] za mjerenje meteoroloških i klimatoloških efekata. Osnovu mreže čine automatske meteorološke stanice, spojene na računalo koje potom podatke obrađuje, te šalje periodične izvještaje putem Interneta. Sustav podržava sljedeće programe: HRMeteoHub, Cumulus i WeatherLink. Na slici 56. su prikazane mjerne pozicije mreže Pljusak u trenutku slanja podataka.

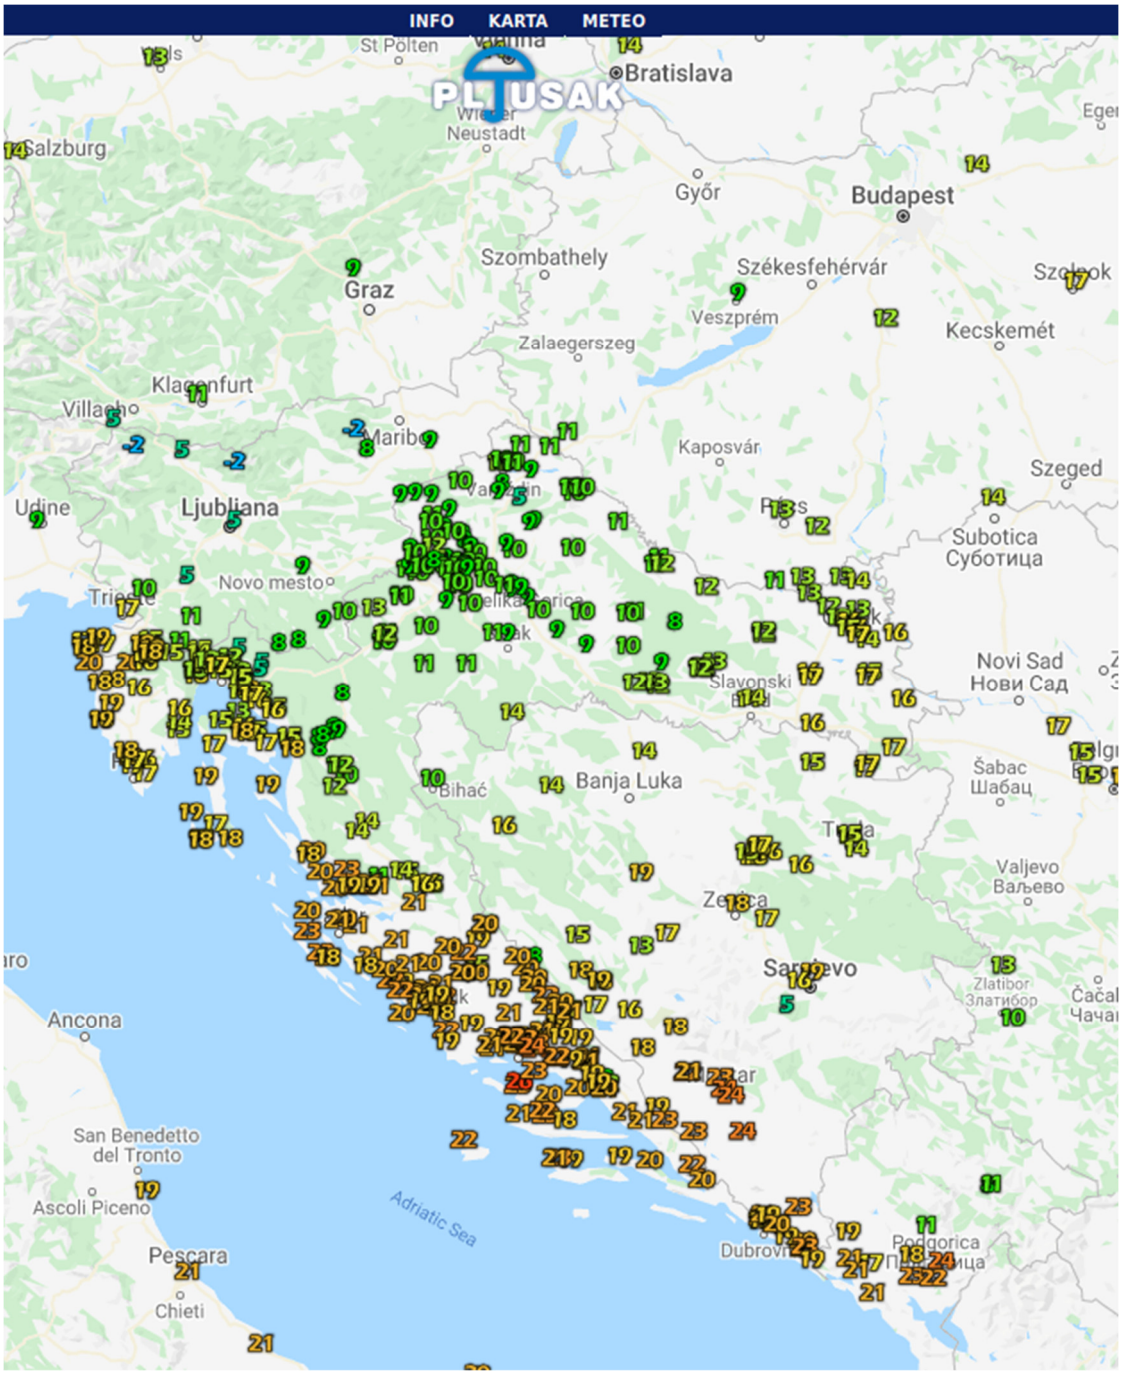

Slika 56. Mjerne pozicije mreze Pljusak

Mreža Pljusak pruža korisnicima uvid u obrađene izvještaje s automatskih meteoroloških stanica spojenih na računala te omogućava pristup podacima trećih osoba, s čime

INFO METEO

HRVATSKA - SJEVEROZAPAD I ISTOK

Mjesto	MNV	Termin Sat	Temperatura °C	min.	u	maks.	u	Vjetar smjer	m/s	maks	u	Tlak hPa	Vlaga %	Oborine 1 sat	danas	mjesec
Čakovec, Eltel **	163	13:15	11.5	7.5	04:25	11.5	13:15	S	0.9	4.8	10:55	-	73	0.0	0.0	0.0
Donji Kraljevec	146	13:14	11.0	7.2	04:49	11.0	13:14	SSW	0.0	2.6	08:59	997.3	73	0.0	3.8	25.2
Varaždin, SIPS	165	13:15	11.2	7.1	05:15	11.3	13:10	ENE	0.5	3.1	08:30	1016.2	70	0.0	6.2	50.8
Varaždin	170	13:14	9.9	7.1	03:14	9.9	13:14	SSE	4.0	8.0	08:29	1016.2	75	0.0	4.1	27.2
Varaždin jug	170	13:13	12.3	6.4	06:18	12.3	13:08	SE	0.3	3.9	10:14	1015.0	68	-	5.9	45.5
Varaždin DHMZ	167	13:00	9.8	7.0	04:00	9.8	13:00	S	2.2	4.6	08:00	1017.1	76	-	-	-
Trnovec B. Zona	161	13:14	10.3	7.1	03:23	10.3	13:14	SW	3.3	5.8	07:43	1017.0	73	0.0	3.3	33.8
Trnovec Bartolovečki	164	13:14	10.3	7.2	05:44	10.6	12:59	SSW	3.1	6.7	07:07	1016.3	75	0.0	4.6	34.0
Sudovčina	160	13:17	9.2	5.6	04:06	9.5	13:06	SW	1.0	4.6	06:51	1013.3	77	0.0	4.1	20.4
Maďarevo	240	13:12	8.9	6.4	05:17	8.9	12:22	SSE	2.8	5.8	11:52	1023.4	87	0.0	0.0	19.5
Koprivnica, Varaždinska	150	13:14	9.6	7.2	04:49	9.7	13:09	SSW	2.7	7.6	09:39	1017.5	80	0.0	2.3	8.4
Koprivnica, Poligon	139	13:12	10.1	6.5	05:07	10.2	12:47	SSW	0.8	2.5	09:47	1009.1	83	-	3.6	11.6
Koprivnica, Ivanščak	139	13:15	9.7	7.0	05:30	9.8	12:35	ESE	2.7	6.3	10:10	1015.6	83	-	3.6	7.9
Koprivnica, Herešin	128	13:16	10.1	7.2	04:56	10.1	13:11	W	2.7	4.0	10:36	1015.5	82	-	3.6	10.0
Kalinovac	121	13:13	10.7	7.1	06:13	11.1	11:28	SSW	0.0	2.5	05:22	1017.9	81	0.0	2.0	9.9
Desinić	218	13:12	9.0	5.9	04:27	9.0	13:12	SE	0.0	1.9	08:52	994.6	94	-	16.8	58.2
Ivanščica poletište	1070	13:12	2.0	0.0	02:57	2.0	13:12	S	1.9	2.6	00:32	892.0	90	0.0	-	0.0
Ravna Gora poletište	650	13:12	4.4	2.4	03:17	4.4	13:12	SSW	2.7	3.8	09:07	936.0	100	0.0	-	0.0
Kalnik, Vranilac	614	13:12	5.0	3.4	09:27	5.0	13:12	S	1.3	3.2	08:07	1014.2	97	0.0	-	0.0
Kalnik, Borje	435	13:13	6.1	4.4	09:18	6.1	13:13	SSE	1.2	3.0	07:43	1015.3	97	0.0	-	0.0
Jugovec	314	13:12	7.9	5.7	06:47	8.0	12:18	SSE	1.0	1.9	10:43	1005.6	82	0.0	-	0.0
Lepoglava	264	13:10	9.9	6.1	03:35	9.9	13:05	SSW	1.2	6.5	09:25	1007.8	80	0.0	6.2	57.9
Pregrada	185	13:15	9.4	6.7	03:15	9.4	13:10	WSW	0.0	0.4	00:35	1015.0	86	0.0	11.6	49.4
Krapina DHMZ	202	13:00	8.8	6.6	05:00	8.8	13:00	SW	1.1	1.9	12:00	1017.5	80	-	-	-
Bobovje	185	13:14	8.7	6.8	04:59	8.7	13:14	SW	2.2	3.1	12:39	1015.8	83	0.0	10.9	53.1
Karane	140	13:14	8.9	6.9	05:39	8.9	13:09	S	2.2	4.9	11:09	1017.4	82	0.0	2.3	9.5
Križevci DHMZ	155	13:00	9.2	7.2	05:00	9.2	12:00	W	2.2	2.9	00:00	1017.8	76	-	-	-
Križevci	151	13:15	9.3	6.9	06:00	9.4	13:00	N	0.0	1.7	07:00	1017.2	86	0.0	2.0	7.8
Bjelovar	125	13:14	9.7	7.1	06:39	9.7	13:14	NW	1.3	4.9	07:49	1017.8	83	0.0	1.8	5.7
Bjelovar DHMZ	141	13:00	10.3	7.3	07:00	10.3	13:00	N	0.8	2.4	06:00	1017.5	75	-	-	-
Viča Sela	155	13:15	11.4	8.4	06:10	11.4	13:15	SSE	2.7	3.1	01:00	1017.3	72	0.0	4.8	35.4
Gubaševo	146	13:15	9.6	6.9	05:15	9.6	13:05	ESE	1.0	2.0	08:45	1017.3	80	0.0	5.1	38.9
Brestovec Orehovički	174	13:14	9.0	6.8	05:58	9.1	12:19	W	0.9	2.7	11:04	1018.9	83	-	8.2	37.9
Oroslavje	231	13:27	9.2	7.1	08:42	9.2	12:27	W	-	-	00:17	1015.9	87	0.0	4.8	24.4
Gornja Stubica	201	13:01	10.2	7.1	04:41	10.2	13:01	ENE	0.0	8.1	09:06	1016.9	80	0.0	2.4	16.2
Sveti Matej	322	13:15	8.9	5.4	04:45	8.9	13:15	N	0.0	0.0	00:05	1017.0	73	0.0	0.0	0.0
Donji Laduč	206	13:13	9.4	5.8	07:58	9.4	13:13	WSW	0.3	1.4	04:18	1017.0	83	0.0	7.1	32.5
Brdovec	137	13:13	9.6	6.7	07:58	9.7	13:08	SW	0.3	2.5	07:53	1018.0	80	-	7.9	23.4
Oborovo Bistransko	164	13:15	11.7	7.6	05:45	11.9	13:05	W	1.3	2.7	08:45	1016.7	66	0.0	4.3	11.6
Jakovlje	164	13:13	9.5	6.4	05:43	9.5	12:54	W	0.0	3.6	09:43	1016.0	82	0.0	5.1	26.9
Sljeme	1026	13:15	1.8	0.7	04:30	2.2	11:50	SE	-	-	00:05	895.8	97	0.0	0.0	0.0
Puntijarka DHMZ	994	13:00	2.9	0.6	06:00	2.9	13:00	SE	4.2	5.0	10:00	901.0	99	-	-	-
Čučerje, Vučja jama	492	13:15	6.5	4.1	08:40	6.5	13:15	SSW	0.9	3.6	07:45	1017.0	91	0.0	5.4	20.6
Planina Donja	298	13:13	8.3	5.6	04:58	8.5	13:08	ESE	0.0	2.5	00:08	1015.0	84	0.0	3.7	16.2
Kašina, Liševo	276	13:15	8.6	6.2	04:45	8.6	13:10	WSW	0.9	2.7	07:35	1015.7	85	0.0	6.0	18.5
Kašina, Frljur	200	13:13	9.0	6.3	08:43	9.2	13:09	SSW	0.0	3.9	07:29	1015.0	68	0.0	3.3	15.5
Žerjavinec	138	13:15	9.6	7.1	04:15	9.7	13:05	N	0.4	5.8	00:05	1017.7	77	0.0	6.1	33.1
Sesvete, Kraljevečki Novaki	130	13:13	9.9	6.8	03:59	9.9	13:13	SSE	0.3	3.6	11:33	1014.0	74	0.0	6.6	26.6
Dugo Selo	109	13:14	9.8	6.9	07:28	9.8	12:14	SSW	0.0	1.9	00:04	1013.0	73	-	6.4	22.1
Rugvica	102	13:17	9.4	7.3	07:57	9.7	12:57	ESE	1.3	3.1	08:57	1016.4	76	0.0	5.8	9.0
Graberanec	173	13:14	9.0	6.7	01:24	9.1	12:58	N	1.9	6.7	00:13	-	84	0.0	6.6	22.2
Vrbovec	125	13:10	10.0	7.5	04:20	10.0	13:10	SW	0.6	1.0	12:10	1015.8	74	-	4.5	16.2
Samobor, Sv. Helena	200	13:14	9.2	6.9	07:59	9.2	13:04	SE	3.1	8.5	07:44	1016.7	79	0.0	6.9	18.1
Samobor	205	13:15	10.2	6.7	04:10	10.2	13:15	SSE	0.0	0.9	12:00	1016.9	81	0.0	6.7	11.8
Jagnjić Dol	210	13:16	9.7	6.3	07:19	9.7	13:16	NW	0.5	1.5	12:21	1018.5	81	0.0	17.5	23.1
Orešje	128	13:15	10.2	7.4	07:35	10.2	13:00	S	0.0	1.0	02:05	1016.6	79	-	11.2	22.4

Slika 57. Mjerni podaci mreze Pljusak

se korisnik suglasio prihvaćanjem uvjeta korištenja, a koji između ostalog navode i sljedeće: „Pljusak zadržava pravo ukidanja kao i promjene izgleda, sadržaja i uvjeta korištenja Pljuska bez prethodne najave i neće biti odgovoran ni za kakve moguće posljedice proizašle iz takvih promjena.“

Meteorološki podaci prikazani na stranici Pljuska nisu službeni podaci, već se koriste kao istraživački podaci. Službene podatke objavljuju državni meteorološki zavodi (u Hrvatskoj: DHMZ, meteo.hr). Ovim putem se zahvaljujem mreži Pljusak na ustupljenim podacima s osnovnom svrhom korištenja predmetnih podataka u istraživačkom modelu za unaprjeđenje energetske učinkovitosti i prometne sigurnosti željezničkog prijevoza primjenom naprednih pogonskih tehnologija i udaljenih uskopojasnih senzorskih mreža.

2.7.4. Upravljanje „fuzzy“ logikom - klasifikator stanja trase

Na osnovi prethodno navedenih podataka (koji bi bili dostupni preko mreže udaljenih bežičnih senzora, a to su temperatura i apsolutna vlažnost zraka) može formirati sustav za klasifikaciju stanja trase temeljen na metodama umjetne inteligencije kao što je neizrazita (fuzzy) logika [132]. Neizrazita (engl. fuzzy) logika tipične primjene nalazi u ekspertnim sustavima, gdje se stručno znanje može predstaviti u obliku lingvističkih pravila AKO-ONDA (engl. IF-THEN) [132]. Slika 58. prikazuje blokovski dijagram klasifikatora stanja trase zasnovanog na neizrazitoj logici, a koji se temelji na mjerenjima temperature T i apsolutne vlažnosti H_A zraka putem udaljene mreže bežičnih senzora koja se kombiniraju unutar algoritma neizrazitog odlučivanja.

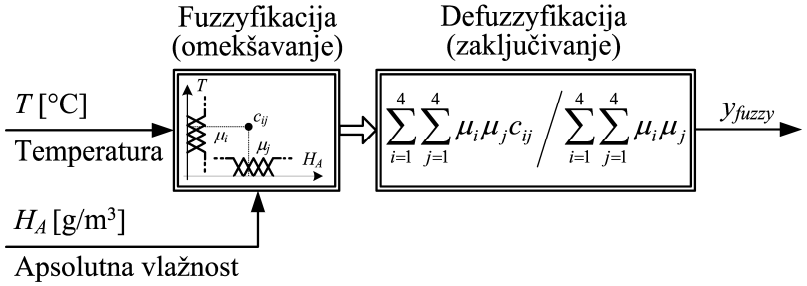

Slika 58. Blokovski prikaz algoritma klasifikatora stanja trase primjenom neizrazite logike.

Lingvistička pravila koja definiraju ulazni dio neizrazitog zakona upravljanja(takozvana fuzzyfikacijaili omekšavanje ulaznih podataka) daju se kako slijedi:

$$\textbf{AKO } T \in \mu_i(T) \textbf{ I } H_A(k) \in \mu_j(H_A) \textbf{ ONDA } y_{fuzzy}(i,j) = g_{ij}(T, H_A) \tag{2-22}$$

gdje su $\mu_i(T)$ i $\mu_j(H_A)$ funkcije pripadnosti signala temperature T i apsolutne vlažnosti zraka H_A, a $g_{ij}(\cdot)$ su vrijednosti izlazne funkcije u dijelu neizrazitog sustava koji provodi zaključivanje (ili defuzzyfikaciju), a koje su ovdje definirani kao konstantni težinski faktori u izlaznom skupu pravila, tzv. „solitoni“ s konstantnom vrijednošću ($g_{ij}(\cdot) = c_{ij}$).

Izlaz neizrazitog klasifikatora y_{fuzzy} se stoga može prikazati kao ponderirana (otežane) suma (definirane na način kao u referenci [133]) :

$$y_{fuzzy} = \frac{\sum_{i=1}^{4}\sum_{j=1}^{4} \mu_i(T)\mu_j(H_A)c_{ij}}{\sum_{i=1}^{4}\sum_{j=1}^{4} \mu_i(T)\mu_j(H_A)} \tag{2-23}$$

Funkcije pripadnosti $\mu_i(T)$ i $\mu_j(H_A)$ i težinski koeficijenti (solitoni) c_{ij} predloženog neizrazitog klasifikatora prikazani su na slici 59. i odgovaraju sljedećim skupovima vrijednosti ulaznih signala: ZN (nula ili negativan) odnosno ZE (nula), SMP (mali do srednji pozitivan), MLP (srednji do veliki pozitivni) i LP (veliki pozitivni). Funkcije pripadnosti su ili trapezne (ZN i LP skupovi) ili trokutaste (ZE, SMP i MLP skupovi), kao što je prikazano na slikama 59a. i 59b. Solitoni c_{ij} u izlaznom dijelu neizrazitog algoritma (slika 59c) dodjeljuju veće težine većim vrijednostima temperatura T i manjim iznosima apsolutne vlažnosti zraka H_A i obratno, kako izvorno i sugeriraju karakteristike koeficijenta trenja u funkciji ovih veličina.

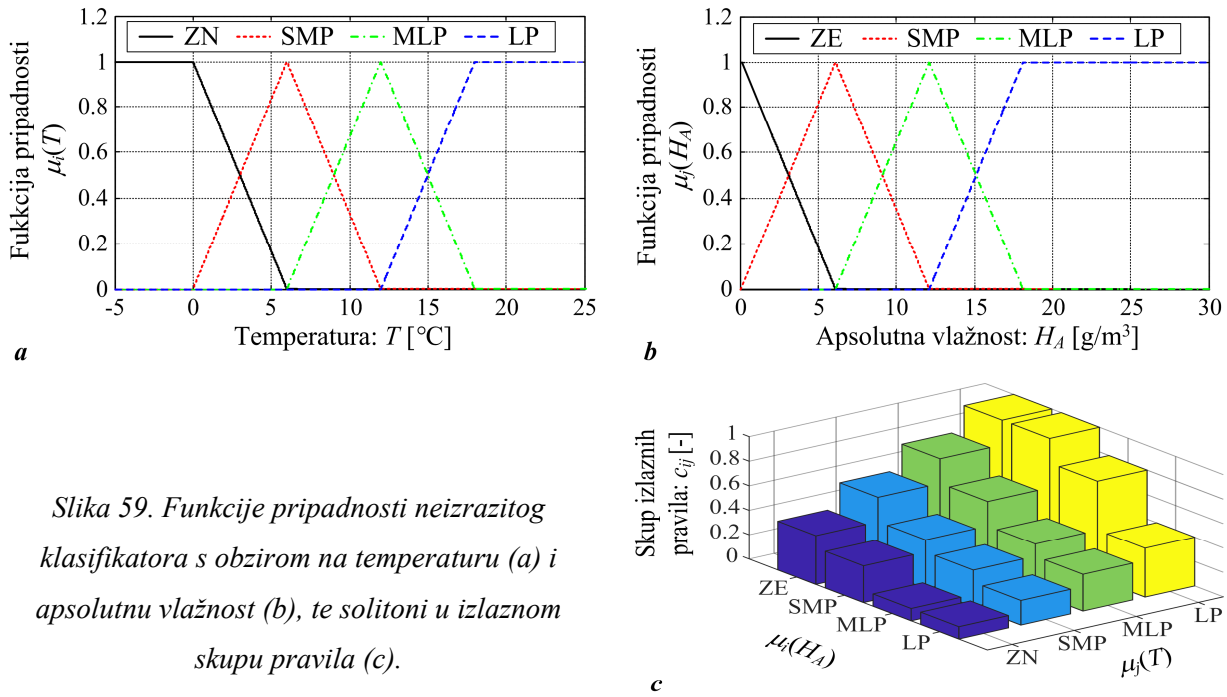

Slika 59. Funkcije pripadnosti neizrazitog klasifikatora s obzirom na temperaturu (a) i apsolutnu vlažnost (b), te solitoni u izlaznom skupu pravila (c).

3. SIMULIRANJE ŽELJEZNIČKOGA PRIJEVOZA NA TRASI BRDSKO PLANINSKE PRUGE

3.1. Simulacija vozne misije pogonjene konvencionalnom diesel-električnom lokomotivom

Razmatrani scenarij vožnje, prikazan na slici 60, odgovara povratnom putovanju planinskom rutom prikazanom na slici 22 u poglavlju 2.1, sa sedam potpuno natovarenih teretnih vagona nosivosti od 90 t. Navedeno otprilike odgovara maksimalnom opterećenju za jednu lokomotivu koja putuje tom rutom, a koje je obično ograničeno na 600 t [134].

Budući da su ograničenja brzine poznata unaprijed (slika 22c u potpoglavlju 2.1), referentna brzina vlaka v_{ref} (crvena linija na slici 60c) generira se kao postupna promjena ciljne brzine kroz interval od 2 km pomoću a-priori poznatog profila ograničenja brzine vlaka. Budući da takva referenca brzine također sprječava prekomjerna ubrzanja i usporavanja, očekuje se da bi u tom slučaju kod usporavanja bilo pretežno korišteno regenerativno kočenje. Za zadani profil brzine v_{ref} i stvarnu brzinu vlaka v (plava krivulja na slici 60c), model strojovođe proračunava komande akceleratora (Notch) i kočenja (Brk) prikazane na slici 60b.

Ovdje valja napomenuti da pozitivne vrijednosti komande strojovođe na slici 60b odgovaraju vuči, dok negativne vrijednosti odgovaraju regenerativnom kočenju, osim kada je, zbog male brzine vlaka, potrebno uključiti i mehaničke kočnice (kako je prethodno objašnjeno), naročito tijekom spuštanja vlaka na prilično strmom nagibu kolosijeka (vidi slike 60a i 60b). S druge strane, grafikoni brzine vlaka na slici 60c pokazuju da raspoloživa snaga vuče vlaka nije uvijek dovoljna da slijedi referentnu trajektoriju brzine tijekom uspinjanja vlaka, iako se vlak još uvijek može uspinjati trasom pri nižim brzinama. Slika 60c također pokazuje da uzdužna brzina vlaka može premašiti referentnu (ograničenje brzine) tijekom određenih silaznih intervala (npr. 200 km < l < 280 km), što je posljedica nedovoljne snage regenerativnog kočenja pogonskog sustava i relativno jednostavnog zakona upravljanja temeljenog na modelu virtualnog vozača. Naravno, u stvarnoj primjeni strojovođa bi se morao strogo pridržavati ograničenja brzine. Također, treba voditi računa da se u danom slučaju razmatra najgori mogući scenarij opterećenja vlaka, pa bi se očekivalo bolje praćenje referenci u slučaju manjeg opterećenja ili više lokomotiva koje rade u tandemu.

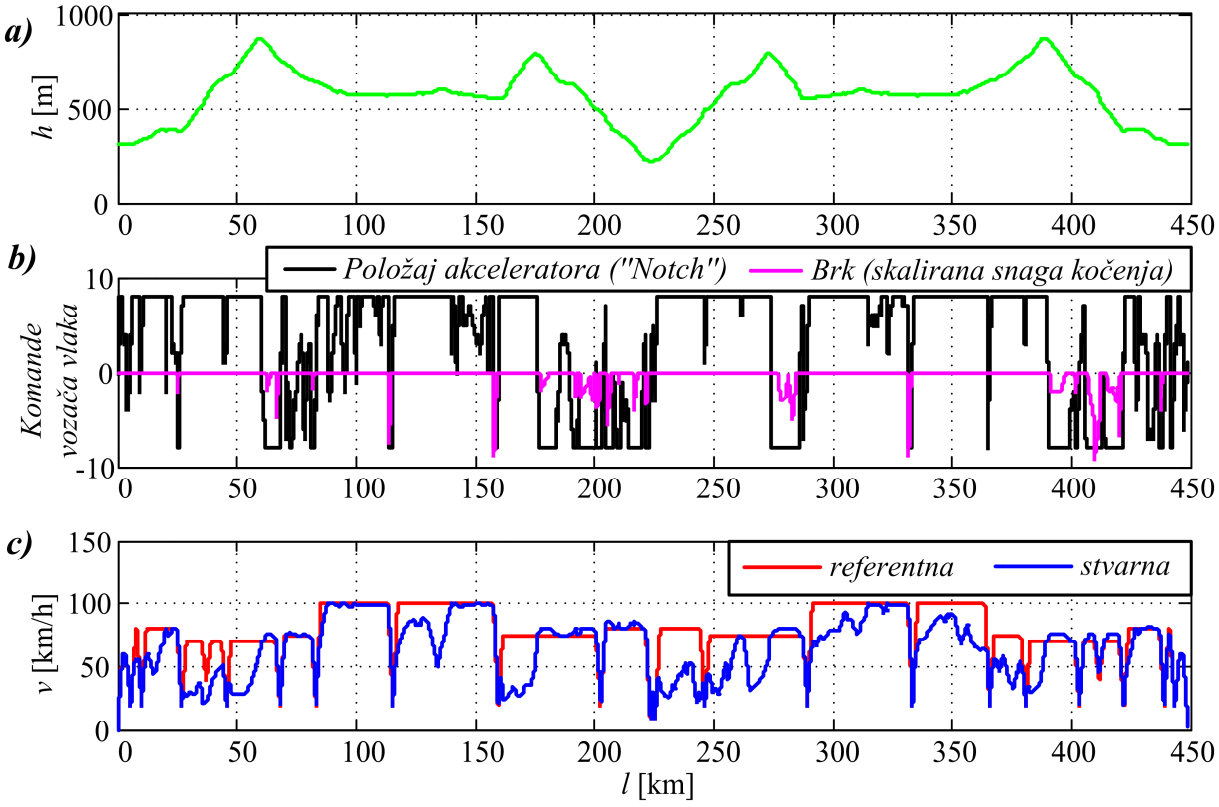

Slika 60. Profil nadmorske visine za predloženi scenarij vožnje (a), komande strojovođe (b) i profili brzine vlaka (c).

Slika 61. prikazuje snagu električnog sustava vuče lokomotive i kumulativnu potrošnju goriva, zajedno s potrošnjom električne energije i potencijalom za povrat energije.

Plava krivulja na slici 61a prikazuje snagu električnog sustava vuče, povezanu s promjenom položaja akceleratora („Notch“ komanda strojovođe, vidi sliku 60b) prema statičkoj mapi sustava vuče (slika 28b u potpoglavlju 2.4), a koja također uključuje učinkovitost pretvorbe energije.

Kumulativna volumna potrošnja goriva (u litrama) prikazana je crvenom krivuljom, a izračunava se iz masenog protoka goriva povezanog sa snagom prema sljedećem izrazu:

$$V_f = \frac{1}{\rho_f} \int_0^{t_f} \dot{m}_f \, dt \tag{3-1}$$

gdje je $\rho_f = 850$ kg/m^3 = 850 g/L gustoća dizelskog goriva.

Slika 61b prikazuje potrebu za električnom energijom sustava vuče za razmatrani scenarij vožnje, dok slika 61c prikazuje potencijal povrata električne energije, koji se naknadno koristi kao osnova za dimenzioniranje sustava za pohranu energije u bateriji. Potonje se procjenjuje integriranjem u vremenu električne snage sustava vuče tijekom razdoblja elektrodinamičkog kočenja, nakon čega slijedi integracija pozitivnih vrijednosti vučne snage dok se na taj način akumulirana energija ne potroši, što bi predstavljalo razdoblja potpomognute vuče iz baterije koja su omogućena regenerativnim povratom kinetičke energije u bateriju.

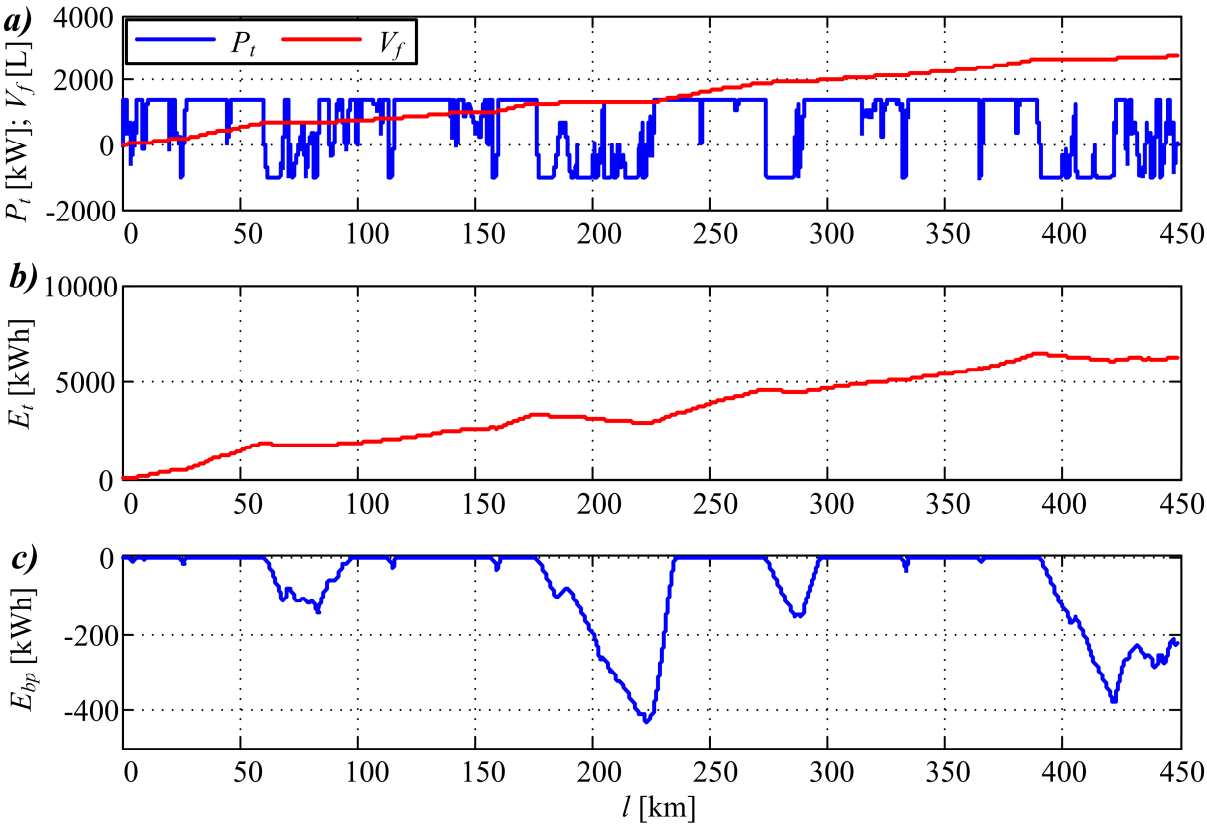

Slika 61. Snaga električne transmisije (sustava vuče) lokomotive i kumulativna potrošnja goriva (a), utrošena električna energija (b) i potencijal povrata energije (c).

3.2. Simulacija vozne misije pogonjene hibridnom lokomotivom

Prethodni simulacijski scenarij (slika 60) ponovljen je za teretnu kompoziciju temeljenu na baterijsko-hibridnoj dizel-električnoj lokomotivi, a koji odgovara povratnom putovanju planinskom rutom prikazanom u poglavlju 2 (i profilom nadmorske visine prikazanom na slici 22a u potpoglavlju 2.1, odnosno na slici 60a u ovom potpoglavlju) sa sedam potpuno natovarenih 90-tonskih teretnih vagona. Budući da su u simulacijama korišteni isti model pogona i karakteristike vuče, a težina vlaka zanemarivo je promijenjena zbog nešto veće mase (težine) hibridne lokomotive (107,85 t u odnosu na 103 t konvencionalne), dobivene su slične performanse u vožnji vezano za ubrzanja i profil brzine vlaka. Ovo je potvrđeno grafom razlike u brzini Δv između konvencionalne dizel-električne lokomotive (referentne vrijednosti) i baterijsko-hibridne lokomotive koja se koristi za prijevoz tereta, a koji je prikazan na slici 62.

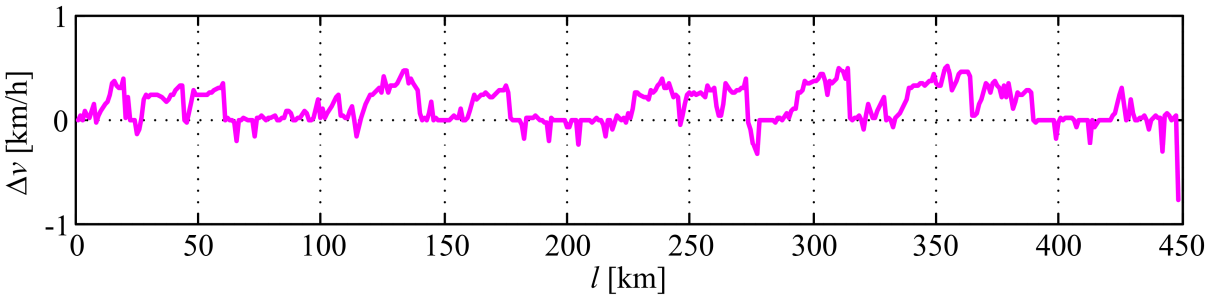

Slika 62. Prikaz razlike u postignutim brzinama vlaka između konvencionalne i baterijsko-hibridne lokomotive.

Unutar baterijsko-hibridne lokomotive, raspoloživa snaga električne vuče P_t uključuje izlaznu snagu glavnog generatora (agregata) P_g i snagu baterije P_{batt}. U slučaju kada vlak ubrzava i uspinje se po trasi, zbog skaliranja glavnog motora, snaga iz agregata nije dovoljna da osigura potrebnu vučnu snagu, pa se baterija prazni i njezino stanje napunjenosti se počinje smanjivati (vidi slike 63 i 60). U slučaju regenerativnog kočenja tijekom usporavanja ili vožnje nizbrdo, baterija se puni i zauzvrat joj se povećava SoC. Slika 63a prikazuje dinamički odziv *SoC* varijable baterije kada se koristi konstanta referenca stanja napunjenosti, dok je u slučaju adaptivne reference stanja napunjenosti, odnosno reference koja se prilagođava nadmorskoj visini, stanje napunjenosti baterije prikazano na slici 63b.

Prema očekivanjima, adaptivna referenca *SoC* rezultira da stanje napunjenosti baterije može poprimiti niže vrijednosti u odnosu na slučaj konstantne reference *SoC*, jer se u prvom slučaju referentna vrijednost dinamički prilagođava tako da odražava varijacije u raspoloživoj potencijalnoj energiji. Na taj se način učinkovito izbjegava se prepunjavanje baterije (vidi slike 63a i 63b), što je korisno sa stajališta broja radnih ciklusa baterije i njenog vijeka trajanja. Štoviše, varijabilna referenca *SoC* također rezultira blagim smanjenjem potrošnje goriva, što je vidljivo iz rezultata u tablici 8). Crvene isprekidane krivulje na slikama 63a i 63b predstavljaju odzive SoC baterije u slučaju kada se kapacitet baterije smanji za 20%, a unutarnji otpor poveća za 100% s obzirom na njihove nominalne vrijednosti (čime se oponašaju učinci starenja baterije prema [135]). Za obje vrste reference *SoC* baterijsko-hibridna lokomotiva opremljena robusnim regulatorom stanja napunjenosti još uvijek uspijeva osigurati potrebnu snagu za vuču i istodobno održavati *SoC* baterije iznad 20%. Tijekom punjenja baterije sprečava se prekomjerno punjenje prekidanjem punjenja kada SoC baterije dosegne 95%, pri čemu se višak električne energije tijekom električnog kočenja može preusmjeriti na mrežu disipacijskih otpornika, osim ako se ne bi koristili različiti pomoćni sustavi kao što su klimatizacija,

osvjetljenje i slično, a koji bi bili sposobni apsorbirati višak proizvedene energije. Slika 63c prikazuje grafikone potrošnje goriva za konvencionalnu lokomotivu i njezine baterijsko-hibridne izvedenice sa i bez adaptacije reference *SoC* baterije, uz pretpostavku potpuno nove baterije. Dodatni rezultati simulacije za različita opterećenja vlaka (broj potpuno natovarenih teretnih vagona) i za optimalne parametre regulatora iz tablice 5 navedeni su u tablici 8.

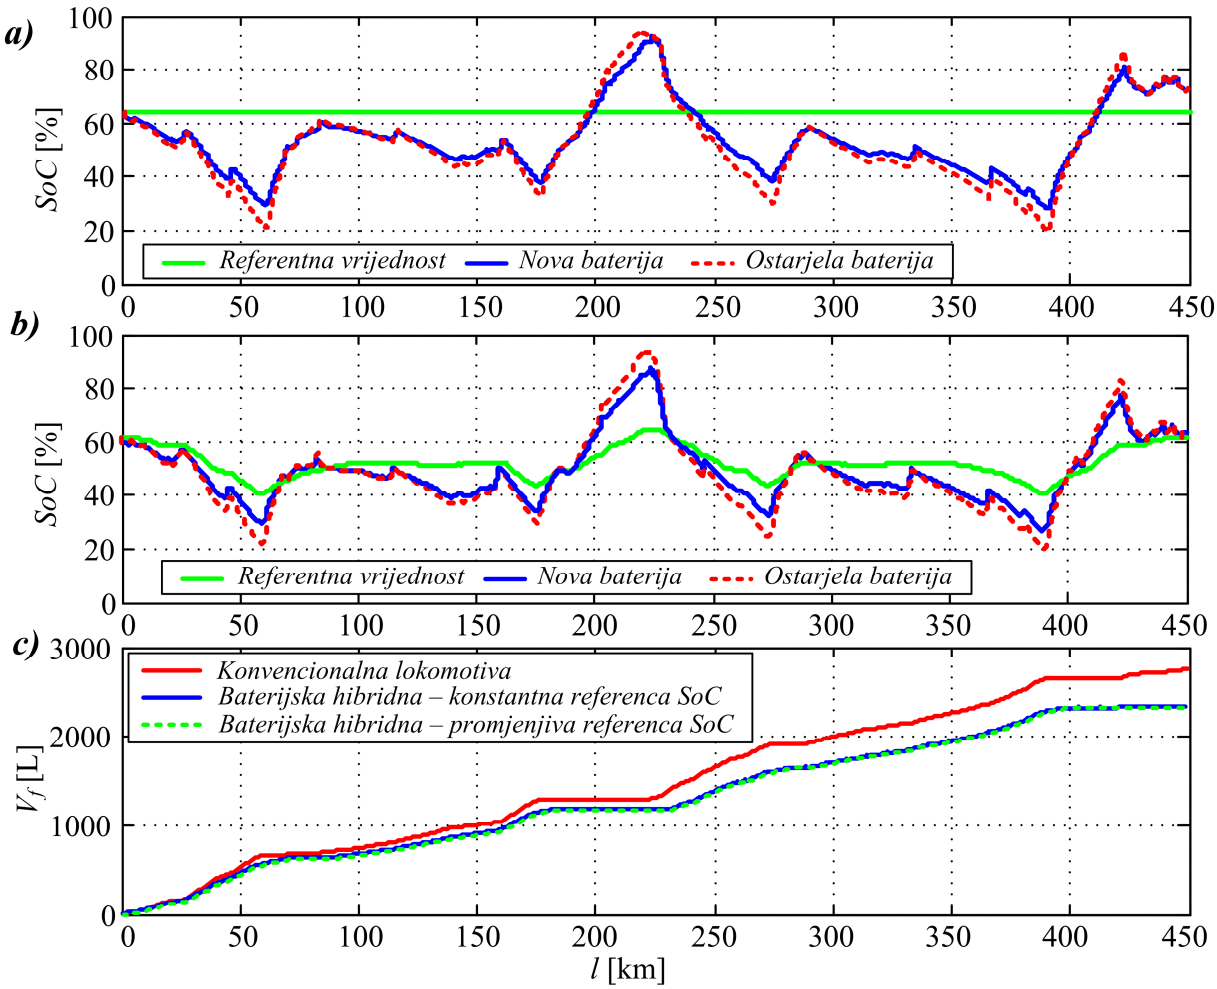

Slika 63. SoC varijabla baterije za slučaj konstantne SoC reference (a) i korištenje adaptivne SoC reference (b), te usporedna kumulativna potrošnja goriva baterijsko-hibridne i konvencionalne lokomotive (c).

*Tablica 14. Rezultati simulacije za različita opterećenja i različite parametre SoC regulatora**

Broj vagona	Konven-cionalna V_f (L)	Hibridna (SoC_{RC})				Hibridna (SoC_{RV})			
		V_f (L)		SoC_{MIN} (%)		V_f (L)		SoC_{MIN} (%)	
		Nova	*Stara*	*Nova*	*Stara*	*Nova*	*Stara*	*Nova*	*Stara*
0	411	(433) 434	(435) 435	(54.60) 55.87	(53.78) 55.81	(385) 406	(394) 413	(41.20) 43.46	(40.31) 42.69
1	718	(651) 640	(655) 644	(56.35) 56.64	(55.93) 56.36	(583) 597	(599) 605	(40.82) 42.84	(40.31) 42.47
2	1082	(942) 934	(946) 942	(54.33) 54.26	(52.86) 52.82	(882) 889	(903) 901	(40.49) 42.87	(40.04) 42.60
3	1447	(1210) 1205	(1214) 1218	(46.69) 49.76	(44.58) 47.75	(1168) 1166	(1194) 1185	(38.09) 40.02	(36.55) 39.82
4	1793	(1483) 1481	(1497) 1506	(42.51) 45.15	(38.65) 41.70	(1453) 1444	(1484) 1472	(35.82) 39.43	(33.23) 37.30
5	2124	(1763) 1762	(1788) 1791	(37.29) 39.94	(32.23) 35.03	(1738) 1733	(1770) 1766	(31.67) 37.38	(26.65) 34.55
6	2442	(2033) 2032	(2057) 2069	(32.47) 34.82	(26.59) 28.30	(2004) 2013	(2041) 2045	(26.57) 32.85	(20.07) 27.54
7	2750	(2307) **2314**	(2331) **2357**	(24.86) **28.22**	(12.92) **20.00**	(2279) **2297**	(2321) **2337**	(20.00) **27.03**	(12.54) **20.00**

* Vrijednosti u zagradama odnose se na parameter SoC regulatora optimirane za puno opterećenje vlaka i novu bateriju

Rezultati u tablici 14 potvrđuju da je regulator stanja napunjenosti (*SoC*) baterije koji koristi parametre optimirane za širok raspon scenarija, uključujući različita opterećenja i različito stanje ispravnosti baterije, u stanju održati *SoC* iznad 20% za sve scenarije, čime se izbjegava preduboko pražnjenje baterije i njeno ubrzano starenje.

Rezultati dobiveni za slučaj optimiranja regulatora *SoC* baterije koji se temelje na specifičnom scenariju potpuno napunjenog vlaka i potpuno nove baterije pokazuju da bi bilo moguće dodatno smanjiti potrošnju goriva u odnosu na prethodno praktički optimalno rješenje dobiveno na temelju širokog raspona scenarija. Međutim, u tom slučaju regulator stanja napunjenosti možda neće moći održavati *SoC* baterije iznad donje granice od 20% u slučaju kada se stanje ispravnosti baterije pogorša uslijed starenja (ostarjela baterija). Rezultati također pokazuju da za slučaj bez tereta (nema priključenih vagona lokomotivi) i slučaj konstantne reference SoC hibridna lokomotiva može imati nešto veću potrošnju goriva u usporedbi s konvencionalnom, što je posljedica približno optimalnog, ali robusnog podešavanja regulatora stanja napunjenosti za koji je prije pokazano je pogodan za sve razmatrane konfiguracije vlakova. Kao što je prije spomenuto, za postizanje boljih rezultata bilo bi potrebno uvesti

dodatnu adaptaciju (prepodešenje) parametara regulatora stanja napunjenosti ovisno o konfiguraciji teretnog vlaka, što nije praktično za realne aplikacije.

Tablica 15. Usporedni podaci o potrošnji goriva u simulaciji kružne vozne misije

Lokomotiva	Potrošnja goriva (L)		Trošak goriva (EUR)	
	Nova	*Stara*	*Nova*	*Stara*
Konvencionalna	2750	2750	3712.50	3712.50
Hibridna (SoC_{RC})	2314	2357	3123.90	3182.95
Hibridna (SoC_{RV})	2297	2337	3100.95	3154.95

Podaci o konačnoj potrošnji goriva koji se koriste u daljnjoj analizi navedeni su u tablici 15, koja ilustrira glavne prednosti baterijsko-hibridne lokomotive u slučaju potpuno opterećenog vlaka u smislu smanjenja potrošnje goriva. Konkretno, smanjenje potrošnje goriva iznosi približno 15% bez obzira koristi li se konstanta ili adaptivna referenca stanja napunjenosti baterije. Tablica 15 također navodi ukupne troškove dizelskog goriva na temelju trenutne maloprodajne cijene goriva za gorivo = 1.35 EUR/L u Hrvatskoj [136].

3.3. Simulacija vozne misije pogonjene baterijskom lokomotivom

Ovaj odjeljak prikazuje rezultate simulacije različitih konfiguracija vlakova koji sadrže baterijsku lokomotivu za slučajeve samostalnog rada pojedinačne baterijske lokomotive, kao i tandemskog rada dviju lokomotiva gdje se razmatra primjena dviju baterijskih lokomotiva ili različiti tandemi koji kombiniraju baterijske i konvencionalne dizel-električne lokomotive za razmatranu brdsko-planinsku rutu i različita opterećenja (terete kompozicije).

3.3.1. Domet baterijske lokomotive

Slika 64. prikazuje rezultate simulacije za konstantnu referentnu vrijednost brzine vlaka od 100 km/h, 7 potpuno opterećenih teretnih vagona (po 90 tona svaki) i parametre konstantnog otpora gibanju na ravnim (nizinskim) kolosijecima. Na slici 64, plave krivulje odgovaraju baterijsko-električnoj lokomotivi bez uključenog reduciranja "Notch" komande, dok crvene krivulje odgovaraju baterijsko-električnoj lokomotivi koja koristi funkciju reduciranja "Notch" komande. Kao što se očekivalo, upotrebom redukcije "Notch" upravljačke komande povećava se domet vlaka zbog smanjene ukupne potrebe za energijom pogonskog sustava kada SoC

baterije padne ispod 50% (slika 54c). Konkretno, smanjenjem ukupne vučne snage smanjuje se i brzina vlaka, čime se zauzvrat smanjuje ukupni otpor kretanja (kako je dano modelom aerodinamičkog otpora u potpoglavlju 2.4).

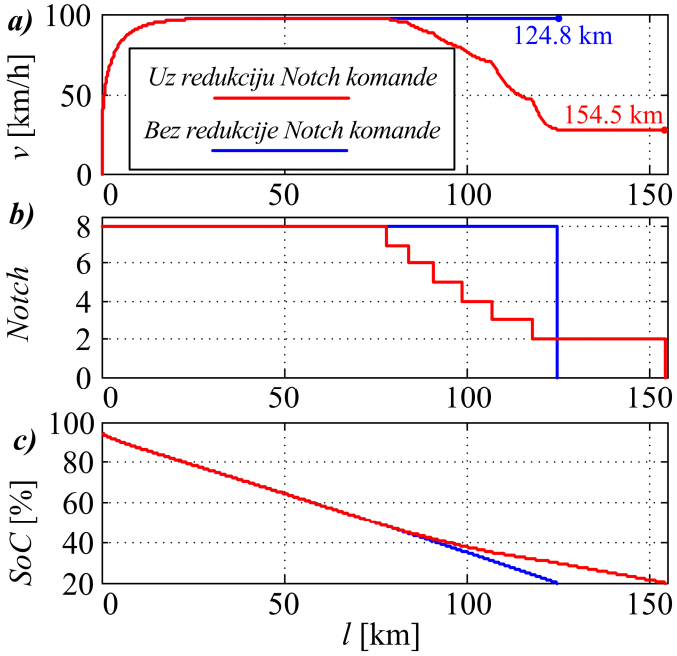

Slika 64. Domet pogona baterijsko-električne lokomotive sa 7 potpuno opterećenih vagona bez i sa redukcije Notch komande akceleratora: profili brzine (a), „Notch" komanda (b) i SoC baterije (c).

Na slici 65. prikazan je potpuno električni domet baterijsko-električne lokomotive za različita opterećenja, nagibe kolosijeka i brzine. Na slici 65a prikazani su rezultati dometa baterijsko-električne lokomotive za slučaj konstantne brzine vlaka od 100 km/h, gdje je vidljivo da se domet smanjuje s povećanjem tereta (broja vagona N_w) i povećanjem nagiba. Na slici 65b prikazan je domet ovisan o brzini vlaka i opterećenju vlaka, pri čemu se (očekivano) najveći domet dobiva za mala opterećenja i srednje brzine vlaka, s time da domet lokomotive doseže svoj vrhunac pri brzini od 60 km/h. Konkretno, pri nižim brzinama vlaka domet lokomotive smanjuje se zbog smanjene učinkovitosti električnih vučnih motora pri malim opterećenjima (vidi učinkovitosti pretvorbe snage dane u tablici 7 u potpoglavlju 2.5), dok je pri velikim opterećenjima izražen učinak povećanog aerodinamičkog otpora gibanju (zbog kvadratične ovisnosti aerodinamičkog otpora s brzinom vlaka), a zbog kojeg se posljedično smanjuje domet vlaka uslijed povećane potrebe za energijom (snagom).

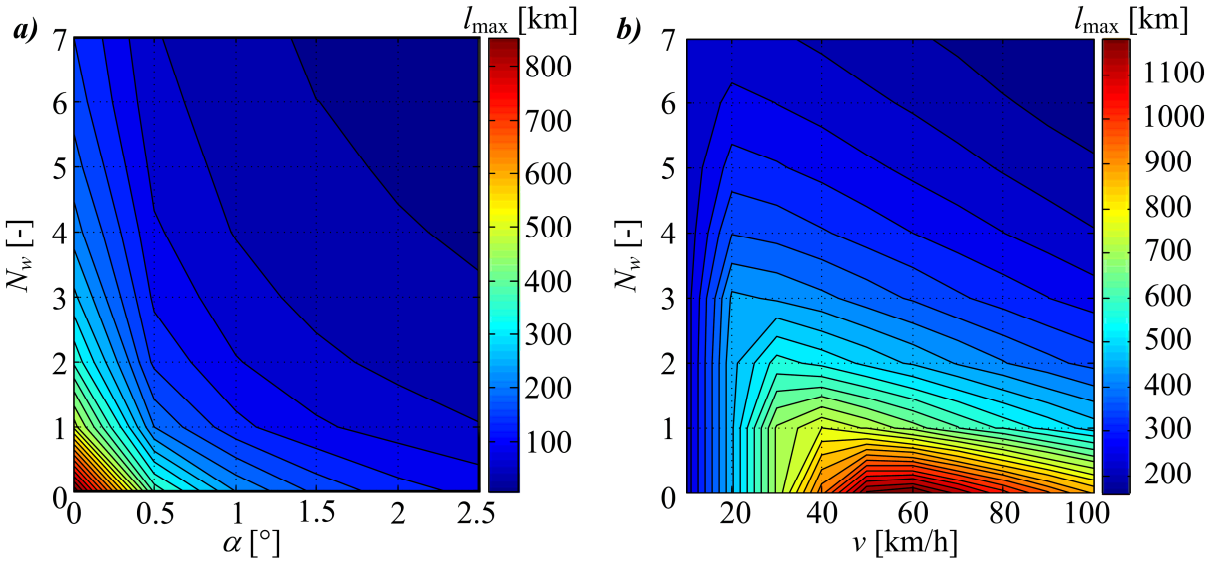

Slika 65. Domet vlaka s baterijsko-električnom lokomotivom za različito opterećenje (broj potpuno opterećenih vagona) i različite nagibe trase (a), te za različite brzine vožnje (b).

3.3.2. Baterijska lokomotiva u tandemu s konvencionalnom

Svojstva segmenta željezničke rute od grada Oštarija do grada Knina i natrag (kružna vožnja), s teretnim vlakom koji prolazi brdsko-planinskom rutom kroz Liku, prikazana su na slici 23 u potpoglavlju 2.2 kroz profil nadmorske visine h i ograničenja brzine vlaka vlimit kako je definirano ranije. Nadalje, kao što je već prije spomenuto u prethodnim odjeljcima koji analiziraju scenarije konvencionalne i baterijsko-hibridne dizel-električne vuče, razmatrani scenarij vožnje prikazan na slici 22 (poglavlje 2.2) odgovara povratnom putovanju između gradova Oštarija i Knina. Pritom se kao nominalni slučaj razmatra scenarij sedam potpuno ukrcanih teretnih vagona od 90 t što odgovara maksimalnom opterećenju teretnog vlaka s jednom dizel-električnom lokomotivom koji vozi preko razmatrane brdsko-planinske željezničke rute. Simulacije se izvode u programskom okruženju Matlab/Simulink. Simulacija je provedena za tri različite konfiguracije lokomotive: konvencionalna lokomotiva (označena s D) i dvije tandemske konfiguracije koje odgovaraju dodatnoj baterijsko-električnoj lokomotivi (označene kao DB1 i DB2, ovisno o režimu punjenja baterije). Obje tandemske simulacije započinju s potpuno napunjenom baterijom unutar baterijsko-električne lokomotive, pri čemu se baterija ili puni samo na kraju simulacije (scenarij DB1), ili na polovici puta i na kraju simulacije (DB2 scenarij), pri čemu punjenje baterije na kraju misije označava pripremu za još

jednu voznu misiju. Tijekom analize troškova također se uzima u obzir i električna energija potrebna za punjenje baterije.

Slika 66a prikazuje brzinu vlaka s obzirom na prijeđeni put i s obzirom na vrijeme za referentnu brzinu v_{ref} i tri brzine vlaka v_D, v_{DB1} i v_{DB2} koje odgovaraju prethodno spomenutim scenarijima vožnje (konvencionalna lokomotiva i tandemi sa baterijskom lokomotivom s jednim, odnosno dva punjenja po voznoj misiji). Referentna brzina vlaka v_{ref} (crvena krivulja na slici 66a) generira se kao postupna promjena brzine unutar intervala željezničke pruge od 2 km pomoću prethodno poznatog profila ograničenja brzine vlaka, kako je dano u potpoglavlju 3.1. Korištenjem ovakvog načina generiranje reference brzine sprječavaju se prekomjerna ubrzanja i usporavanja, pa se stoga može lakše implementirati sveobuhvatna upotreba električnog regenerativnog kočenja (nema potrebe za naglim kočenjem što bi zahtijevalo i uporabu mehaničkih kočnica). Za zadanu ciljnu (referentnu) brzinu v_{ref} stvarna brzina vlaka v_D za slučaj dizel-električne lokomotive (referentni scenarij) dobiva se simulacijom i predstavljena je crnom krivuljom na slici 66a, dok plave i zelene krivulje predstavljaju stvarnu brzinu vlaka v_{DB1} i v_{DB2} za slučaj prethodno spomenutih scenarija tandemskih konfiguracija vučnih lokomotiva sa odgovarajućim scenarijima punjenja baterijske lokomotive. Grafikoni brzina vlakova na slici 66a pokazuju da stvarna brzina vlaka ne može pratiti referencu brzine za vrijeme uspinjanja, i to zbog nedovoljne vučne sposobnosti vlaka zbog ograničenja snage vučnog sustava. Konkretno, ovo se očituje u poprilično velikom odstupanju od referentne brzine, iako je vlak još uvijek sposoban penjati se uzlaznom trasom pri nižim brzinama. Krivulje na slici 66a, točnije, odstupanja stvarnih brzina različitih konfiguracija lokomotiva u odnosu na referentnu (ciljnu) brzinu, pokazuju poboljšano praćenje profila referentne brzine za tandemsku konfiguraciju zbog poboljšanih vučnih mogućnosti i dodatne vučne snage tandemskog sustava lokomotiva. Nadalje, tandemski scenarij DB2, koji također uključuje dodatno punjenje baterijske lokomotive, poboljšava vozne performanse u drugom dijelu putovanja jer je u tom slučaju dostupno dodatno napajanje (nakon dopunjavanja baterije).

Unutar tandema, raspoloživa vučna snaga uključuje snagu konvencionalne dizel-električne lokomotive i baterijsko-električne lokomotive. U slučaju ubrzavanja i uspinjanja vlaka, dodatnu vučnu snagu daje baterijska električna lokomotiva. Stoga se ugrađena baterija prazni tijekom putovanja, odnosno njezin se SoC počinje smanjivati (slika 66c). U slučaju regenerativnog kočenja tijekom usporavanja ili vožnje nizbrdo, baterija se puni i zauzvrat joj se povećava SoC. Slika 66b prikazuje odzive potrošnje goriva za sve razmatrane scenarije, dok

slika 66c prikazuje odzive SoC baterije za razmatrane DB1 i DB2 scenarije. Podaci o potrošnji goriva na slici 66b pokazuju da scenarije DB1 i DB2 karakterizira primjetan pad potrošnje goriva u odnosu na referentni slučaj dizel-električne lokomotive (scenarij D). Konačne vrijednosti (V_{fD} = 2751 L, V_{fBD1} = 2233 L i V_{fBD2} = 1900 L) ilustriraju glavne prednosti baterijsko-električne lokomotive koja se koristi zajedno s konvencionalnom za slučaj potpuno opterećenog vlaka u smislu smanjenja potrošnje goriva. Prema slici 66c, i za DB1 i za DB2 scenarij, SoC baterije održava se iznad minimalne vrijednosti (SoC_{min} = 20%). Stoga se učinkovito izbjegava duboko pražnjenje baterije, što bi trebalo biti korisno sa stajališta vijeka trajanja (broja ciklusa punjenja i pražnjenja) baterije i njenog kalendarskog životnog vijeka. Tijekom punjenja baterije, u modelu se sprječava prekomjerno punjenje onemogućavanjem postupka punjenja kada SoC baterije dosegne 95%, a višak električne energije dobiven tijekom elektro-dinamičkog kočenja tada se preusmjerava prema mreži disipacijskih otpornika i raznim pomoćnim uređajima, kako je spomenuto ranije u referencama [137] i [76].

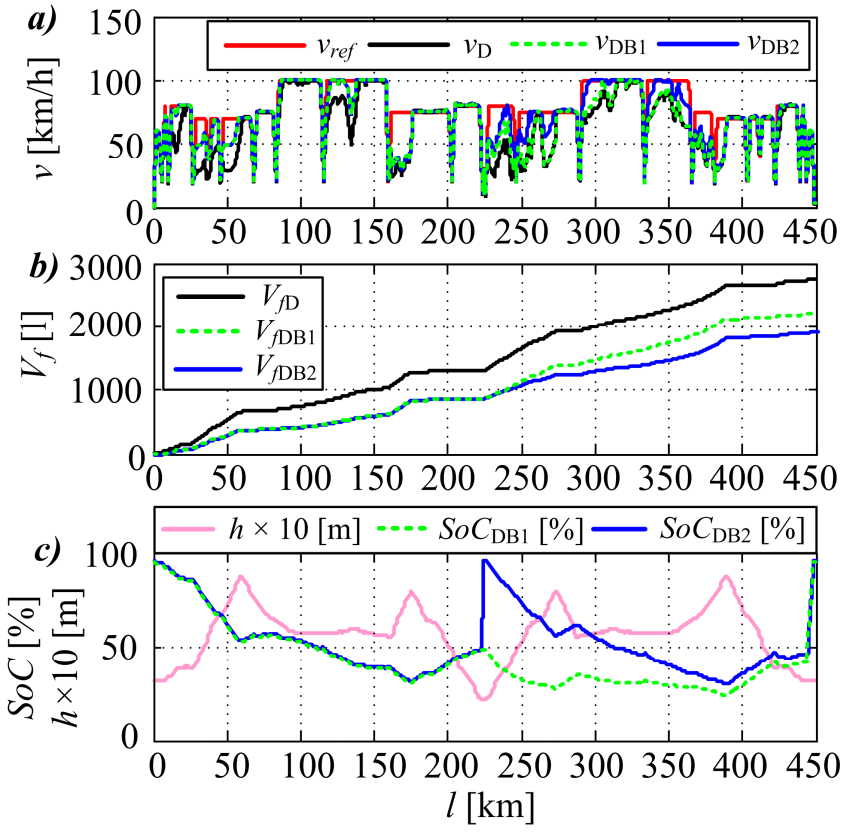

Slika 66. Usporedba konvencionalne kompozicije i tandemskog rada s baterijsko-električnom lokomotivom: (a) profili brzine (b) kumulativna potrošnja goriva i (c) SoC baterije i nadmorska visina rute.

Slika 67a prikazuje potrebno vrijeme putovanja za različita opterećenja i konfiguraciju lokomotiva. Minimalno vrijeme putovanja za sve konfiguracije je 6,7 h i određeno je ograničenjima brzine rute. Krajevi pojedinačnih krivulja na slici 67 predstavljaju maksimalne mogućnosti opterećenja dobivene simulacijama. Jedna baterijsko-električna lokomotiva sa samo jednim punjenjem (slučaj B1 na slici 67) sposobna je vući samo jedan teretni vagon s trajanjem putovanja nešto duljim od teoretskog minimuma, jer se zbog pražnjenja baterije ispod 50% SoC aktivira redukcija "Notch" komande (tj. kada SoC baterije padne ispod 50%). Uz dodatno punjenje baterije (slučaj B2) ista lokomotiva može vući do tri vagona (teret od 270 t). Međutim, treba imati na umu da se mogu vući samo dva vagona (nosivost 180 t) ako se traži slično vrijeme putovanja kao u referentnom slučaju D koji odgovara jednoj dizel-električnoj lokomotivi (vidi sliku 67a). Odzivi koji odgovaraju tandemu dizel-električne i baterijsko-električne lokomotive (DB1 i DB2) pokazuju značajno smanjenje vremena putovanja, te također ukazuju na mogućnost vuče većih tereta. Razlika u karakteristikama vuče između slučajeva DB1 i DB2 može se objasniti dostupnom energijom baterije koja je dva puta veća u slučaju DB2 scenarija (punjenje na polovici putovanja), zbog čega se rjeđe uključuje funkcija redukcije "Notch" komande. Ostala tri scenarija, namijenjena za vuču većih tereta (DD, DDB1 i DDB2), imaju slična svojstva kod tereta koji premašuju sposobnost vuče pojedine dizel-električne lokomotive (sa ili bez pomoćne baterijsko-električne lokomotive).

Slike 67b i 67c prikazuju potrošnju goriva dizel-električne lokomotive i kumulativnu električnu energiju koja se koristi za punjenje baterija. Općenito, potrošnja goriva raste linearno s opterećenjem vlaka. Kao što se očekivalo, slučaj DD ima najveću potrošnju goriva (slika 67b) zbog dvije dizel-električne lokomotive koje rade u tandemu. Dodavanjem baterijsko-električne lokomotive u tandem koji se sastoji od dvije konvencionalne dizel-električne lokomotive, potrošnja goriva može se smanjiti do te mjere da ova konfiguracija postaje štedljivija od pojedinačne dizel-električne lokomotive (slučaj D), što je vidljivo iz usporedbe odziva scenarija DDB2 i D na slici 67b. Najniža potrošnja goriva dobiva se za DB2 scenarij. S druge strane, zahtjevi za električnom energijom prikazani na slici 67c ponašaju se linearno samo za slučajeve B1 i B2 i tandemske konfiguracije pri malim opterećenjima koja uključuju baterijsko-električnu lokomotivu. Ovo se može objasniti činjenicom da pri malim opterećenjima vučnu snagu pretežno pokriva baterijska lokomotiva. U slučajevima koje karakteriziraju veća opterećenja, baterija se brzo prazni i uključuje se redukcija "Notch" komande, te stoga krivulje potrošnje električne energije postaju ravne (zasićene), odnosno doprinos električne energije u vuči postaje zanemariv kako se opterećenje vlaka dodatno povećava. Konfiguracija B2 i tandemi koji

uključuju scenarij slučaja B2 imaju gotovo dvostruko veću potrošnju električne energije u usporedbi s ostalim slučajevima, jer odgovaraju punjenju baterije dva puta tijekom putovanja (na pola puta puta i na kraju putovanja, odnosno početku novog putovanja).

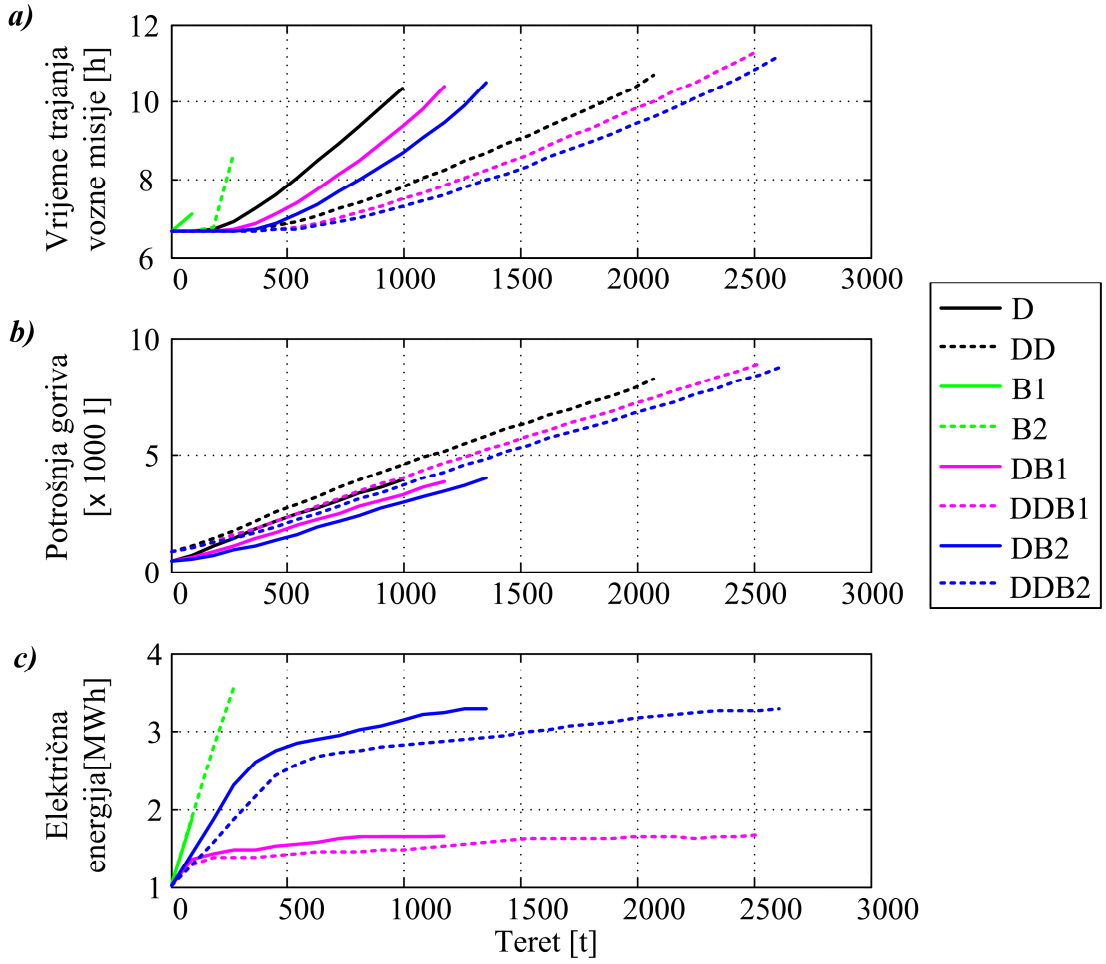

Slika 67. Rezultati za različite konfiguracije lokomotiva: (a) vrijeme putovanja, (b) potrošnja goriva i (c) potrošena električna energija.

3.4. Simulacija vozne misije pogonjene hibridnom lokomotivom uz varijaciju vremenskih uvjeta

U ovom potpoglavlju se analizira učinak promjenjivih vremenskih uvjeta na stanje željezničke trase u smislu promjenjive adhezije kako je objašnjeno u uvodnim razmatranjima (vidi sliku 11 u potpoglavlju vremenski uvjeti, adhezija i otpori gibanja željezničkoga vozila).

Cjelokupni model implementiran je u programskom okruženju Matlab/Simulink i njegova opisna struktura dana je blokovskim dijagramom na slici 68. Na temelju dobivenih simulacijskih rezultata, tj. podataka mogu se prepoznati korekcijske preporuke korisne za planiranje voznih misija, odnosno za povećanje stabilnosti voznih redova vlakova na promatranim trasama prometovanja.

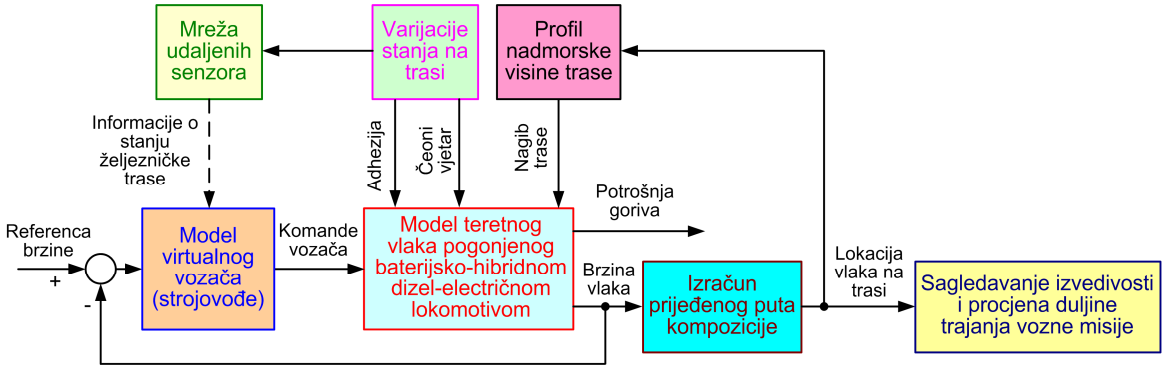

Slika 68. Blokovski dijagram toka predložene metodologije za povećanje energetske učinkovitosti i sigurnosti željezničkog transporta.

3.4.1. Simulacijski model vlaka uz varijabilne vremenske uvjete na trasi

Na slici 69 prikazan je cjelokupni kvazistacionarni model baterijsko-hibridne dizel-električne lokomotive s tokom informacija, koji se u odnosu na model prikazan u potpoglavlju 2.5 (slika 32) razlikuje u tome što uključuje i model varijabilne adhezije i brzine čeonog vjetra prema profilima koji su zadani na slici 23 u potpoglavlju 2.2. Na temelju navedenog podmodela teretnog vlaka, implementiranog u sklopu šireg modela, te modela distribuiranih senzora uskopojasne komunikacije, danih u poglavljima 2.6 i 2.7, provode se simulacijske analize u idućem potpoglavlju u okviru programskog paketa Matlab/Simulink.

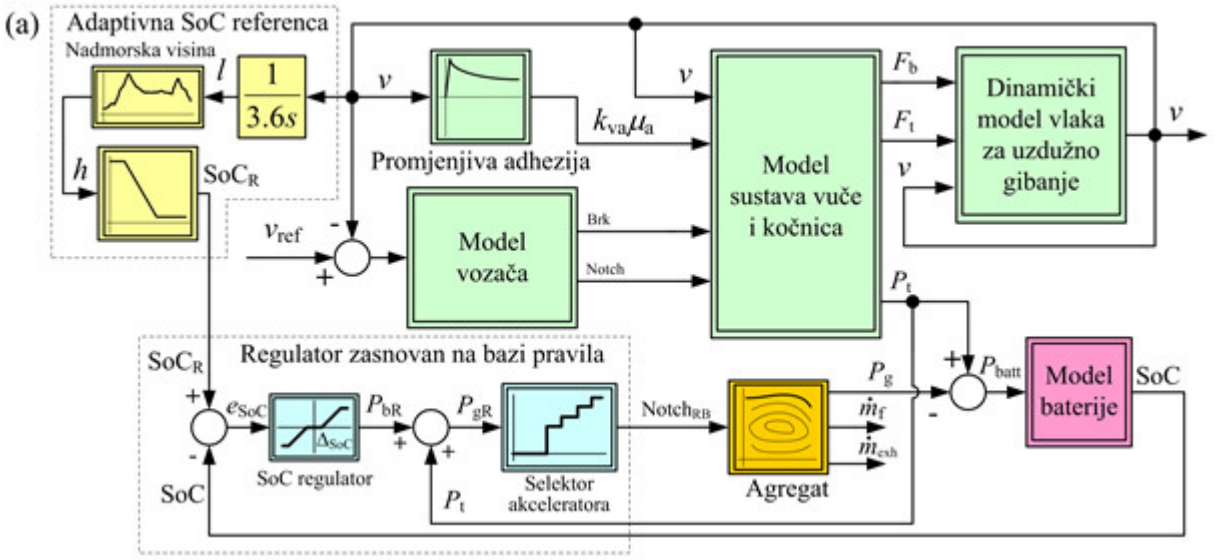

Slika 69. Blokovski dijagram modela baterijsko-hibridne i dizel-električne lokomotive (a) i pod-modela sustava električne vuče (b) te toka informacija (c)

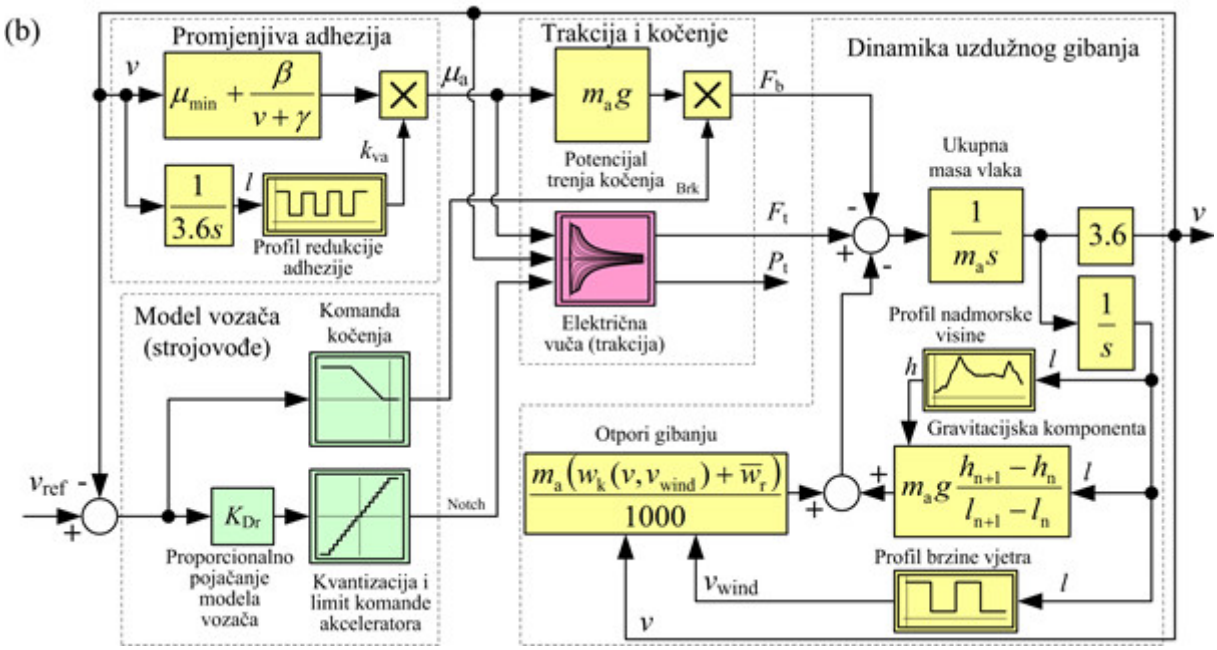

Slika 69. Blokovski dijagram modela baterijsko-hibridne i dizel-električne lokomotive (a) i pod-modela sustava električne vuče (b) te toka informacija (c)

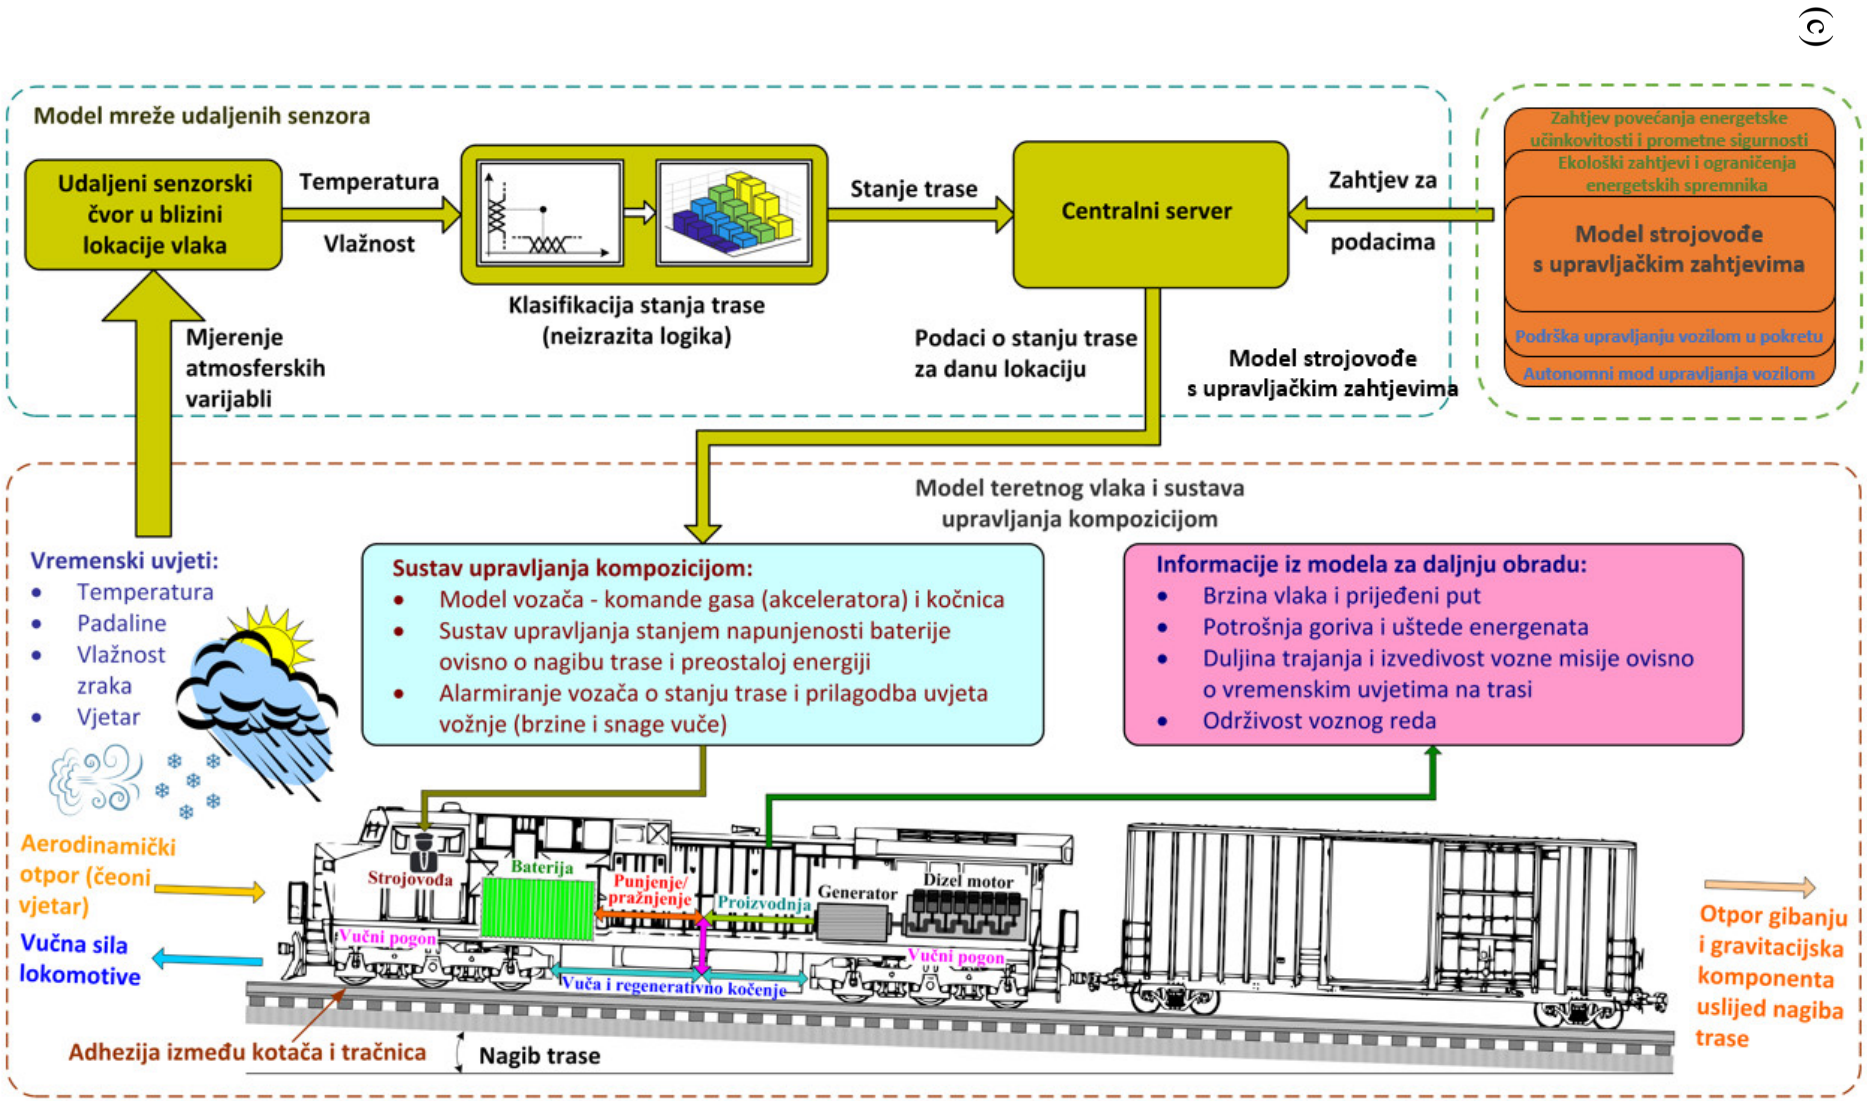

Slika 69. Blokovski dijagram modela baterijsko-hibridne i dizel-električne lokomotive (a) i pod-modela sustava električne vuče (b) te toka informacija (c)

3.4.2. Simulacijski rezultati

Simulacije vozne misije vlaka provedene su za kružno putovanje brdsko-planinskom rutom karakteriziranom profilom nadmorske visine prikazanim na slici 23 u poglavlju 2.2, pri čemu lokomotiva vuče 630 t teretnih vagona (što približno odgovara maksimalnom opterećenju jedne konvencionalne dizel-električne teretne lokomotive na navedenoj ruti, kako je naznačeno u prethodnim poglavljima.

Slika 70. prikazuje komande položaja poluge akceleratora 'Notch' i komande kočenja 'Brk' pri čemu plava krivulja označena sa (Co) predstavlja scenarij u kojem se koriste nominalne (referentne) vrijednosti brzine čeonog vjetra i adhezije (v_{wind} = 12 km/h, k_{va} = 100%, vidi simulacijski scenarij proveden u poglavlju 3.2), dok crvena krivulja s oznakom (Vo) odgovara scenariju sa varijabilnim vrijednostima prethodno navedenim. Rezultati na slici 70. također pokazuju da na toj voznoj misiji električno (regenerativno) kočenje nije uvijek dovoljno da održava brzinu vlaka na nizbrdici, što zahtijeva upotrebu dodatnih mehaničkih kočnica (usporediti odzive na slici 70 i profile ključnih varijabli trase prikazane na slici 23 u potpoglavlju 2.2).

Slika 71. prikazuje odgovarajući profil brzine vlaka u funkciji prijeđene udaljenosti i vremena s obzirom na rezultate prikazane na slici 70. Koristeći prethodno poznata ograničenja brzine vlaka (slika 23 u poglavlju 2.2.), ciljna brzina vlaka v_{ref} (crna krivulja na slici 71a) oponaša ponašanje virtualnog strojovođe koji bi postupno povećavao i smanjivao brzinu vlaka s jedne na drugu vrijednost ograničenja brzine. Takvo generiranje referentne brzine vlaka ovdje se izvodi kroz „prozor“ (interval) širine 2 km, kako je naznačeno u poglavlju 3.1. Za zadanu referencu brzine v_{ref} i konstantne vrijednosti čeonog vjetra v^{wind} i potencijala adhezije k_{va}, stvarna brzina vlaka (v_{Co}) za nominalni (referentni) slučaj dobiva se u simulaciji i predstavljena je plavom krivuljom na slici 71, dok crvena krivulja predstavlja brzinu vlaka (v_{Vo}) kada se koriste varijabilne vrijednosti adhezije i čeonog vjetra sa slike 23, poglavlje 2.2. Razlika u brzinama gore spomenutih scenarija vožnje nije naglašena, kao što pokazuju profili brzine u odnosu na prijeđenu udaljenost na slici 71a. Međutim, kada se ovi odzivi brzine iscrtaju u odnosu na proteklo vrijeme vozne misije (slika 71b), razmatrani scenariji simulacije karakteriziraju različita trajanja voznih misija. Navedeni rezultat ukazuje na to da predloženi simulacijski model također može biti koristan za predviđanje mogućih korekcija brzina i načina vožnje, a time i na stabilnost voznih redova između postaja za prethodno poznate uvjete adhezije i čeonog vjetra. Kao što se očekivalo, adhezija ispod nominalnog iznosa i porast brzine

čeonog vjetra pogoršavaju performanse sustava vuče lokomotive i rezultiraju nižim brzinama vlaka, naročito tijekom uzlaznih faza putovanja, što rezultira nižom brzinom vlaka i sporijim izvršavanjem vozne misije (slika 71b). Također treba imati na umu da bi se u slučaju značajnog nagiba kolosijeka, profil brzine teretnog vlaka dodatno pogoršao, posebice kada su prisutni nepovoljni uvjeti na trasi. Naime, u tim slučajevima električni vučni sustav ne može pružiti dovoljno vučnog djelovanja kako bi se brzina vlaka održala blizu ciljne vrijednosti, što se očituje u nižim brzinama vlaka u odnosu na ograničenje brzine za pojedini segment kolosijeka. Dakle, učinak nagiba trase također pridonosi produljenom trajanju vozne misije i njezinu uspješnom završetku.

Slika 72. prikazuje potrošnju goriva lokomotive i SoC akumulatora za tri različita scenarija kada se koristi baterijsko-hibridna lokomotiva:

- Konstantna brzina čeonog vjetra i adhezijskog koeficijenta k_{va} (nominalni, odnosno referentni slučaj) koriste se u simulaciji, a parametri regulatora stanja napunjenosti baterije optimirani su upravo za te konstantne parametre (tzv. CoC scenarij), što se izravno odnosi na glavni rezultat optimizacije predstavljen u potpoglavlju 2.5.
- Simulacija se provodi za slučaj varijabilne brzine čeonog vjetra i varijabilnog koeficijenta adhezije k_{va}, dok su parametri strategije upravljanja izvedeni za slučaj referentnih (nominalnih) uvjeta na trasi (tzv. VoC scenarij);
- Simulacija se provodi za slučaj varijabilne brzine čeonog vjetra i varijabilnog koeficijenta adhezije k_{va}, a parametri strategije upravljanja optimirani su za upravo navedene varijabilne parametre na trasi (tzv. VoV scenarij).

Slika 72a prikazuje odzive potrošnje goriva, dok slika 72b prikazuje odzive stanja napunjenosti (SoC) baterije za prethodno navedene scenarije (CoC, VoC i VoV). Zanimljivo je da je referentni scenarij CoC, analiziran detaljnije u potpoglavlju 3.2, karakteriziran najmanjom kumulativnom potrošnjom goriva, te također istodobno održava SoC baterije iznad preporučene donje granične vrijednosti (SoC_{MIN} = 20%). Uočena 'optimalnost' potrošnje goriva u ovom nominalnom (referentnom) simulacijskom scenariju prvenstveno se odnosi na odsutnost varijabilnosti adhezije što omogućuje pogonskom sustavu lokomotive da u potpunosti iskoristi potencijal regenerativnog kočenja za punjenje baterije. U slučaju VoC scenarija, baterija biva dublje ispražnjena (SoC pada ispod 20%) u usporedbi sa scenarijima CoC i VoV. Naime, u slučajevima CoC i VoV scenarija, optimirani parametri SoC regulatora izvedeni su uz donju graničnu vrijednost SoC baterije iznosa 20%. Na taj način, korištenjem podataka iz mreže

udaljenih senzora o stanju željezničke trase (poglavlje 2.6.2.) i pravilno optimiranim parametrima strategije upravljanja, učinkovito se izbjegava duboko pražnjenje baterije. Ovo bi posljednje rezultiralo manje naglašenim starenjem komponenata baterijskog sustava za pohranu energije (prvenstveno baterijskih ćelija), te također i produljenjem vijeka trajanja baterije (kronološkog vijeka trajanja i broja ciklusa punjenja i pražnjenja) u odnosu na slučaj kada se takve mjere ne bi mogle primijeniti. U svim gore spomenutim slučajevima, profili stanja napunjenosti baterije uvelike podsjećaju na stvarne profile visine željezničke pruge (slika 23 u poglavlju 2.2.). Konkretno, pozitivni (rastući) trendovi stanja napunjenosti povezani su sa silaznim nagibima kolosijeka koje karakterizira opsežna upotreba regenerativnog kočenja putem sustava električne vuče (punjenje baterije), dok su negativni (padajući) trendovi stanja napunjenosti povezani s uzlaznim nagibima kolosijeka koji zahtijevaju dodatno korištenje dodatne snage iz baterije (pražnjenje baterije) radi poboljšanja vučnih performansi.

Podaci o potrošnji goriva na slici 72a pokazuju da scenarije VoC i VoV karakterizira primjetan porast potrošnje goriva u odnosu na slučaj CoC. Konačne vrijednosti (Vf_{CoC} = 2320 L, Vf_{VoC} = 2552 L, Vf_{VoV} = 2556 L) potvrđuju da varijabilnost uvjeta na trasi (tj. promjenjivi koeficijent adhezije, odnosno koeficijent vuče) može dovesti i do 10% veće potrošnje goriva, što je dodatno pogoršano povećanim otporom gibanju zbog dodatnog čeonog vjetra u kombinaciji s manje raspoložive snage regenerativnog kočenja kada se smanji adhezija. VoV scenarij pokazuje da lokomotiva troši zanemarivo više goriva (samo 4 L više) u odnosu na slučaj VoC. Iako su parametri strategije upravljanja za slučaj VoV optimirani imajući u vidu promijenjene uvjeta kolosijeka, ovaj neznatno različiti rezultat posljedica je zahtjeva za održavanjem SoC baterije unutar propisanih granica.

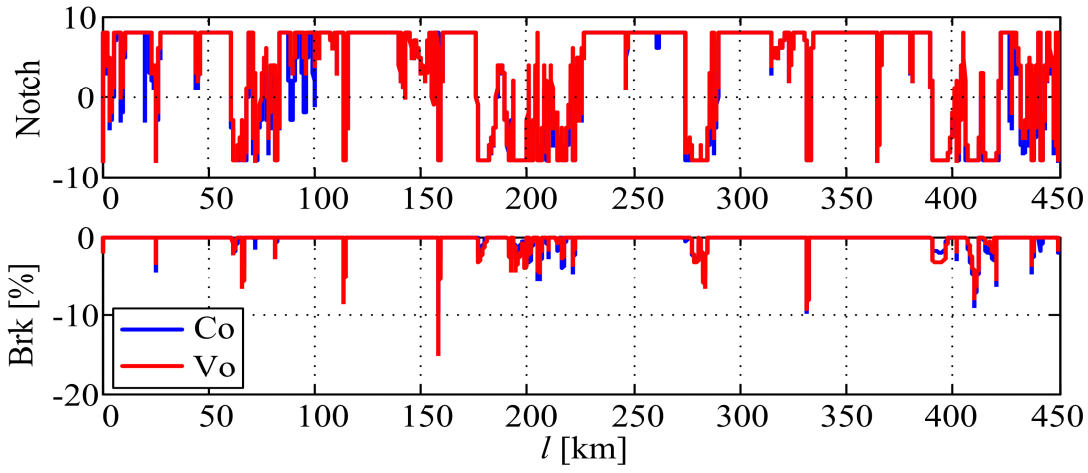

Slika 70. Komande koje zadaje model strojovođe

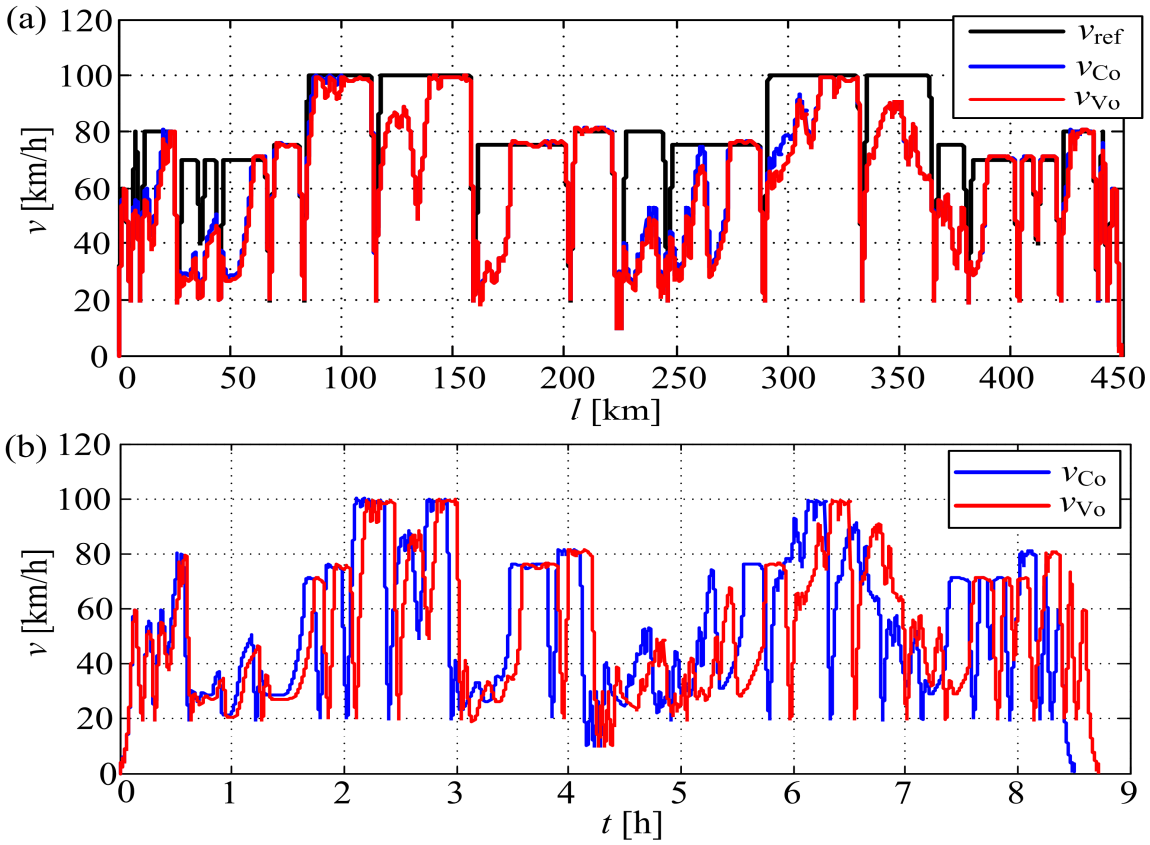

Slika 71. Brzina vlaka s obzirom na prijeđenu udaljenost (a) i s obzirom na vrijeme (b)

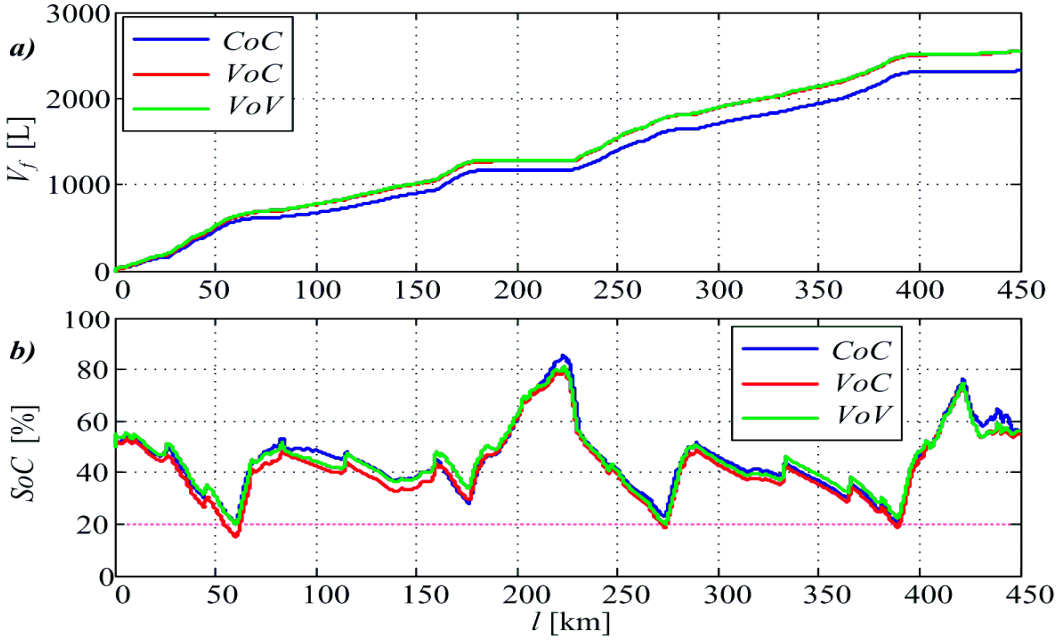

Slika 72. Usporedna kumulativna potrošnja goriva lokomotive (a) i prikaz SoC varijable (b) za različite nadređene strategije upravljanja lokomotivom.

4. TEHNOLOŠKO-EKONOMSKA ANALIZA I DISKUSIJA REZULTATA

4.1. Potencijalne uštede utrošenog goriva i redukcije emisija štetnih plinova

4.1.1. Potencijalna ušteda uz primjenu baterijsko-hibridne lokomotive

Prema referenci [138], litij-ionske (Li-Ion) baterije karakterizirane su životnim vijekom od približno 2000 ciklusa, pri čemu se izmjenjuju ciklusi punjenja do 100% njenog kapaciteta i pražnjenja do 80% dubine pražnjenja. Stoga je navedena vrijednost broja ciklusa odabrana u ovoj procjeni kao reprezentativni vijek trajanja baterijskog sustava za pohranu energije lokomotive prije nego što je potrebno izvršiti remont i njenu kompletnu zamjenu. Uz to, prethodno spomenuti ciklus punjenja i pražnjenja približno odgovara jednom povratnom putovanju preko planinske željezničke rute, upravo zato jer razmatrani scenarij sadrži sličan profil punjenja i pražnjenja baterije kada se gledaju vršne vrijednosti stanja napunjenosti (vidi odzive SoC baterije na slici 63. u potpoglavlju 3.2). Rezultirajuća kumulativna potrošnja goriva i troškovi goriva za konvencionalnu lokomotivu i baterijsko-hibridnu lokomotivu s promjenjivom referencom stanja napunjenosti baterije (SoC) navedeni su u tablici 16. Prema prikazanim rezultatima i uzimajući u obzir trenutnu maloprodajnu cijenu dizelskog goriva od 1.35 EUR/L [136], očekuje se da bi baterijsko-hibridna lokomotiva mogla smanjiti troškove goriva za oko 1.2 milijuna EUR (što odgovara 16,47% smanjenja potrošnje goriva) tijekom razmatranog razdoblja korištenja.

Gruba procjena troškova hibridizacije uključivala bi glavne troškove dizelskog agregata i troškove baterija, koji se mogu smatrati ukupnim troškovima ulaganja (tablica 17). U tom slučaju, ukupne uštede postignute korištenjem baterijsko-hibridne lokomotive procjenjuju se na oko 1.06 milijuna EUR (što odgovara 14,25% smanjenja troškova kroz uštede dizelskog goriva). Na temelju podataka navedenih u tablici 17, procijenjeno je da bi hibridna dizelsko-električna lokomotiva s ugrađenim baterijskim sustavom za pohranu energije rezultirala neto dobitkom koji iznosi tri puta više od predviđenih investicijskih troškova tijekom korisnog vijeka trajanja takvog hibridnog sustava vuče potpomognutog baterijskim sustavom za pohranu energije, s razdobljem povrata ulaganja od 1/4 predviđenog vijeka trajanja baterijskog sustava.

S obzirom na činjenicu da se očekivani troškovi ugradnje baterije i troškovi goriva mogu razlikovati u odnosu na stvarno stanje, te da se mogu mijenjati s vremenom, maksimalni prihvatljivi trošak baterije za hibridizaciju može se približno procijeniti kao:

$$c_{f,batt} = \frac{(V_{f,conv} - V_{f,hev}) \cdot N_{run} \cdot c_{fuel}}{E_{batt}} \tag{4-1}$$

gdje su $V_{f,conv}$ i $V_{f,hev}$ redom kumulativne potrošnje goriva u litrama za konvencionalnu lokomotivu i za baterijsko-hibridnu lokomotivu (vidi tablice 8 i 9 u potpoglavlju 3.2), N_{run} je očekivani broj eksploatacijskih pogonskih ciklusa (odabrano je 2000 ciklusa koji odgovaraju procijenjenom životnom vijeku baterije), c_{fuel} je cijena goriva u EUR/L, a E_{batt} je kapacitet pohrane energije u bateriji dan u kWh.

Prema jednadžbi (4-1), koristeći pritom podatke iz tablice 16 i uzimajući u obzir prethodno definiranu cijenu goriva, maksimalni prihvatljivi trošak nabave i ugradnje baterije iznosi 1359 EUR/kWh. Međutim, u tom se graničnom slučaju korist od hibridizacije očituje samo u potencijalu smanjenja emisija stakleničkih plinova.

Također treba imati na umu da predstavljena analiza nije uključivala utjecaj manje zahtjevnih režima rada dizelskog generatora zbog sposobnosti baterije da preuzme vršna opterećenja pogonskih sklopova, što bi rezultiralo smanjenim opterećenjem dizelskog generatora. Ovo bi također moglo pružiti dodatne pogodnosti u smislu smanjenog trošenja komponenata dizelskog generatora i povezanog smanjenja troškova održavanja i remonta, kako je navedeno u referenci [139]. Nadalje, treba uzeti u obzir i da je gornja procjena provedena pomoću podataka koji odgovaraju relativno starijem dizelskom motoru (EMD 16-645-E), što može dovesti do korekcija ušteda u usporedbi s hibridizacijom novije lokomotive opremljene naprednijim dizajnom dizelskog motora. Također, treba napomenuti da se prikazane uštede goriva i povrat ulaganja, dobiveni za razmatranu brdsko-planinsku željezničku rutu vjerojatno neće moći izravno preslikati na nizinsku željezničku trasu. Naime, takve vrste ruta karakteriziraju manje promjene nadmorske visine, gdje bi kinetička energija dobivena ubrzanjem vlaka pretežno odredila dobitke energije kod regenerativnog kočenja tijekom usporavanja, dok bi iskorištavanje razlike potencijalne energije zbog promjene profila visine bilo manje naglašeno.

Uz sve navedeno, potrebno je kritički ocijeniti potencijal ovakvih dobitaka u smislu ušteda energije u odnosu na procijenjene troškove elektrifikacije željezničke trase i usporediti ih s troškovima nabave baterijsko-hibridnih lokomotiva, što odgovara broju konvencionalnih dizel-električnih lokomotiva razmatranog tipa koje su trenutno u pogonu u Hrvatskim željeznicama [140].

Temeljem podataka o kapitalnim troškovima elektrifikacije kolosijeka u SAD-u, a koji približno iznose 4.8 milijuna USD / milji (2,63 milijuna EUR / km) [141], procjenjuje se da bi ukupni troškovi elektrifikacije pruge za rutu razmatranu u ovom radu iznosili 591 milijun EUR. S druge strane, trošak nabave 20 novih dizel-električnih lokomotiva procjenjuje se na temelju dostupnih podataka za lokomotive s pogonom od 4500 konjskih snaga [142], a čija nabavna cijena iznosi 3 milijuna USD, na temelju čega se procjenjuje specifični trošak od 790 EUR/kW. Stoga bi procijenjeni trošak jedne dizel-električne lokomotive, opremljene pogonskim sklopom snage 1,6 MW, iznosio 1,264 milijuna EUR (odnosno ukupni trošak nabave 20 novih lokomotiva procjenjuje se na 25,28 milijuna EUR).

Međutim, kako bi se procijenili troškovi baterijsko-hibridne lokomotive, gore spomenuti trošak konvencionalne lokomotive prilagođava se s obzirom na smanjenje veličine i troškova glavnog generatora motora u usporedbi s konvencionalnom lokomotivom (cijena lokomotive bez agregata u tablici 17), a također i zbog povećanja troškova na instalaciju sustava za baterijsku pohranu energije. Dakle, ukupni trošak kupnje baterijsko-hibridne lokomotive procjenjuje se na 1.43 milijuna EUR (vidi tablicu 17), što rezultira ukupnim troškovima nabave 20 baterijsko-hibridnih lokomotiva u iznosu od 28,6 milijuna EUR, što je i dalje dvadeset puta manje u odnosu na kapitalne investicije za elektrifikaciju kolosijeka. Budući da se ova procjena temelji na javno dostupnim i citiranim podacima o cijenama u SAD-u, stvarni lokalni troškovi naknadne ugradnje mogu se razlikovati od gornje procjene, a ta pretpostavka ne uključuje troškove održavanja i trajanje postupka elektrifikacije kolosijeka što je znatno dulje u odnosu na životni vijek baterije unutar hibridne lokomotive, a koji iznosi približno 2000 ciklusa punjenja i pražnjenja. Dodatna prednost korištenja hibridne lokomotive je u smanjenju emisija ispušnih plinova koji su također navedeni u tablici 12, gdje je vidljivo da su redukcije emisija ispušnih plinova proporcionalne smanjenju potrošnje goriva, uzevši naravno u obzir i performanse baterijskog sustava za pohranu energije (nova baterija rezultira manjim troškovima goriva i manjim emisijama zbog većeg iznosa kapaciteta pohrane i obratno).

Tablica 16. Trošak goriva za jednu vožnju i kumulativna potrošnja goriva za više od 2000 vožnji.

Tip lokomotive	Kumulativna potrošnja (L)		Trošak goriva (EUR)
	Jedna vožnja	2000 vožnji	
Konvencionalna	2750	5500000	7425000
Hibridna (SoC_{RV})	2297	4594000	6201900
Uštede goriva	453	906000	**1223100**
Poboljšanje učinkovitosti [%]		16.47 %	

Tablica 17. Usporedni troškovi konvencionalnih i baterijsko-hibridnih dizel-električnih lokomotiva.

Lokomotiva	Troškovi (EUR)			
	Lokomotiva bez agregata	Glavni agregat	Baterija	Ukupna cijena
Konvencionalna	1190155	73845	-	1264000
Hibridna		59076	180000	1429231
			Razlika u cijeni:	**165231**

Tablica 18. Usporedni rezultati emisija ispušnih plinova u simulaciji

Lokomotiva	Emisije ispušnih plinova (kg)			
	HC	CO	NO_X	CO_2
Konvencionalna	8.21	94.97	130.43	7257
Hibridna (SoC_{RC}) *Nova*	6.97	82.02	109.94	6103
Hibridna (SoC_{RC}) *Stara*	7.09	83.84	111.92	6215
Hibridna (SoC_{RV}) *Nova*	6.99	83.23	108.72	6055
Hibridna (SoC_{RV}) *Stara*	7.11	84.98	110.55	6160

4.1.2. Potencijalne uštede uz primjenu baterijske lokomotive

Kao što je prikazano u prethodnom odjeljku litij-ionske baterije mogu izdržati najmanje 2000 ciklusa punjenja i pražnjenja, pri čemu se ciklus eksploatacije baterije definira kao periodičko punjenje do 100% kapaciteta pohrane (stanja napunjenosti) nakon čega slijedi pražnjenje do 20% stanja napunjenosti. Na ovaj način definirana vrijednost vijeka ciklusa koristi se i u ovom odjeljku za definiciju korisnog vijeka trajanja baterijskog sustava za pohranu energije u sklopu baterijsko-električne lokomotive, odnosno na taj način se definira period eksploatacije nakon kojeg je potreban njen kompletan remont. Dobiveni podaci o kumulativnoj potrošnji goriva i troškovima goriva za konvencionalnu lokomotivu i lokomotivski tandem DB1 i DB2 (vidi rezultate u poglavljima 3.2 i 3.3) za standardni teret od sedam 90-tonskih vagona navedeni su u tablici 19. Prema prikazanim rezultatima baterijska lokomotiva mogla bi pomoći smanjiti potrošnju goriva konvencionalne lokomotive do 30%. Međutim, kada se koristi u tandemu, baterijska lokomotiva će također koristiti električnu energiju. Stoga bi „gruba“ procjena „tandemskih“ troškova uključivala i cijenu dizelskog goriva od 1,35 EUR/L (vidi prethodni odjeljak) i trenutnu cijenu električne energije od 0,1034 EUR/kWh [143]. Ovi procijenjeni troškovi prikazani su u posljednjem stupcu tablice 19. Ukupne uštede goriva i električne energije su oko 14% za slučaj DB1 i 22% za slučaj DB2.

Tablica 19. Ukupni troškovi goriva i električne energije tijekom 2000 ciklusa

Lokomotiva	Kumulativna potrošnja		Trošak (EUR)
	1 vožnja	2000 vožnji	
Konvencionalna dizel [l]	2750	5500000	7425000
Dizel tandem DB1 / DB2 [l]	2233 / 1900	4466000 / 3800000	6029100 / 5130000
Baterijska tandem DB1 / DB2 [kWh]	1570 / 2889	3140000 / 5778000	324676 / 597445
Uštede goriva DB1 / DB2 [l]	518 / 851	1036000 / 1702000	
Uštede goriva DB1 / DB2 [%]	18,83 % / 30,93 %		
Smanjenje troškova DB1 / DB2 [%]			**14,42 % / 22,86 %**

Sažetak procjene troškova dani su u tablici 20, gdje se cijena lokomotiva određuje na sličan način kao u prethodnom poglavlju. Trošak nove baterijsko-električne lokomotiva procjenjuje se tako, da se na cijenu lokomotive (vidi tablicu 17) doda trošak baterije koji iznosi 523.200 EUR s obzirom na definirani kapacitet baterije od 2616 kWh u potpoglavlju 2.6 i cijenu od 200 EUR/kWh u potpoglavlju 2.5 Troškovi povezani s 2000 prelazaka predmetne željezničke rute za razmatrane scenarije D, DB1 i DB2 karakteriziranih vučom sedam 90-tonskih vagona također su prikazani u tablici 20. Ovi troškovi uključuju ukupne troškove goriva i električne energije procijenjene u tablici 19, a koji pokazuju da iako tandem lokomotiva ima značajan potencijal ušteda, to još uvijek nije dovoljno za prevladavanje procijenjenih troškova nabave nove baterijsko-električne lokomotive. Za slučaj DB1 ova razlika iznosi -642.131 EUR (manjak) u odnosu na točku povrata ulaganja (slučaj rentabilnosti), dok se u slučaju DB2 scenarija primjećuje samo -15.800 EUR manjka u odnosu na slučaj rentabilnosti. Međutim, u slučaju naknadne ugradnje baterije u staru dekomisioniranu dizel-električnu lokomotivu (tzv. baterijski retrofit), troškovi ovakvog retrofita baterijsko-električne lokomotive mogu biti bliži procijenjenom trošku baterije, pa će uštede u tom slučaju opravdati ulaganje. Također treba imati na umu da se tijekom životnog vijeka lokomotive očekuje da se može dogoditi nekoliko zamjena baterija (ili njene povremene obnove). Prema trenutnim trendovima troškova baterija, razumno je pretpostaviti da će troškovi baterija vjerojatno i dalje opadati prije konačnog otpisa/rashoda lokomotive, čime će ukupni troškovi ulaganja biti niži, što scenarij povrata investicije čini vjerojatnijim. S druge strane, sa stanovišta emisija ispušnih plinova, upotrebom baterijske električne lokomotive u tandemu moguće je postići smanjenje potrošnje goriva do 30%, što se također odražava i na potencijalu smanjenja emisija stakleničkih plinova.

Tablica 20. Sažetak procjene troškova

	Trošak (EUR)
Konvencionalna dizel-električna lokomotiva	1.264.000
Baterijsko-električna lokomotiva	1.713.355
2000 vožnji za slučaj D	7.425.000
2000 vožnji za slučaj DB1	6.353.776
2000 vožnji za slučaj DB2	5.727.445

Slika 73. prikazuje troškove vuče tereta za različite vrijednosti tereta i različite konfiguracije lokomotive. Krivulja troškova goriva (slika 73a.) i krivulja troškova električne energije uslijed punjenja iz mreže (slika 73b.) jednakog su oblika kao i krivulje prikazane na slikama 67.b i 67.c u potpoglavlju 3.3, jer se te krivulje linearno skaliraju cijenom goriva i električne energije. Ukupni troškovi na slici 73c. pokazuju kako se troškovi razlikuju između konfiguracija. Štoviše, slika 67c. pokazuje da su troškovi goriva dominantni u usporedbi s troškovima električne energije (usporediti slike 73c i 73a), dok je baterijska električna lokomotiva s punjenjem na sredini putovanja (B2) troškovno optimalno rješenje, ali za vuču vrlo lakih tereta. Tandemska konfiguracija DB2 dobro je rješenje za terete do približno 1200 t, dok DDB2 predstavlja troškovno optimalno rješenje za veća opterećenja. Ako se ovi rezultati za scenarije DB2 i DDB2 usporede s vremenima putovanja na slici 67a u potpoglavlju 3.3, ponovno se mogu smatrati optimalnim između razmatranih scenarija. Naime, ovi tandemi su sposobni prijeći danu rutu u kraćem vremenu uz istodobno najmanju potrošnja goriva.

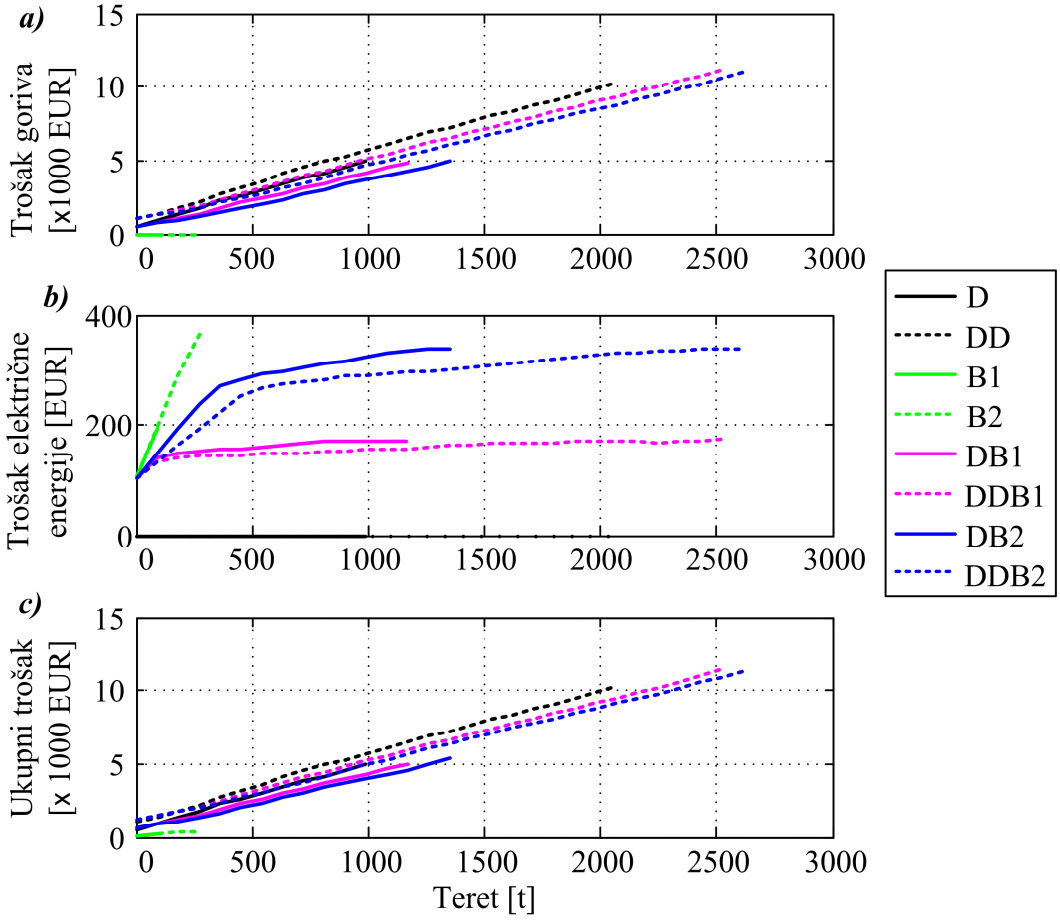

Slika 73. Troškovi za različite konfiguracije: (a) gorivo, (b) električna energija i (c) ukupni trošak.

4.2. Predviđanje zastoja i moguće intervencije

Budući da se uvjeti na kolosijeku (adhezija, čeoni vjetar i dr.) mogu bitno razlikovati tijekom vozne misije prema lokacijskoj i vremenskoj distribuciji, podaci s udaljenih senzora mogu se koristiti u predloženom modelu za procjenu trajanja putovanja i njegove izvedivosti za određeni segment kolosijeka.

Konturna mapa vremenskih okvira ispunjenja vozne misije za prvih 50 km razmatrane rute sa slike 23 iz potpoglavlja 2.2 i slučaj potpuno opterećenog vlaka dana je na slici 74. Normalno vrijeme prolaska kroz ovaj segment s ovom vrstom tereta i s nominalnom 100%-tnom adhezijom uz čeoni vjetar brzine 12 km/h, je 1.4 sata. Smanjenje adhezije na oko 70% i povećanje brzine čeonog vjetra na 40 km/h ima zanemariv utjecaj na povećanje vremena tranzicije kroz navedeni segment trase. Međutim, daljnje smanjenje adhezije ili daljnje povećanje brzine čeonog vjetra značajno povećava vrijeme prolaska segmenta. Bijelo područje na slici 74. prikazuje vrijednosti adhezije i brzine čeonog vjetra za koje vozna misija postaje neizvediva za zadanu konfiguraciju vlaka. Ova informacija bi se mogla koristiti unutar lokomotivskog 'telematskog' sučelja za udaljeno alarmiranje strojovođe o mogućnosti nailaska na izrazito nepovoljne uvjete vožnje. Štoviše, podaci prikazani na slici 74 mogu se također koristiti za predviđanje mogućeg problema nepredviđenog zaustavljanja vlaka zbog nedovoljne sposobnosti sustava vuče za prevladavanje nepovoljnih vremenskih uvjeta na tračnicama. Navedeno bi se moglo pokazati vrlo korisnim u smislu vođenja rasporeda vlakova uključivanjem dodatne lokomotive u teretni vlak kako bi se povećale vučne sposobnosti te kako bi se na taj način smanjile moguće odgode voznih misija.

Ovdje valja napomenuti da su prikazani rezultati dobiveni za slučaj idealne dostupnosti podataka sa mreže udaljenih NB-IoT senzora u stvarnom vremenu. Očito bi se smanjenjem dostupnosti podataka sa mreže senzora bitno degradirala i strategija upravljanja teretnim vlakom, što bi rezultiralo time da se virtualni model strojovođe (autonomni mod upravljanja) oslanja isključivo na mjerenja brzine vlaka u samoj lokomotivi i informacijama o nagibu na temelju poznatog profila nadmorske visine željezničke rute. Shodno tome, u uvjetima niske dostupnosti podataka s mreže udaljenih senzora u stvarnom vremenu, predstavljena adaptivna strategija upravljanja svela bi se na osnovnu strategiju upravljanja baterijsko-hibridnom dizel-električnom lokomotivom koja je prikazana u poglavlju 3.2.

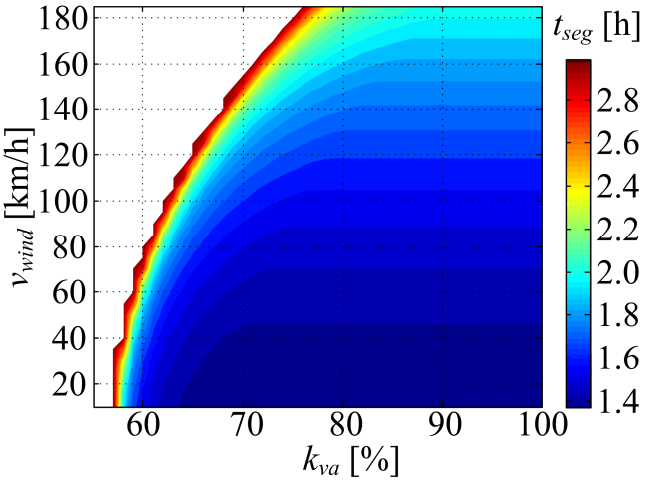

Slika 74. Procijenjeno trajanje vozne misije vlaka za početni segment (50 km) željezničke pruge pri promjenjivim uvjeta na kolosijeku.

4.3. Povećanje sigurnosti i učinkovitosti prijevoza uz varijabilne uvjete na trasi

4.3.1. Simuliranje ovisnosti koeficijenta trenja o atmosferskim varijablama

Empirijski ustanovljena ovisnost koeficijenta trenja o temperaturi T i apsolutnoj vlažnosti zraka H_A koja je prethodno navedena u potpoglavlju 1.4.5. (slike 12 i 13.) koristi se u simulacijskom modelu vlaka za posredno emuliranje promjene koeficijenta adhezije kako je dano na slici 13, gdje su za male vrijednosti apsolutne vlažnosti zraka vrijednosti koeficijenta trenja ekstrapolirane prema jediničnoj vrijednosti (a što bi odgovaralo potpuno suhim tračnicama). Navedene ovisnosti se jednostavno ugrađuju u model teretnog vlaka implementiranog u programskom okruženju Matlab / Simulink u obliku dvodimenzionalne (2D) pregledne (engl. look-up) tablice čiji su ulazi temperatura zraka T [°C] i apsolutna vlažnost zraka H_A [g/m^3]. Na taj način se jednostavnom promjenom pojedinog parametra (temperature i apsolutne vlažnosti zraka) može simulirati promjenjivu adheziju (i varijabilni potencijal kočenja) na pojedinim dijelovima trase.

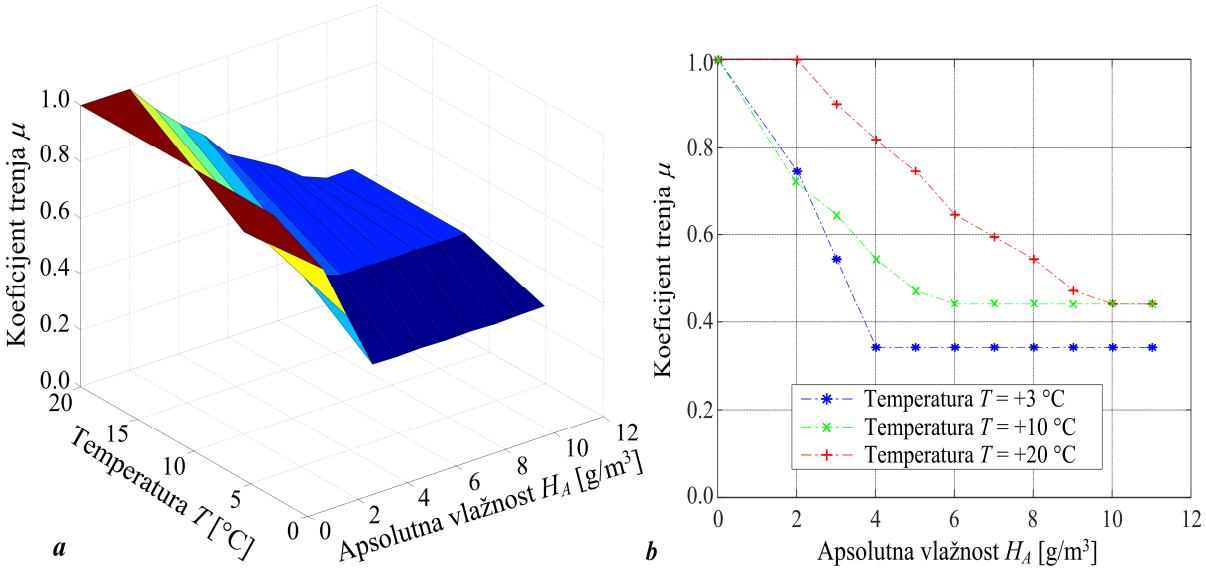

Slika 75. Trodimenzionalni prikaz (a) i parametarski prikaz (b) koeficijenta trenja u simulaciji s obzirom na promjene temperature i apsolutne vlažnosti zraka.

4.3.2. Rezultati simulacije vozne misije vlaka uz primjenu fuzzy klasifikatora stanja željezničke trase

Simulacijski rezultati za slučaj promjenjive adhezije i konstantnog čeonog vjetra prikazani su na slikama 76 – 78, za slučaj modela strojovođe koji ne prima, odnosno prima informaciju o stanju trase temeljenu na neizrazitom algoritmu klasifikacije trase iz potpoglavlja 2.8 u smislu dostupne adhezije između kotača i tračnica. Slika 76 prikazuje profil temperature i apsolutne vlažnosti korišten u simulaciji s obzirom na položaj vlaka na trasi, čiji profil nadmorske visine, rezultirajući koeficijent adhezije i čeoni vjetar su dani na slici 77 u funkciji prijeđenog puta vlaka. Slika 76 također prikazuje usporedbu koeficijenta adhezije i izlaza klasifikatora temeljenog na neizrazitoj logici gdje je vidljivo da je sustav neizrazitog zaključivanja podešen da može kvalitetno detektirati promjenu adhezije na trasi temeljenu na bazi pravila.

Simulacijski rezultati vozne misije vlaka i rezultat klasifikacije stanja na trasi prikazani u funkciji prijeđenog puta tijekom prethodno opisane vozne misije teretnog vlaka s dizel-električnom lokomotivom koja vuče sedam potpuno natovarenih teretnih vagona (90 t svaki) za zadanu željezničku trasu i uvjete adhezije na slici 77 prikazani su na slici 78. Gornji graf na slici 78 prikazuje rezultate simulacije dobivene tijekom vozne misije željezničkom za slučaj

kada strojovođa nema dostupnu informaciju o stanju trase te nastoji voziti kompoziciju tako da zadovolji referentnu brzinu vlaka jednaku ograničenju brzine na pojedinoj dionici (vidi prethodna razmatranja vezana za slučaj ocjene energetske učinkovitosti). Vidljivo je da u intervalima gdje je stanje adhezije na trasi loše, a koji korespondiraju jakim nagibima pruge dolazi ili do proklizavanja te nemogućnosti dostizanja limita brzine (kod uspona), odnosno do potrebe za kočenjem pri spuštanju pri čemu se održava relativno velika brzina vlaka. Budući da u potonjem slučaju vlak koči, ali svejedno održava visoku brzinu vožnje, ovo može postati sigurnosni problem iz dva razloga:

- budući da je vlak već u stanju kočenja i pritom ostvaruje veliku brzinu tijekom spuštanja, ograničen mu je potencijal kočenja u slučaju potrebe za naglim zaustavljanjem kompozicije,

- potencijal kočenja je dodatno ograničen zbog smanjenog potencijala sile trenja mehaničkih kočnica.

Stoga je potrebno provesti odgovarajuću intervenciju koja će smanjiti rizik i povećati sigurnost prometovanja vlaka, odnosno omogućiti sigurnije zaustavljanje u slučaju potrebe za naglim kočenjem. To se postiže ograničavanjem brzine vlaka u uvjetima kada se detektiraju loši uvjeti na trasi (niska adhezija) primjenom klasifikatora stanja trase primjenom neizrazite logike. Jednostavna intervencija koja je primijenjena u ovoj studiji je da se model strojovođe informira o lošim uvjetima na trasi, što indicira izlaz fuzzy klasifikatora $y_{fuzzy} < 0.7$, što modelu strojovođe automatski smanjuje ciljnu (referentnu) brzinu vlaka za 20 km/h u odnosu na limit, uz donju ogradu brzine postavljenu na 20 km/h. Rezultati za navedeni scenarij prikazani su na donjem grafu slike 78, i oni potvrđuju da predloženi algoritam upozoravanja strojovođe efikasno smanjuje referencu brzine vlaka kada se detektiraju loši uvjeti adhezije na trasi, smanjujući time stvarnu brzinu vlaka na kritičnim dionicama. Na ovaj način su vrlo jednostavno inkorporirana mjerenja sa udaljene mreže senzora u sustav upozoravanja vozača (strojovođe) preko jednostavnog indeksa stanja trase gdje $y_{fuzzy} < 0.7$ indicira razmjerno loše uvjete na trasi.

Ovaj model se, naravno, može dodatno doraditi tako da se različitim iznosima ovoga indeksa pridijele različite kategorije (na primjer, dobra, osrednja ili loša trakcija), što će svakako biti tema budućih istraživanja u ovom području.

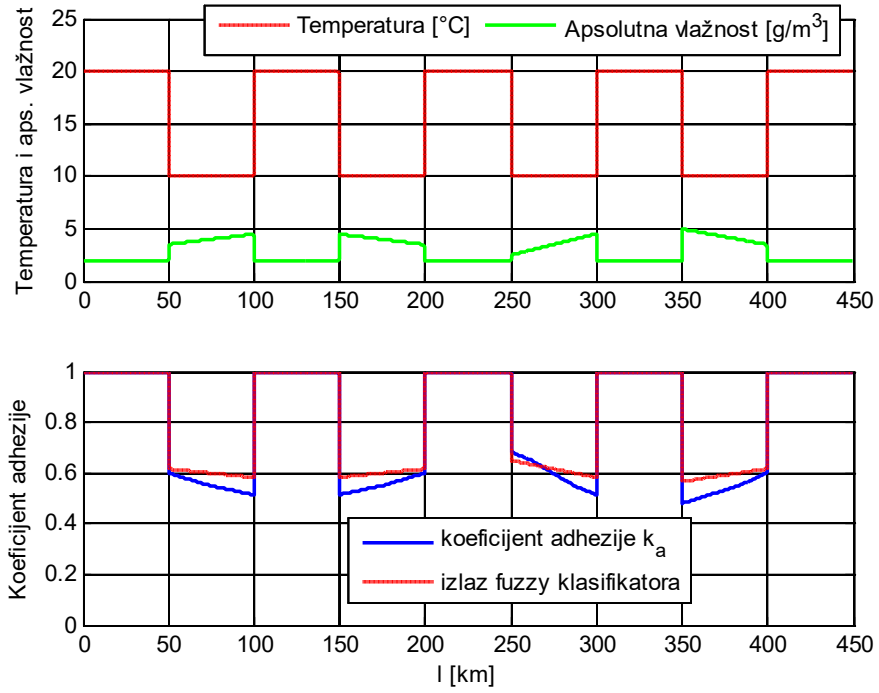

Slika 76. Temperatura i apsolutna vlažnost zraka u simulaciji vozne misije vlaka u funkciji pozicije vlaka na trasi (prijeđenog puta) i rezultirajuća klasifikacija primjenom neizrazite logike u usporedbi sa stvarnim koeficijentoim adhezije.

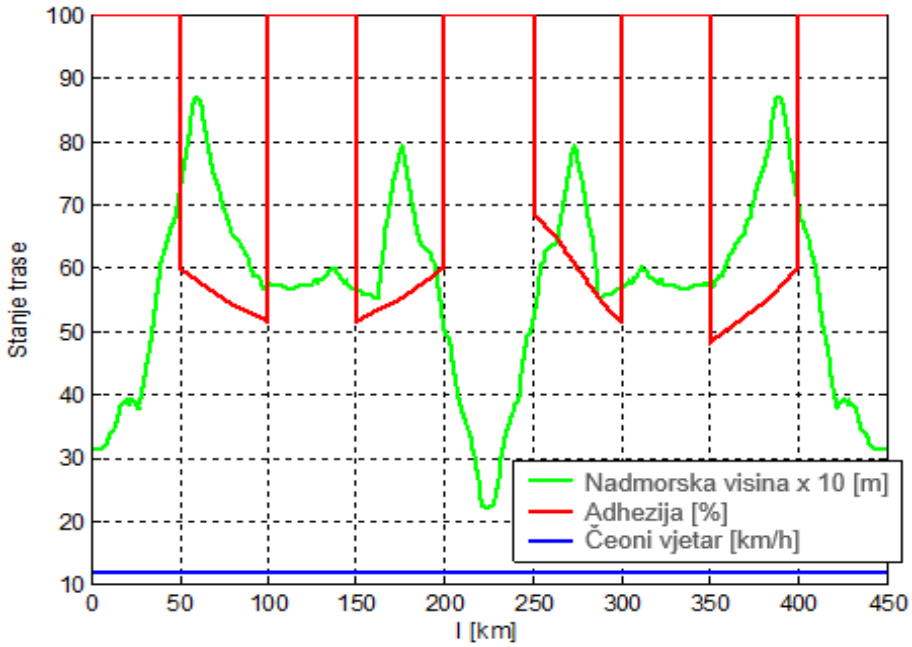

Slika 77. Nadmorska visina, adhezija i čeoni vjetar u funkciji prijeđenog puta kompozicije.

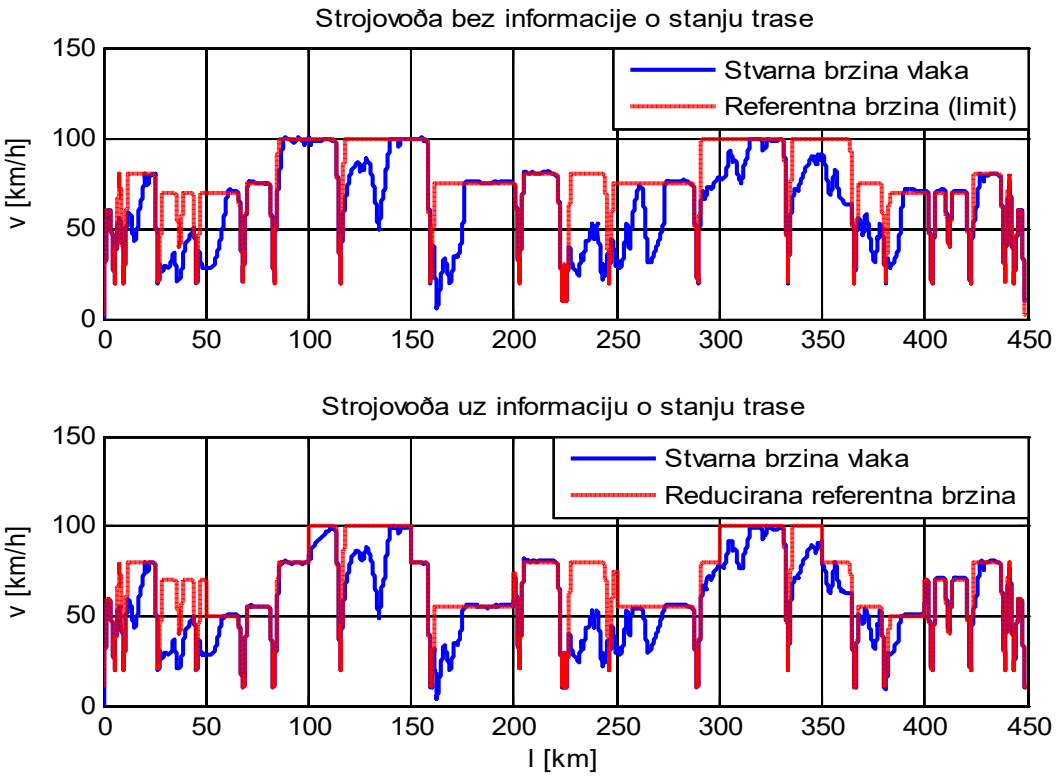

Slika 78. Profili brzine vlaka za slučaj kada strojovođa nema, odnosno ima informaciju o stanju trase na temelju neizrazitog klasifikatora.

5. ZAKLJUČAK

U doktorskom radu predložen je cjeloviti i sistematičan pristup modeliranju hibridnog pogona željezničkog prometnog entiteta podržanog informacijama iz udaljenih uskopojasnih senzorskih mreža male potrošnje energije, a u svrhu postizanja energetske učinkovitosti i sigurnosti željezničkog prijevoza. Glavna prednost ovog pristupa je da se u određenom vremenskom odsječku tijekom vozne misije dodaju strukturirane informacije temeljene na ekspertnom znanju iz udaljenih senzorskih mreža i time omogućuje da se kvaliteta strategije upravljanja željezničkog prometnog entiteta s hibridnim pogonom može povećati prema kriteriju energetske učinkovitosti i prometne sigurnosti.

U radu je predložen kvazistatički model konvencionalne dizelsko-električne lokomotive za tešku vuču snage 1.6 MW, a koju koristi nacionalna željeznička kompanija Hrvatske željeznice. Model je dobiven na temelju poznatih parametara pogonskog sklopa lokomotive, kao što su nazivna snaga dizelskog motora i izlazna električna snaga agregata, odnosno sustava vuče. U svrhu izvođenja modela potrošnje goriva i s njim povezanog modela emisija ispušnih plinova, te modela vučne sile i karakteristika snage pogonskog sustava, iskorištene su karakteristike sličnog dizelskog motora i generatora (agregata) i njihovi podaci o potrošnji goriva preuzeti su iz dostupne literature radi prilagodbe (skaliranja) kako bi odgovarali karakteristikama snage ciljnog agregata razmatrane dizel-električne lokomotive. Tako dobiveni model konvencionalne lokomotive potom je iskorišten za hipotetsku konverziju lokomotive u baterijsko-hibridnu te potpuno baterijsku varijantu dodavanjem odgovarajućeg baterijskog sustava za pohranu energije dovoljno velikog kapaciteta pohrane paralelno generatoru. Uz to, osmišljena je odgovarajuća optimizirana strategija upravljanja energijom kako bi se stanje baterije održavalo u unaprijed definiranim granicama, istodobno pomažući konvencionalnom pogonu tijekom vožnje, te također olakšavajući povrat dijela potencijalne energije vlaka tijekom spuštanja pretvorbom njegove kinetičke energije u električnu pomoću regenerativnog kočenja trakcijskim motorima. Također je razmatran novi pristup teškoj željezničkoj vuči tereta kombiniranim radom konvencionalnih dizel-električnih i baterijsko-električnih lokomotiva za različite karakteristične scenarije pojedinačnog i zajedničkog (tandemskog) rada konvencionalnih i baterijskih električnih lokomotiva. U svrhu upravljanja tokovima snage između konvencionalne i baterijske električne lokomotive, te kako bi se osigurala dodatna razina sigurnosti usmjerena na održavanje stanja napunjenosti baterije iznad minimalne preporučene vrijednosti od 20% u zahtjevnim uvjetima vuče tereta, dodatno je uključeno

pravilo redukcije "Notch" komande akceleratora koju zadaje vozač. Simulacijski modeli baterijsko-električne i konvencionalne dizel-električne lokomotive uspoređeni su i simulirani u različitim tandemskim i samostalnim kombinacijama za razmatranu brdsko-planinsku željezničku rutu za slučaj kružnog putovanja, uključujući realni nagib željezničke pruge i ograničenja brzine.

U radu je nadalje razvijeni model baterijsko-hibridne dizel-električne lokomotive proširen dodatnim podacima o stanju kolosijeka iz udaljene mreže bežičnih senzora zasnovanih na primjeni uskopojasnih 5G komunikacijskih tehnologija. Podaci korišteni u modelu odnose se na ključna dva parametra koji definiraju uvjete kolosijeka, tj. koeficijent adhezije između kotača i tračnica i prosječnu brzinu čeonog vjetra, koji, pak, odgovaraju promjenjivim vremenskim uvjetima na trasi. Navedeni se podaci zatim koriste u okviru modela teretnog vlaka za predviđanje njegovog ponašanja, a koriste se i za pronalaženje optimalnih parametara regulatora stanja napunjenosti baterijskog sustava za pohranu energije za različite režime rada, čime se izbjegava nepotrebno duboko pražnjenje baterije u sklopu pogona baterijsko-hibridne dizel-električne lokomotive.

Za odabrani profil planinske željezničke rute kojom upravlja nacionalna željeznička tvrtka (Hrvatske željeznice, HŽ) izvršena je procjena energetske učinkovitosti, odnosno ocjena potrošnje goriva konvencionalne i hibridne baterijske lokomotive koristeći simulacijski scenarij povratnog putovanja. Ovaj scenarij uključuje realna ograničenja nagiba trase i brzine vlaka. Dobiveni rezultati simulacije pokazali su da se primjenom baterijsko-hibridne lokomotive mogu postići značajne uštede energije, a koje rezultiraju smanjenjem potrošnje goriva čak do 16.5%, što se također odražava u proporcionalnom smanjenju emisija stakleničkih plinova. Prošireni simulacijski model koji uključuje promjenjive uvjete kolosijeka uspio je identificirati potrebnu prilagodbu ponašanja vozača (tj. promjenu režima vožnje i potrebu za kočenjem) u uvjetima promjenjive adhezije na tračnicama prianjanjem i promjenjivom čeonom vjetru. Navedene modifikacije režima rada lokomotive također su rezultirale povećanim vremenskim trajanjem putovanja pod pogoršanim uvjetima na trasi (u usporedbi s referentnim slučajem s konstantnom adhezijom i čeonim vjetrom) u skladu s ograničenjima sustava vuče lokomotive. Pogoršani uvjeti kolosijeka (tj. smanjena adhezija i pojačani čeoni vjetar) također rezultiraju povećanom potrošnjom goriva i dubljim pražnjenjem baterijskog sustava za pohranu energije u sklopu baterijsko-hibridne dizel-električne lokomotive zbog neoptimalnog rada glavnog pogona (tj. dizelskog agregata i vučnih električnih motora). Konkretno, u slučaju smanjene

adhezije, potencijal za prikupljanje kinetičke energije teretnog vlaka putem vučnog elektromotornog pogona značajno je smanjen, dok porast čeonog vjetra općenito rezultira povećanom potrošnjom energije. Optimirani regulator stanja napunjenosti baterije koji koristi informacije o stanju kolosijeka s mreže udaljenih bežičnih senzora može održavati stanje napunjenosti baterije iznad minimalne preporučene vrijednosti (20% u ovom slučaju), što nije bio slučaj sa regulatorom stanja napunjenosti s konstantnim parametrima. Stoga je optimirani regulator sposoban spriječiti duboko pražnjenje baterije i na taj način smanjiti njenu degradaciju i s time povezano smanjenje vijeka trajanja baterije, istodobno održavajući potrošnju goriva na prihvatljivoj razini za konkretni zahtjevni scenarij vožnje. Rezultati također ukazuju na to da model koji uključuje podatke o stanju kolosijeka s udaljenih senzora može predvidjeti trajanje vozne misije na predmetnom segmentu željezničke pruge i predvidjeti moguća neplanirana zaustavljanja vlakova zbog nepovoljnih atmosferskih uvjeta na kolosijeku.

Na temelju empirijski ustanovljene korelacije koeficijenta trenja, okolišne temperature apsolutne vlažnosti zraka formiran je neizraziti algoritam klasifikacije stanja adhezije između kotača i tračnica na željezničkoj trasi kako bi se pravovremeno upozorilo strojovođu na promjenu potencijala sile kočenja i sile vuče na pojedinim dijelovima trase temeljem mjerenja temperature i vlažnosti zraka iz mreže udaljenih senzora. Neizraziti algoritam klasifikacije stanja trase i odgovarajuća intervencija strojovođe u slučaju smanjenog potencijala sile trenja i sile vuče kroz smanjenje brzine prometovanja (čime se inherentno povećava sigurnost prometovanja i olakšava zaustavljanje u slučaju nužde) ispitani su simulacijama na računalu. Predloženi algoritam klasifikacije stanja na trasi efikasno upozorava strojovođu koji pravovremeno smanjuje brzinu vlaka na kritičnim dionicama kada se detektiraju loši uvjeti adhezije na trasi.

U završnom dijelu rada prikazana je tehno ekonomska analiza koja je provedena uz uvjet očekivanog vijeka trajanja baterije i s tim povezani očekivani pad kapaciteta od 20% tijekom eksploatacije, gdje hibridna lokomotiva može održavati iste vučne performanse kao i konvencionalna. Na temelju trenutnih troškova ugradnje litij-ionskih baterija, očekuje se da bi se troškovi ulaganja u hibridizaciju mogli nadoknaditi približno tri puta unutar očekivanog životnog vijeka baterije. Nadalje, dobiveni rezultati simulacija za baterijsko-električnu lokomotivu pokazuju kako je takva lokomotiva energetski najučinkovitija, ali je sposobna prijeći razmatrani planinski put samo pri vrlo malim opterećenjima. Ako se uvede dodatno punjenje baterija na sredini puta, baterijsko-električna lokomotiva u samostalnom radu može

ostvariti povećanje vuče tereta kao i poboljšane vozne karakteristike. U tandemskim operacijama, baterijsko-električna lokomotiva može omogućiti značajnu uštedu goriva do 30% povezanu s istodobnom upotrebom dizel-električne lokomotive, posebno ako se razmatra scenarij dvostrukog punjenja, što se također odražava u proporcionalnom smanjenju emisija stakleničkih plinova. Ako se uzmu u obzir i troškovi električne energije, konvencionalne tandemske konfiguracije plus baterijska lokomotiva mogu osigurati uštede do čak 22%. Iako ove uštede možda neće moći opravdati procijenjeni trošak potpuno nove baterijsko-električne lokomotive na temelju trenutnih troškova baterijskih sustava za pohranu energije, to možda nije slučaj kada se razmatra dugotrajna uporaba, imajući u vidu trenutni trend opadanje cijena baterija.

Istraživanjem je dokazana temeljna hipoteza ovoga znanstveno istraživačkog rada koja kaže da se uspješnost strategije upravljanja željezničkog prometnog entiteta s hibridnim pogonom može povećati prema kriteriju energetske učinkovitosti i prometne sigurnosti ako se u određenom vremenskom odsječku tijekom vozne misije, dodaju strukturirane informacije temeljene na ekspertnom znanju iz udaljenih senzorskih mreža.

Na temelju izloženog može se zaključiti kako se kao izvorni znanstveni doprinosi ovog istraživanja ističu:

- Razvoj metodologije i modela za podršku prediktivnom upravljanju željezničkim prometnim entitetom s ciljem povećanja energetske učinkovitosti i prometne sigurnosti.

- Definiranje novog optimiranog indeksa s težinskim faktorima za korektivno upravljanje željezničkim vozilima, te razvoj postupka za njegov izračun.

- Doprinos optimiranju upravljačkih varijabli željezničkih vozila s hibridnim pogonom na temelju udaljenih infrastrukturnih parametara

Predloženi postupak poboljšanja strategije upravljanja željezničkog prometnog entiteta s hibridnim pogonom dodavanjem strukturirane informacije temeljene na ekspertnom znanju iz udaljenih senzorskih mreža, namijenjen je domenskim stručnjacima iz područja inteligentnog prometa i transporta, energetike u prometu, ekologije, zelene energije i autonomnih željezničkih vozila, te široj znanstvenoj zajednici koja se bavi istraživanjem naprednog željezničkog transporta s ciljem energetske učinkovitosti i smanjenja emisije CO_2. Metodologija prikazana u radu je primjenjiva u razvoju sustava za podršku strojovođi s ciljem smanjenja njegovog kognitivnog opterećenja ili kao podsustav u budućim željezničkim vozilima s autonomnim

načinom upravljanja. Također, predloženi aplikativni model je moguće koristiti kao digitalni alat za planiranje i testiranje predefiniranih željezničkih prometnih trasa gdje je moguće procijeniti energetsku učinkovitost i potencijale za smanjenje emisiju CO2 u željezničkom prijevozu na nacionalnoj ili regionalnoj razini.

Identificirana su i područja za buduća istraživanja i unaprjeđenje predloženog modela strategije upravljanja željezničkim prometnim entitetima. U realiziranom i prethodno opisanom istraživanju promatran je odnos upravljanja vuče tereta i parametara okoline s ciljem optimizacije utrošene energije. Istraživanje za putničke vlakove koji zahtijevaju dodatno grijanje i hlađenje u putničkom prostoru ili prijevoz tereta koji zahtijeva kontroliranu temperaturu, kao što su „neprekinuti hladni lanci“, otvaraju dodatne mogućnosti uštede energije kojima je potrebno kroz modele upravljati.

LITERATURA

[1] European Parliament and of Council, Directive (EU) 2018/2001 on the promotion of the use of energy from renewable sources, Official Journal of the European Union 328/82, 2018.

[2] European Commission, Directorate - General for Research and Innovation: Accelerating Clean Energy Innovation, COM(2016) 0763 final, Bruxelles, November 2016.

[3] European Economic and Social Committee, Implications of the digitalisation and robotisation of transport for EU policy-making, TEN/632EESC2017, OJC 345, Brussels, Belgium, pp. 52-57, 2017.

[4] D. McCollum, V. Krey, P. Kolp, Y. Nagai and K. Riahi: „Transport electrification: A key element for energy system transformation and climate stabilization“, Climatic Change, Vol. 123, No. (3-4), pp 651-664, 2014.

[5] A. Y. Saber, and G. K. Venayagamoorthy: “Plug-in Vehicles and Renewable Energy Sources for Cost and Emission Reductions”, IEEE Transactions on Industrial Electronics, Vol. 58, No. 4, pp. 1229-1238, 2011.

[6] J. Hansen, M. Sato, P. Kharecha, D. Beerling, R. Berner, V. Masson-Delmotte, M. Pagani, M. Raymo, D. L. Royer, and J. Zachos: “Target atmospheric CO2: Where should humanity aim?”, The Open Atmospheric Science Journal, Vol. 2, pp. 217 – 231, 2008.

[7] S. Sorrell, J. Speirs, R. Bentley, A. Brandt, and R. Miller: “Global oil depletion: A review of the evidence”, Energy Policy, Vol. 38, No. 9, 5290-5295, 2010.

[8] U. Bardi: “Peak Oil: The four stages of a new idea”, Energy, Vol. 34, No. 3, pp. 323 – 326, 2009.

[9] J. Y. Yong, V. K. Ramachandramurty, K. M. Tan, and N. Mithulananthan, A Review of the State-of-the-Art Technologies of Electric Vehicle, Its Impacts and Prospects, Renewable and Sustainable Energy Reviews, Vol. 49, pp. 365-385, 2015.

[10] M. Barth, and M. Todd, “Intelligent Transportation System Architecture for a Multi Station Shared Vehicle System”, in Proc. of 2000 IEEE Intelligent Transportation Systems Conference, Dearborn, MI, USA, 2000, pp. 240-245.

[11] W. Su, H. R. Eichi, W. Zhang, and M.-Y. Chow, “A Survey on the Electrification of

Transportation in a Smart Grid Environment", IEEE Transactions on Industrial Informatics, Vol. 8, No. 1, pp. 1-10, 2012.

[12] S. R. Shakya and R.M. Shrestha: „Transport sector electrification in a hydropower resource rich developing country: Energy security, environmental and climate change co-benefits", Energy for Sustainable Development, Vol. 15, No. 2, pp 147-159, 2011.

[13] S. Frey: „Railway Electrification Systems & Engineering" 1st ed., White Word Publications, 2012.

[14] M. Mandić, I. Uglešić, V. Milardić, and B. Filipović-Grčić: „Application of Regenerative Braking on Electrified Railway Lines in AC Traction Systems 25 kV, 50 Hz", Proceedings of 12th Symposium HRO CIGRÉ, Šibenik, Croatia, November 8-11, 2015.

[15] F. E. S. Al-Tony and A. Lashine: „Cost-benefit analysis of railway electrification: case study for Cairo-Alexandria railway line", Impact Assessment and Project Appraisal, Vol. 18, No. 4, pp 323-333, 2012.

[16] Cambridge Systematics, Inc.: „Technical report prepared for Southern California Association of Governments Task 8: Analysis of Freight Rail Electrification in the SCAG Region", April 2012.

[17] M. Spiryagin, C. Cole, Y. Q. Sun, M. McClanachan, Y. Spiryagin and T. McSweeney: "Design and Simulation of Rail Vehicles", Taylor & Francis Group, LLC, 2014.

[18] United Nations Economic Commission for Europe (UNECE), "Glossary for transport statistics, fourth ed. " 2009.

[19] L. Li, R. R. Negenborn, B. De Schutter, "A general framework for modeling intermodal transport networks," *2013 10th IEEE INTERNATIONAL CONFERENCE ON NETWORKING, SENSING AND CONTROL (ICNSC)*, Evry, France, 2013, pp. 579-585.

[20] L. Qing, G., Tang, T., Yong-duan, S., A Survey on Energy-saving Operation of Railway Transportation Systems, Beijing Jiaotong University, China, Measurement + Control Vol 43/7, pp. 209-211, 2010.

[21] B. Klopper, C. Sondermann-Wolke, C. Romaus: "Probabilistic Planning for Predictive Condition Monitoring and Adaptation Within the Self-Optimizing Energy Management of an Autonomous Railway Vehicle", Tokyo, Japan, March 22, 2011.

[22] General Electric Transportation: „GE Transportation's Ecomagination Portfolio“, T.B. # 20153-A, 2018.

[23] General Electric Energy Storage: „Durathon Batteries - Battery Power, Reimagined“, Technical Brochure # 20194-A

[24] International Renewable Energy Agency (IRENA): "Road Transport: The Cost of Renewable Solutions", IRENA's Costing Study (http://www.irena.org/publications), 2013.

[25] D. Pavković, A. Komljenović, M. Hrgetić, M. Krznar: „Experimental Characterization and Development of a SoC/SoH Estimator for a LiFePO4 Battery Cell“, Proceedings of IEEE EUROCON 2015, pp. 397-402, Salamanca, Spain, 8-11 September 2015.

[26] D. Pavković, M. Krznar, A. Komljenović, M. Hrgetić, D. Zorc: „Dual EKF-based State and Parameter Estimator for a LiFePO4 Battery Cell“, Journal of Power Electronics, Vol. 17, No. 2, pp. 398 – 410, 2017.

[27] D. Pavković, A. Sedić, Z. Guzović: „Oil Drilling Rig Diesel Power-plant Fuel Efficiency Improvement Potentials through RuleBased Generator Scheduling and Utilization of Battery Energy Storage System“, Vol. 121, pp. 194-211, 2016.

[28] C. Mayet, J. Pouget, A. Bouscayrol, and W. Lhomme: „Influence of an Energy Storage System on the Energy Consumption of a Diesel-Electric Locomotive“, IEEE Transactions on Vehicular Technology, Vol. 63, No. 3, pp. 1032 - 1040, 2014.

[29] M. Meinert, M. Melzer, C. Kamburow, R. Palacin, M. Leska, H. Aschemann: „Benefits of hybridisation of diesel driven rail vehicles: Energy management strategies and life-cycle costs appraisal“, Applied Energy, Vol. 157, pp. 897 - 904, 2015.

[30] B. Asaei, M. Amiri: „High Efficient Intelligent Motor Control for a Hybrid Shunting Locomotive“, Proceedings of 2007 IEEE Vehicle Power and Propulsion Conference, pp. 405-411, Arlington, TX, USA, 9-12 September 2007.

[31] B. Klopper, C. Sondermann-Wolke, C.Romaus: "Probablistic Planning for Predictive Condition Monitoring and Adaptation Within the Self-Optimizing Energy Management of a Autonomous Railway Vehicle", Tokyo, Japan, March 22, 2011.

[32] Cuenca, O., KRRI tests 5G autonomous trains, International Railway Journal, Simmons-Boardman Publishing Corp. 88 Pine Street, New York, USA, V60I10, Falmouth, UK.

October, 2020.

[33] A, Smith, New ‘trackless train’ which runs on virtual rail lines launched in China, Metro Journal, 1 Farringdon Street, London, UK, 2017.

[34] D. Han, J. Wang, Y. Yan, M. Wu, Z. Lin and Y. Guodong, "Velocity Planning of the Autonomous Rail Rapid Transit with Consideration of Obstacles," 2020 4th CAA International Conference on Vehicular Control and Intelligence (CVCI), Hangzhou, China, 2020, pp. 35-40, doi: 10.1109/CVCI51460.2020.9338562.

[35] E. Díez-Jiménez, M. Fernández-Muñoz, R. Oliva-Domínguez, D. Fernández-Llorca and M. Á. Sotelo, "Personal Rapid Transport System Compatible With Current Railways and Metros Infrastructure," in IEEE Transactions on Intelligent Transportation Systems, doi: 10.1109/TITS.2020.2977387.

[36] Rosique F, Navarro PJ, Fernández C, Padilla A. A Systematic Review of Perception System and Simulators for Autonomous Vehicles Research. Sensors. 2019; 19(3):648. https://doi.org/10.3390/s19030648 [37]

[37] B. Hofmann-Wellenhof, H. Lichtenegger, E. Wasle: „GNSS - Global Navigation Satellite Systems“, Springer Science & Business Media, 2007.

[38] H. Cheng: „Autonomous Intelligent Vehicles - Theory, Algorithms, and Implementation“, Springer-Verlag London Limited, 2011.

[39] Z. Kljaić, E. Briški, H. Vojvodić, N. Amin: “Benefits of Utilisation of GPS Error Mitigation Models for Intelligent Transport Systems”, 41st International Convention on Information and Communication Technology, Electronics and Microelectronics, Opatija, Croatia, 2018.

[40] J. Talvitie, T. Levanen, M. Koivisto, K. Pajukoski, M. Renfors, M. Valkama: „Positioning of High-speed Trains using 5G New Radio Synchronization Signals“, In Proc. of 2018 IEEE Wireless Communications and Networking Conference (WCNC), 6 pages, Barcelona, Spain, April 15-18, 2018.

[41] S. E. Shladover: „Connected and automated vehicle systems: Introduction and overview“, *Journal of Intelligent Transportation Systems*, DOI: 10.1080/15472450.2017.1336053, 11 pages, 2017.

[42] 5G PPP METIS-II: „5G RAN Architecture and Functional Design”, White Paper on 5G

RAN Architecture and Functional Design, March 4th 2016.

[43] Ericsson research center: „Cellular networks for massive IoT“, Stockholm, Sweden, January 2016.

[44] M.Sneps-Sneppe, D. Namiot: „On 5G Projects for Urban Railways“, 22nd Conference of Open Innovations Association, Jyvaskyla, Finland, September 2018.

[45] P. Papadimitratos ; A. Fortelle ; K. Evenssen ; R. Brignolo ; S. Cosenza: „Vehicular communication systems: Enabling technologies, applications, and future outlook on intelligent transportation“, IEEE Communications Magazine, Vol. 47, Issue: 11, pp. 84-95, November 2009.

[46] G. R. Grob: „Future Transportation with Smart Grids & Sustainable Energy“, Proceedings of the 6th International MultiConference on Systems, Signals and Devices, 2009.

[47] X. Ge, Z. Li,and S. Li: „5G Software Defined Vehicular Networks“, IEEE Communications Magazine, pp. 87-93, July 2017

[48] I.Jovović; I.Forenbacher; M.Periša, Massive Machine-Type Communications: An Overview and Perspectives Towards 5G // RCITD - Proceedings in Research Conference in Technical Disciplines 2015 / Mokrys, Michal ; Badura, Stefan (ur.). Zilina: EDIS - Publishing Institution of the University of Zilina, 2015.

[49] Project: 5G-ConnectedMobility, video content: 5G-CM_Conclusion_EN.mp4, http://www.5g-connectedmobility.com/, pristupljeno: 21.01.2021.

[50] Completion of "5G-ConnectedMobility" after four successful years, http://www.5g-connectedmobility.com/, pristupljeno: 23.01.2021.

[51] 5G-Testfahrt im ICE und auf der Autobahn, ComputerWeekly.de, https://www.computerweekly.com/de/feature/5G-Testfahrt-im-ICE-und-auf-der-Autobahn, pristupljeno: 28.01.2021.

[52] Deutsche Bahn Introduces its Research Lab for the Future - the Advanced TrainLab, Railway-News Magazine, Science and Technology-Railway News, Feb.2019, https://railway-news.com/db-advanced-trainlab/, pristupljeno: 04.02.2021.

[53] Motion and Localization Reference at Advanced TrainLab, iMAR Navigation GmbH, Ingbert, Deutschland, https://www.imar-navigation.de/de/news/news/item/inat-rqt-

motion-and-localization-referenc-at-advanced-trainlab-deutsche-bahn, pristupljeno: 25.01.2021.

[54] 5G-Connected Mobility is a cross-industry consortium driving 5G R&D in Germany and in Europe, tech. brochure Eri, Prinzenallee 21 40549 Düsseldorf, Ericsson GmbH, 2020.

[55] Rossetti, M., Analysis of Weather Events on U.S. Railroads, United States Department of Transportation - Volpe National Transportation Systems Center, 55 Broadway, Cambridge, Massachusetts, SAD, 87th American Meteorological Society Annual Meeting, 2007.

[56] Kljaić, Z., Cipek, M., Pavković, D., Mlinarić, T. J., Assessment of Railway Train Energy Efficiency and Safety Using Real-time Track Condition Information, J. sustain. dev. energy water environ. syst., 9(2), 1080352, 2021, DOI: https://doi.org/10.13044/j.sdewes.d8.0352

[57] Kljaić, Zdenko; Cipek, Mihael; Mlinarić, Tomislav-Josip; Pavković, Danijel; Zorc, Davor. Utilization of Track Condition Information from Remote Wireless Sensor Network in Railways – A Mountainous Rail Track Case Study. Proceedings of 27th Telecommunications Forum TELFOR 2019, Beograd, Serbia, 2019. Paper No. 4485.

[58] Yi Zhu, Ulf Olofsson, Hua Chen: „Friction Between Wheel and Rail: A Pin-On-Disc Study of Environmental Conditions and Iron Oxides“, Tribology Letters, Vol. 52, pp. 327–339, 2013.

[59] Chinowsky, P., Helman, J., Gulati, S., Neumann, J., Martinich, J., Impacts of climate change on operation of the US rail network, Transport Policy journal 75. 183-191. US Environmental Protection Agency, Climate Change Division, Washington, DC, SAD, 2019, http://dx.doi.org/10.1016/j.tranpol.2017.05.007

[60] Temperature Anomaly - Global Land-Ocean Temperature Index, Data source: NASA's Goddard Institute for Space Studies (GISS), https://climate.nasa.gov/vital-signs/global-temperature/, pristupljeno: 19.01.2021.

[61] Rececap after Devon Train Line closed due to flooding, 2018, Cornwall News, Jamie Hawkins, https://www.cornwalllive.com/news/cornwall-news/live-updates-devon-train-line-2250568 [pristupljeno: 22.01.2021].

[62] Camp, J., Abkowitz, M., Hornberger, G., Benneyworth, L., Banks, J., Climate Change

and Freight-Transportation Infrastructure: Current Challenges for Adaptation, Journal of Infrastructure Systems, ASCE Library / Volume 19 Issue 4, Reston, USA, December 2013.

[63] Testfahrt des Stadler Flirt Akku, Eurail press, https://www.eurailpress.de/nachrichten/fahrzeuge-komponenten/detail/stadler-tu-berlin-ewe-dreijaehrges-projekt-mit-flirt-akku-batterie-reichweite-nach-oben-korrigiert.html, pristupljeno: 18.02.2021.

[64] Der dritte Batteriezug: Flirt Akku, RailBusiness 44/2018, Eurail Press, DVV Media Group GmbH, Heidenkampsweg 73-79, Hamburg, Deutschland. 2018.

[65] Haramina, H., Inteligentni transportni sustavi u željezničkom prometu, Autorizirana predavanja, Fakultet prometnih znanosti, Sveučilište u Zagrebu, 2017.

[66] Erbes, V., Cheremisin, V., Komyakov, A., Simulation of power consumption in railway power supply systems with of artificial intelligence aids, 2017 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM), 2017, pp. 1-5, doi: 10.1109/ICIEAM.2017.8076242.

[67] Komyakov, A., Nikiforov, M., Erbes, V., Cheremisin, T., Ivanchenko, V., Construction of electricity consumption mathematical models on railway transport used artificial neural network and fuzzy neural network," 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016, pp. 1-4, doi: 10.1109/EEEIC.2016.7555450.

[68] Utomo, R., Sumardi, Widianto, E., Control system of train speed based on fuzzy logic controller," 2015 2nd International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE), 2015, pp. 256-261, doi: 10.1109/ICITACEE.2015.7437809.

[69] Kljaić, Z., Pavković, D., Mlinarić, T.J., Nikšić, M., Scheduling of traffic entities under reduced traffic flow by means of fuzzy logic control, Promet - Traffic and Transportation (prihvaćen) 2021.

[70] Vučić, D., Traffic interconnection of Southern Croatia, Presentation (in Croatian) held at Vital Railway Infrastructure Panel, Dubrovnik, Croatia, November 2014. http://www.korema.hr/attachments/article/84/5_Uskotracna%20zeljeznicka%20pruga%20Gabela-Uskopolje-Dubrovnik.pdf, accessed 08.10.2018.

[71] GPS Visualizer: Freehand Drawing Utility: Draw on a map and save GPX data: http://www.gpsvisualizer.com/draw/, accessed 24.09.2018.

[72] OpenRailwayMap: https://www.openrailwaymap.org/, accessed 24.09.2018.

[73] Cipek, M., Bitanga, P., Mlinarić, T. J., Pavković, D. and Kljaić, Z., Comparative Analysis of Conventional Diesel-electric and Hybrid-electric Heavy Haul Locomotive Based on Mountain Rail Route Driving Scenario, Digital Proceedings of 3rd South East Europe (SEE) Sustainable Development of Energy Water and Environment Systems (SDEWES) Conference, Novi Sad, Vojvodina, Serbia, 2018.

[74] Pichlík, P., Zděnek, J., Overview of Slip Control Methods Used in Locomotives, Transactions on Electrical Engineering, Vol. 3, No. 2, pp 38-43, 2014.

[75] Valter, Z., Diesel-Electric Locomotives (in Croatian), Školska Knjiga, Zagreb, Croatia, 1985. ISBN: 978-953-0-30697-4

[76] Cipek, M., Pavković, D., Kljaić, Z., Mlinarić, T. J., Assessment of Battery-Hybrid Diesel-electric Locomotive Fuel Savings and Emission Reduction Potentials Based on a Realistic Mountainous Rail Route, Energy, Vol. 173, pp 1154-1171, 2019, https://doi.org/10.1016/j.energy.2019.02.144

[77] Spiryagin, M., Cole, C., Sun, Y. Q., McClanachan, M., Spiryagin, V. and McSweeney, T., Design and Simulation of Rail Vehicles, Taylor & Francis Group, LLC, 2014. ISBN: 978-11-380-7370-8

[78] Technical report: Hybrid Locomotive - SUSTRAIL, FP7 No. 265740, Deliverable 3.2.1, Hybrid Locomotive, 2014. http://www.sustrail.eu/IMG/pdf/d3.2-v1-hybrid_locomotive-final_version.pdf, accessed 08.10.2018.

[79] Spiryagin, M., Wolfs, P., Szanto, F., Sun, Y. Q., Cole, C. and Nielsen, D, Application of flywheel energy storage for heavy haul locomotives, Applied Energy, Vol. 157, pp 607-618, 2015. https://doi.org/10.1016/j.apenergy.2015.02.082

[80] Škrobonja, D., Beraković, T., Božunović, A., Ljubaj, Z. and Ljubaj, N., Applicative Monitoring of Locomotive Diesel Engine Oil, Professional paper, Fuels and Lubricants (Goriva i maziva), Vol. 43, No. 4, pp 291-309, 2004. https://hrcak.srce.hr/7174, accessed 08.10.2018.

[81] Fritz, S. G., Evaluation of Biodiesel Fuel in an EMD GP38-2 Locomotive, NREL

REPORT/PROJECT NUMBER: SR-510-33436, May 2004. https://www.nrel.gov/docs/fy04osti/33436.pdf, accessed 08.10.2018.

[82] Fritz, S. Pourabdollah, M., On Optimization of Plug-in Hybrid Electric Vehicles, Thesis for the Degree of Licentiate of Engineering, Department of Signals and Systems, Chalmers University of Technology, Göteborg, Sweden 2012. http://publications.lib.chalmers.se/records/fulltext/170631/170631.pdf, accessed 08.10.2018.

[83] Fritz, S., Pourabdollah, M., Murgovski, N., Grauers, A. and Egardt B., Optimal Sizing of a Parallel PHEV powertrain, IEEE Transactions on Vehicular Technology, Vol. 62, No. 6, pp 2469-2480, 2013. https://doi.org/10.1109/TVT.2013.2240326

[84] Pourabdollah, M., Murgovski, N., Grauers, A. and Egardt B., An iterative dynamic programming/convex optimization procedure for optimal sizing and energy management of PHEVs, 19th IFAC World Congress, Cape Town, South Africa. August, 2014. https://doi.org/10.3182/20140824-6-ZA-1003.02375

[85] Sarvi, A., Lyyränen, J., Jokiniemi J. and Zevenhoven, R., Particulate emissions from large-scale medium-speed diesel engines: 1. Particle size distribution, Fuel Processing Technology, Vol. 92, No. 10, pp 1855-1861, 2011. https://doi.org/10.1016/j.fuproc.2011.04.031

[86] Prime Mover EMD 645 – Data | Project Rail: https://projectrail.wordpress.com/2008/11/12/prime-mover-emd-645-data/ accessed 08.02.2020.

[87] Atlas Copco – QES generators, Catalogue, No. 2958 1060 02 – v02, 2017. https://www.atlascopco.com/content/dam/atlas-copco/construction-technique/portable-energy/documents/2_generators/mobile-diesel generator/QES%20mobile%20diesel%20generator%20english.pdf, accessed 08.10.2018.

[88] Dimitrova, Z. and Maréchal, F., Environomic design of vehicle integrated energy system –application on a hybrid electric vehicle energy system, Chemical Engineering Transaction, Vol. 39, pp 475-480, 2014. https://doi.org/10.3303/CET1439080

[89] Pichlík, P. and Zděnek, J., Overview of Slip Control Methods Used in Locomotives, Transactions on Electrical Engineering, Vol. 3, No. 2, pp 38-43, 2014.

[90] Lička željeznička pruga | Hrvatska enciklopedija: http://www.enciklopedija.hr/natuknica.aspx?id=36402, accessed 24.09.2018.

[91] Cipek, M., Pavković, D. and Petrić, J., A control-oriented simulation model of a power-split hybrid electric vehicle, Applied Energy, Vol. 101, pp 121-133, 2013. https://doi.org/10.1016/j.apenergy.2012.07.006

[92] Liu, J., and Peng, H., Modeling and Control of a Power-Split Hybrid Vehicle, IEEE Transactions on Control Systems Technology, Vol. 16, No. 6, pp 1242-1251, 2008. https://doi.org/10.1109/TCST.2008.919447

[93] Bin, Y., Li, Y. and Feng, N., Nonlinear dynamic battery model with boundary and scanning hysteresis, Proceedings of the ASME 2009 Dynamic Systems and Control Conference, No. DSCC2009-2745, Hollywood, California, USA, pp 245-251, 2009. https://doi.org/10.1115/DSCC2009-2745

[94] Besselink, I. J. M., Van Oorschot, P. F., Meinders, E. and Nijmeijer, H., 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, pp. 32-41, 2010.

[95] Mettlach, H., Development of the Li-Ion battery for the Opel Ampera Extended-Range Electric Vehicle, PPT on GM Alternative Propulsion Center - Europe Adam Opel GmbH, 3rd International Congress on Advanced battery Technology, Wiesbaden, June 22, 2010. http://www.selidori.com/tech/00000-04999/1072-WHAKu.pdf, accessed 08.10.2018.

[96] IRENA (2017), Electricity Storage and Renewables: Costs and Markets to 2030, International Renewable Energy Agency, Abu Dhabi, 2017. http://www.irena.org/-/media/Files/IRENA/Agency/Publication/2017/Oct/IRENA_Electricity_Storage_Costs_2017.pdf, accessed 08.10.2018.

[97] Steen, M., Lebedeva, N., Di Persio, F. and Boon-Brett, L., EU Competitiveness in Advanced Li-ion Batteries for E-Mobility and Stationary Storage Applications – Opportunities and Actions, JCR Science for Policy Report EUR 28837 EN, European Commission, 2017. https://doi.org/10.2760/75757

[98] Škugor, B., Deur, J., Cipek, M. and Pavković, D., Design of a power-split hybrid electric vehicle control system utilizing a rule-based controller and an equivalent consumption

minimization strategy, Proc IMechE Part D: J Automobile Engineering, Vol. 228, No. 6, pp 631–648, 2014. https://doi.org/10.1177/0954407013517220

[99] Cipek, M., Bitanga, P., Mlinarić, T.J., Pavković, D. and Kljaić, Z., Comparative Analysis of Conventional Diesel-electric and Hybrid-electric Heavy Haul Locomotive based on Mountain Rail Route Driving Scenario, Digital proceedings of 3rd South East Europe (SEE) Sustainable Development of Energy Water and Environment Systems (SDEWES) conference, Novi Sad, Vojvodina, Serbia, 2018.

[100] Finkel, D.E., Global Optimization with the DIRECT Algorithm, Dissertation, North Carolina State University, February, 2005. http://www.lib.ncsu.edu/resolver/

1840.16/4738, accessed 08.10.2018.

[101] Björkman, M. and Holmstrom, K., Global Optimization Using the DIRECT Algorithm in Matlab, AMO - Advanced Modeling and Optimization, Vol.1, No.2, pp 17-37, 1999.

[102] J. Cao and A. Emadi, Batteries need electronics – Battery management systems vary according to chemistry and applications, IEEE Industrial Electronics Magazine, Vol. 5, No 1, pp. 27-35, Mar. 2011.

[103] Pavković, D., Krznar, M., Komljenović, A., Hrgetić, M., Zorc, D. Dual EKF-based State and Parameter Estimator for a $LiFePO_4$ Battery Cell, Journal of Power Electronics, Vol. 17, No. 2 (2017): 398 – 410.

[104] Löbberding, H., Wessel, S., Offermanns, C., Kehrer, M., Rother, J., Heimes, H., and Kampker, A., From Cell to Battery System in BEVs: Analysis of System Packing Efficiency and Cell Types. World Electric Vehicle Journal. 2020; 11(4):77. https://doi.org/10.3390/wevj11040077

[105] Xing, Y., Ma, E.W.M., Tsui, K.L., and Pecht, M.. Battery Management Systems in Electric and Hybrid Vehicles. Energies. 2011; 4(11):1840-1857. https://doi.org/10.3390/en4111840

[106] Vučić, D., Lalić, D., Sustav automatske kontrole željezničkih vozila, Časopis Željeznice 21 - broj 1/2016, ISSN 1333-7971; UDK 625.1-6; 629.4; 656.2-4; GODINA 15, Broj 1, Zagreb, 2016.

[107] Commission Implementing Decision (EU) 2018/637, pan-European electronic communications services in the EU as regards relevant technical conditions for the Internet of Things, Official Journal of the European Union, L 105/27, April 2018.

[108] Tech - What is the difference between narrowband and wideband, Radiocrafts AS Norway, https://radiocrafts.com/kb/difference-narrowband-wideband/#, accessed 24.01.2020.

[109] Lavric, A., Petrariu, A. I., Popa, V., Long Range SigFox Communication Protocol Scalability Analysis Under Large-Scale, High-Density Conditions, IEEE Access, vol. 7, pp. 35816-35825, 2019, doi: 10.1109/ACCESS.2019.2903157.

[110] Essential Technical guide of Sigfox protocol: Network architecture, interfaces, protocol stack; SWA, https://www.survivingwithandroid.com/sigfox-protocol-network-architecture-iot-protocol-stack/, accessed 12.02.2020.

[111] LoRa- Long Range Network and Protocol Architecture & Frame Structure; October 2018, https://www.techplayon.com/lora-long-range-network-architecture-protocol-architecture-and-frame-formats; accessed 14.02.2020.

[112] Narrowband – Internet of Things (NB-IoT), GSM Association, https://www.gsma.com/iot/narrow-band-internet-of-things-nb-iot/,accessed 08.10.2019.

[113] Baldini, G., Barboni, M., Duch Brown, N., Digital Transformation in Transport, Construction, Energy, Government and Public Administration, Desruelle, P. editors, EUR 29782 EN, Publications Office of the European Union, Luxembourg, 2019, ISBN 978-92-76-08614-7, doi:10.2760/058696, JRC116179.

[114] Industrial Internet Consortium. The industrial internet of things, reference architecture. January 2017. https://www.iiconsortium.org/vertical-markets/transportation.htm, accessed 24.02.2021.

[115] DIN specification 91345, reference architecture model industrie 4.0 (RAMI4.0), English translation. April 2016. https://www.din.de/en/about-standards/din-spec-en/current-din-specs/wdc-beuth:din21:250940128, accessed 21.10.2019.

[116] Third Generation Partnership Project, Technical Report 37.910, v1.1.0. Study on self evaluation towards IMT-2020 submission, December 2018.

[117] NB-IoT networks coverage in Europe, IoT Creators by Deutsche Telekom IoT GmbH, https://iotcreators.com/en/coverage-eu/, accessed 17.02.2021.

[118] Third Generation Partnership Project, Technical Report 45.820, v13.0.0. Cellular system support for ultra-low complexity and low throughput internet of things, 2016.

[119] Third Generation Partnership Project, Technical Report 38.913, v14.1.0. Study on scenarios and requirements for next generation access technologies, 2016.

[120] Luthra, M., Atri, R., Sadeghian, M., Rekhi, P., Long Term Evolution for IoT, Maharshi Dayanand University, Delhi rd, IN, 2016.

[121] Proakis, J. G. and Salehi, M., Digital Communications (5th ed.), McGraw-Hill Co. Inc., New York, USA, 2008.

[122] Elo, M., Orthogonal Frequency Division Multiplexing, Keithley Instruments Inc., Cleveland, Ohio, USA, 2008.

[123] Lindner, D. K., Introduction to Signals and Systems, McGraw-Hill Co. Inc., Boston, Massachusetts, USA, 1999.

[124] Matlab Software, http://www.mathworks.com/products/communications.html,accessed: 20.04.2020.

[125] Brajdić, I., Vrednovanje anketnih upitnika sa stajališta ispitanika menadžera u turizmu, Tourism and hospitality management, 8(1-2), 2002. str. 65-78.

[126] Zelenika, R., Metodologija i tehnologija izrade znastvenog i stručnog djela, 4 izdanje, Ekonomski fakultet Sveučilišta u Rijeci, 2000.

[127] Mužić, V., Uvod u metodologiju istraživanja odgoja i obrazovanja, 2. izmijenjeno i dopunjeno izdanje. 2002, Zagreb: Educa, str.90.-91.

[128] Donna J. Peuquet & Niu Duan (1995) An event-based spatiotemporal data model (ESTDM) for temporal analysis of geographical data, International Journal of Geographical Information Systems, 9:1, 7-24, DOI: 10.1080/02693799508902022

[129] Renolen, A., History graphs: Conceptual modeling of spatio-temporal data. GIS Front. Bus. Sci. 1996.

[130] LibreOffice Help – XML Data, https://help.libreoffice.org/latest/lo/text/scalc/01/xml_source.html pristupljeno: 20.05.2020.

[131] Pljusak - poveznica na podatke: https://pljusak.com/trenutno-vrijeme-tablica.php, pristupljeno: 21.05.2020.

[132] Ross TJ. Fuzzy Logic with Engineering Applications. Chichester, UK: John Wiley & Sons; 2004.

[133] Kljaić, Zdenko; Mlinarić, Tomislav-Josip; Pavković, Danijel; Cipek, Mihael; Nikšić, Mladen: „Fuzzy logic-based scheduling of rail vehicles under reduced traffic flow conditions“, Proceedings of 27th Telecommunications Forum TELFOR 2019, Beograd, Serbia, 2019. Paper No. 4484.

[134] Škrobonja, D., Beraković, T., Božunović, A., Ljubaj, Z. and Ljubaj, N., Applicative Monitoring of Locomotive Diesel Engine Oil, Professional paper, Fuels and Lubricants (Goriva i maziva), Vol. 43, No. 4, pp 291-309, 2004. https://hrcak.srce.hr/7174, accessed 08.10.2018.

[135] Ecker, M., Gerschler, J.B., Vogel, J., Käbitz, S., Hust F. Dechent, P. and Sauer, D.U., Development of a lifetime prediction model for lithium-ion batteries based on extended accelerated aging test data, Journal of Power Sources, Vol. 215, pp 248-257, 2012. https://doi.org/10.1016/j.jpowsour.2012.05.012

[136] Croatia - the trend in gasoline prices: https://autotraveler.ru/en/croatia/trend-price-fuel-croatia.html, accessed 24.09.2018

[137] Cipek, Mihael; Pavković, Danijel; Kljaić, Zdenko; Mlinarić, Tomislav Josip. Hypothetical Conversion and Modernization of a Conventional Heavy Haul Diesel-electric Locomotive to its Battery Counterpart. // Digital proceedings of 4th South East Europe (SEE) Sustainable Development of Energy Water and Environment Systems (SDEWES) conference, Sarajevo, Bosnia and Herzegovina, 2020. 18 pages

[138] Sun, Y., Cole, C., Spiryagin, M., Godber, T., Hames, S. and Rasul, M., Conceptual designs of hybrid locomotives for application as heavy haul trains on typical track lines, Proc IMechE Part F:J Rail and Rapid Transit, Vol. 227, No.5, pp 439-452, 2013. https://doi.org/10.1177/0954409713501655

[139] Pavković, D., Sedić, A., and Guzović, Z., Oil Drilling Rig Diesel Power-plant Fuel Efficiency Improvement Potentials through Rule-Based Generator Scheduling and Utilization of Battery Energy Storage System, Energy Conversion and Management, Vol. 121, pp 194 – 211, 2016. https://doi.org/10.1016/j.enconman.2016.05.022

[140] Škrobonja, D., Beraković, T., Božunović, A., Ljubaj, Z. and Ljubaj, N., Applicative Monitoring of Locomotive Diesel Engine Oil, Professional paper, Fuels and Lubricants (Goriva i maziva), Vol. 43, No. 4, pp 291-309, 2004. https://hrcak.srce.hr/7174, accessed 08.10.2018.

[141] Technical report: Cambridge Systematics, Inc., prepared for Southern California Association of Governments, Task 8: Analysis of Freight Rail Electrification in the SCAG Region, April 2012. http://www.freightworks.org/DocumentLibrary/CRGMSAIS%20%20Analysis%20of%20Freight%20Rail%20Electrification%20in%20the%20SCAG%20Region.pdf, accessed 08.10.2018.

[142] CN to buy 200 locomotives from GE as freight volumes surge - The Globe and Mail: https://www.theglobeandmail.com/report-on-business/cn-to-buy-200-locomotives-from-ge-as-freight-volumes-surge/article37418466/, accessed 24.09.2018.

[143] Electricity prices for non-household consumers, https://ec.europa.eu/eurostat/statistics-explained/index.php/Electricity_price_statistics#Electricity_prices_for_non-household_consumers, accessed: 14.02.2020.

POPIS TABLICA

Tablica 1. Željeznički incidenti povezani s vremenskim uvjetima 1995.-2005. USA [55].....24

Tablica 2. Eksperimentalni podaci lokomotive GP38-2 [81].....44

Tablica 3. Približni podaci za G26CW dizel-električnu lokomotivu.....50

Tablica 4. Parametri Li-Ion baterijske ćelije i predloženog baterijskog sustava za pohranu energije 57

Tablica 5. Podaci za umanjeni glavni motor i generator (agregat) 59

Tablica 6. Parametri SoC regulatora baterijsko-hibridne lokomotive 62

Tablica 7. Li-Ion ćelija i baterija i ukupni za baterijsku električnu lokomotivu.....66

Tablica 8. Prikaz odgovora ispitanika u Hrvatskoj na prvo pitanje u anketnom upitniku.....79

Tablica 9. Prikaz odgovora ispitanika u Hrvatskoj na drugo pitanje u anketnom upitniku. 79

Tablica 10. Prikaz odgovora ispitanika u Hrvatskoj na treće pitanje u anketnom upitniku. 80

Tablica 11. Prikaz odgovora ispitanika van Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na prvo pitanje u anketnom upitniku. 82

Tablica 12. Prikaz odgovora ispitanika van Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na drugo pitanje u anketnom upitniku. 82

Tablica 13. Prikaz odgovora ispitanika van Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na treće pitanje u anketnom upitniku. 83

Tablica 14. Rezultati simulacije za različita opterećenja i različite parametre SoC regulatora.....98

Tablica 15. Usporedni podaci o potrošnji goriva u simulaciji kružne vozne misije 99

Tablica 16. Trošak goriva za jednu vožnju i kumulativna potrošnja goriva za više od 2000 vožnji.....116

Tablica 17. Usporedni troškovi konvencionalnih i baterijsko-hibridnih dizel-električnih lokomotiva.....116

Tablica 18. Usporedni rezultati emisija ispušnih plinova u simulaciji 116

Tablica 19. Ukupni troškovi goriva i električne energije tijekom 2000 ciklusa.....117

Tablica 20. Sažetak procjene troškova.....118

POPIS SLIKA

Slika 1. Testiranje 5G autonomnih željezničkih vozila na trasi „Osong Railway“ SK [32] 12
Slika 2. U gradu Zhuzhou prometuju autonomni vlakovi sa virualnim tračnicama i senzorskom podrškom (engl. Autonomous Rail Rapid Transit - ART) [33]..... 14
Slika 3. Model upravljanja autonomnim prometnim entitetom sa podrškom senzorskih mreža [36] 15
Slika 4. Model pozicioniranja temeljenog na 5G tehnologiji za autonomne vlakove velikih brzina (400 km/h) s točnošću od 1 m i vremenskim intervalima od 5 milisekundi. [40]. 17
Slika 5. Karakteristike senzorskih mreža za masivne i kritičke aplikacije interneta stvari [43]...... 19
Slika 6. Projekt „5G - Connected Mobility“ u partnerstvu Deutsche Bahn i Ericsson - testiranje senzorskih sustava temeljenih na 5G tehnologijama na brzoj željezničkoj pruzi između Nürnberga-Feuchta i Gredinga u Bavarskoj, Njemačka, [49]...... 20
Slika 7. Željeznički kolodvor - testiranje komunikacijskih i senzorskih sustava temeljenih na 5G tehnologijama, Deutsche Bahn - Njemačka [51]. 21
Slika 8. „Advanced TrainLab“-Deutsche Bahn-ov istraživački vlak (ICE TD klase 605) s hibridnom dizel-električnom pogonom opremljen naprednim komunikacijskim i senzorskim sustavima [53]...... 22
Slika 9. Željeznički prometni incidenti povezani s vremenskim uvjetima po mjesecima u godini i prema najčešćim vrstama uzročnih događaja po mjesecima u periodu 1995.-2005. USA [55]. 25
Slika 10. Ukupan broj željezničkih incidenata povezanih s vremenom po satima u danu i po najčešćim vrstama uzročnih događaja po satima u danima, 1995.-2005. USA [55]. 26
Slika 11. Krivulje maksimalne vučne sile u odnosu na brzinu s položajem akceleratora ('Notch') i adhezijom između kotača i tračnica kao parametrima [56]. 27
Slika 12. Ovisnost koeficijenta trenja o relativnoj vlažnosti zraka [58]...... 28
Slika 13. Ovisnost koeficijenta trenja o apsolutnoj vlažnosti zraka [58]...... 28
Slika 14. Trend povećanja temperaturnih anomalija od 1880 god. – NASA, GISS Institute, Columbia University, New York, SAD [60]. 29
Slika 15. Zbog iznenadnih olujnih naleta vjetra i poplave zaustavljanje prometovanja vlaka na trasi Totnesa – Plymoutha, UK [61]...... 30
Slika 16. Stadler „FLIRT Akku“ vlak na baterijski pogon za željezničke rute bez emisije CO_2 [63] 31
Slika 17. Prikaz blokovskog dijagrama sustava za upravljanje prometom temeljenog na neizrazitoj logici za slučaj zapreke na jednoj jednosmjernoj prometnoj trasi [69]...... 35
Slika 18. Funkcije pripadnosti neizrazitog regulatora s obzirom na signal razlike reda čekanja [69]. 36
Slika 19. Funkcije pripadnosti neizrazitog regulatora s obzirom na njegovu vremensku diferenciju [69]. 36

Slika 20. Solitoni u izlaznom skupu pravila pripadnosti neizrazitog regulatora [69]. 37
Slika 21. Rezultati dobiveni s konvencionalnim regulatorom (a) i neizrazitim regulatorom (b) za normalnu vjerojatnosnu distribuciju vremena dolazaka vozila [69]. 38
Slika 22. Službeno dostupni pojednostavljeni profil [70], nadmorske visine (a), profil visine generiran iz softvera GPS visualizer (b), profil ograničenja brzine (c) i geografska karta razmatrane željezničke rute (d). 39
Slika 23. Nadmorska visina, trakcijski koeficijent, brzina vjetra i profili ograničenja brzine vlaka za trasu razmotrenu u ovom radu. 42
Slika 24. Pojednostavljeni shematski prikaz pogonskog sklopa dizel-električne lokomotive [75]. 43
Slika 25. Snaga lokomotive u odnosu na položaj poluge akceleratora (a) i učinkovitost pretvorbe električne energije (b). 45
Slika 26. Koeficijenti polinomske aproksimacije u ovisnosti o kutnoj brzini motora (a), mapa trenutne potrošnja goriva u g/s (b) i specifična potrošnja goriva izražena u g/kWh (c). 47
Slika 27. Normalizirane emisije ispušnih plinova lokomotive za (a) ugljikovodike (HC), (b) ugljik-monoksid (CO), (c) dušikove okside (NO_X) i (d) ugljik-dioksid (CO_2). 48
Slika 28. Statičke mape maksimalne vučne sile (a) i maksimalne snage (b) sustava vuče. 52
Slika 29. Blokovski dijagram kvazi-statičkog modela vlaka s modelom strojovođe (vozača) koji upravlja konvencionalnom dizel-električnom lokomotivom. 54
Slika 30. Model ekvivalentnog strujnog kruga baterije (a), napon otvorenog kruga u odnosu na stanje napunjenosti (b) i unutarnji otpor u odnosu na stanje napunjenosti i smjer struje (c). 56
Slika 31. Blokovski dijagram kvazi-statičkog modela predložene baterijsko-hibridne lokomotive. 60
Slika 32. Blokovski dijagram kvazistatičkog modela baterijsko-električne lokomotive. 63
Slika 33. Blokovski dijagram dinamičkog modela baterije temeljenog na tokovima snage koji je pogodan za simulacijske analize. 64
Slika 34. Senzorska mjerna postaja za nadzor gabarita željezničkih vozila [106]. 67
Slika 35. Induktivni senzori detekcije kotača željezničkih vozila prema standardu CENELEC SIL 4 [106]. 68
Slika 36. Sigfox format komunikacijskog okvira na MAC razini [110]. 70
Slika 37. Stanično pokrivanje NB-IoT (LTE opseg 20) u Hrvatskoj [117]. 72
Slika 38. Prikaz baznih stanica LTE B20 (NB-IoT) – zeleno označene točke i polja radio pokrivanja ljubičasta boja, te svjetlo plavim označena testna dionica željezničke pruge: Oštarije (početak Ličke pruge) - Lički Podhum. 73
Slika 39. Arhitektura senzorske mreže NarrowBand - LTE (B20), prilagođeno [120]. 74
Slika 40. Blokovski prikaz veze jednog elementa NB IoT mreže udaljenih senzora s zahtjevanom bazom podataka o adheziji na kolosijeku i čeonom vjetru 75
Slika 41. Blokovski dijagram integriranog simulacijskog modela koji obuhvaća teretni vlak i strojovođu, mrežu udaljenih inteligentnih senzora i podmodele za razmjenu podataka o stanju pruge na istraživanoj trasi. 76

Slika 42. Prikaz distribucije odgovora ispitanika u Hrvatskoj na prvo pitanje u anketnom upitniku. 80
Slika 43. Prikaz distribucije odgovora ispitanika u Hrvatskoj na drugo pitanje u anketnom upitniku. 80
Slika 44. Prikaz distribucije odgovora ispitanika u Hrvatskoj na treće pitanje u anketnom upitniku. 81
Slika 45. Grafički prikaz odgovora ispitanika u postotcima u Hrvatskoj na prvo pitanje u anketnom upitniku. 81
Slika 46. Grafički prikaz odgovora ispitanika u postotcima u Hrvatskoj na drugo pitanje u anketnom upitniku. 81
Slika 47. Grafički prikaz odgovora ispitanika u postotcima u Hrvatskoj na treće pitanje u anketnom upitniku. 82
Slika 48. Prikaz distribucije odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na prvo pitanje u anketnom upitniku. 83
Slika 49. Prikaz distribucije odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na drugo pitanje u anketnom upitniku. 83
Slika 50. Prikaz distribucije odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) na treće pitanje u anketnom upitniku. 84
Slika 51. Grafički prikaz odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) u postotcima na prvo pitanje u anketnom upitniku. 84
Slika 52. Grafički prikaz odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) u postotcima na drugo pitanje u anketnom upitniku. 84
Slika 53. Grafički prikaz odgovora ispitanika izvan Hrvatske (Poljska, Švedska, Nizozemska, Austrija, BiH, Slovenija) u postotcima na treće pitanje u anketnom upitniku. 85
Slika 54. Testiranje, kalibracija i prikupljanje podataka mjerenja temperature i vlažnosti preko uskopojasnih NB-IoT senzora (engl. NarrowBand IoT) u Ericssonovom laboratoriju. 86
Slika 55. Izvorni DHZM podaci iz baze podataka. 87
Slika 56. Mjerne pozicije mreze Pljusak 88
Slika 57. Mjerni podaci mreze Pljusak..... 89
Slika 58. Blokovski prikaz algoritma klasifikatora stanja trase primjenom neizrazite logike. 90
Slika 59. Funkcije pripadnosti neizrazitog klasifikatora s obzirom na temperaturu (a) i apsolutnu vlažnost (b), te solitoni u izlaznom skupu pravila (c). 92
Slika 60. Profil nadmorske visine za predloženi scenarij vožnje (a), komande strojovođe (b) i profili brzine vlaka (c). 93
Slika 61. Snaga električne transmisije (sustava vuče) lokomotive i kumulativna potrošnja goriva (a), utrošena električna energija (b) i potencijal povrata energije (c). 95
Slika 62. Prikaz razlike u postignutim brzinama vlaka između konvencionalne i baterijsko-hibridne lokomotive. 96
Slika 63. SoC varijabla baterije za slučaj konstantne SoC reference (a) i korištenje adaptivne SoC reference (b), te usporedna kumulativna potrošnja goriva baterijsko-hibridne i konvencionalne lokomotive (c). 97

Slika 64. Domet pogona baterijsko-električne lokomotive sa 7 potpuno opterećenih vagona bez i sa redukcije Notch komande akceleratora: profili brzine (a), „Notch“ komanda (b) i SoC baterije (c). 100
Slika 65. Domet vlaka s baterijsko-električnom lokomotivom za različito opterećenje (broj potpuno opterećenih vagona) i različite nagibe trase (a), te za različite brzine vožnje (b)… 101
Slika 66. Usporedba konvencionalne kompozicije i tandemskog rada s baterijsko-električnom lokomotivom: (a) profili brzine (b) kumulativna potrošnja goriva i (c) SoC baterije i nadmorska visina rute. 103
Slika 67. Rezultati za različite konfiguracije lokomotiva: (a) vrijeme putovanja, (b) potrošnja goriva i (c) potrošena električna energija. 105
Slika 68. Blokovski dijagram toka predložene metodologije za povećanje energetske učinkovitosti i sigurnosti željezničkog transporta. 106
Slika 69. Blokovski dijagram modela baterijsko-hibridne i dizel-električne lokomotive (a) i pod-modela sustava električne vuče (b) te toka informacija (c) 107
Slika 70. Komande koje zadaje model strojovođe 111
Slika 71. Brzina vlaka s obzirom na prijeđenu udaljenost (a) i s obzirom na vrijeme (b) 112
Slika 72. Usporedna kumulativna potrošnja goriva lokomotive (a) i prikaz SoC varijable (b) za različite nadređene strategije upravljanja lokomotivom. 112
Slika 73. Troškovi za različite konfiguracije: (a) gorivo, (b) električna energija i (c) ukupni trošak. 119
Slika 74. Procijenjeno trajanje vozne misije vlaka za početni segment (50 km) željezničke pruge pri promjenjivim uvjeta na kolosijeku. 121
Slika 75. Trodimenzionalni prikaz (a) i parametarski prikaz (b) koeficijenta trenja u simulaciji s obzirom na promjene temperature i apsolutne vlažnosti zraka. 122
Slika 76. Temperatura i apsolutna vlažnost zraka u simulaciji vozne misije vlaka u funkciji pozicije vlaka na trasi (prijeđenog puta) i rezultirajuća klasifikacija primjenom neizrazite logike u usporedbi sa stvarnim koeficijentoim adhezije. 124
Slika 77. Nadmorska visina, adhezija i čeoni vjetar u funkciji prijeđenog puta kompozicije. 124
Slika 78. Profili brzine vlaka za slučaj kada strojovođa nema, odnosno ima informaciju o stanju trase na temelju neizrazitog klasifikatora. 125

ŽIVOTOPIS

Zdenko Kljaić rođen je 1970. godine u Sisku, Republika Hrvatska. Srednju školu završio je u Sisku, Tehnička škola Sisak, elektrotehnički smjer, usmjerenje elektro strojarstvo i automatizacija. Studirao je na Zagrebačkom sveučilištu i TU Beč i stekao je zvanje diplomirani inženjer prometa i diplomirani inženjer elektrotehnike (njem. Diplom Ingenieur Studienrichtung Elektrotechnik, Studienzweig Nachrichten und Informationstechnik). Na Ekonomskom fakultetu u Zagrebu je nastavio školovanje na Poslijediplomskom studiju Informatički management. Pri Ministarstvu zaštite okoliša, prostornog uređenja i graditeljstva RH, 1998 god. položio je stručni ispit za obavljanje poslova s ovlaštenjem u području prostornog uređenja i graditeljstva (lic.132-04/98-01/512). U Hrvatskoj komori inženjera tehnologije prometa i transporta položio je stručni ispit „ovlaštenog inženjera“ iz područja informacijsko-komunikacijskog prometa i poštanskog prometa 2011. godine. Tijekom stručnog usavršavanja pohađao je niz certifikacijskih tečajeva u području organizacijskog i projektnog upravljanja. 1997 god. počeo je rad u tvrtci Ardor - Consulting & Engineering na poslovima projektiranja, a kasnije poslovnog savjetovanja. Radio je u Austriji i Hrvatskoj. Značajni projekti u kojima je sudjelovao u projektiranju su: Pogon za proizvodnju Azitromicina - Pliva, S.M.; Istraživački institut Plive, Zagreb. Od 2000. godine zaposlen je u tvrtci Ericsson Nikola Tesla d.d. kao projektant, a kasnije napreduje kao domenski ekspert za područje digitalizacije prometno transportnih sustava i pametnih gradova.

Bio je član uprave Inteligentni transportni sustavi Hrvatske, a od 2021 je član uprave Hrvatske komore inženjera tehnologije prometa i transporta. Sudjelovao je kao predavač na nizu seminara, tribina i međunarodnih konferencija iz područja: sigurnosti gradova, ICT u upravljanju kritičnom infrastrukturom, pametni gradovi s inteligentnom prometno/energetskom infrastrukturom, te digitalizacije prometnih sustava s ciljem uštede energije i smanjenja emisije CO_2.

Zdenko Kljaić je autor ili koautor četiri rada u značajnim znanstvenim časopisima s CC/SCI indeksima, 13 radova u zbornicima skupova s međunarodnom recenzijom, te niza studija i tehničkih izvješća. Njegov znanstveni rad pod nazivom: „Assessment of Railway Train Energy Efficiency and Safety Using Real-time Track Condition Information“, Journal of Sustainable Development of Energy, Water and Environment Systems (2020) doi:10.13044/j.sdewes.d8.0352; je među izabranim radova Znanstvenog vijeća za promet (HAZU), izdan u Ljetopisu Hrvatske akademije za godinu 2020.

CURRICULUM VITAE

Zdenko Kljaić was born in 1970 in Sisak, Republic of Croatia. He finished high school in Sisak, Technical School Sisak, electrical engineering, majoring in electrical engineering and automation. He studied at the University of Zagreb and the Technical University of Vienna and obtained a degree in traffic engineering and a degree in electrical engineering (Germ. Diplom Ingenieur Studienrichtung Elektrotechnik, Studienzweig Nachrichten und Informationstechnik). He continued his education at the Postgraduate Study of Informatics Management at the Faculty of Economics in Zagreb. At the Ministry of Environmental Protection, Physical Planning and Construction of the Republic of Croatia, in 1998 he passed the professional exam for performing activities with authorization in the field of physical planning and construction (lic.132-04 / 98-01 / 512). In the Croatian Chamber of Engineers of Traffic and Transport Technology, he passed the professional exam for a "certified engineer" in the field of information and communication traffic and postal traffic in 2011. During his professional training, he attended a number of certification courses in the field of organizational and project management. 1997 he started working in the company Ardor - Consulting & Engineering on project design jobs, and later on business consulting. He worked in Austria and Croatia. Significant projects in which he participated in the project design are: Azithromycin production plant - Pliva, S.M.; Pliva Research Institute, Zagreb. Since 2000 he has been employed by Ericsson Nikola Tesla d.d. as a designer, subsequently being advanced as a domain expert in the field of digitalization of transport systems and smart cities.

He was a member of the Management Board of the Intelligent Transport Systems of Croatia, and since 2021 he has been a member of the Management Board of the Croatian Chamber of Traffic and Transport Technology Engineers. He has participated as a lecturer in a number of seminars, forums and international conferences in the field of: city safety, ICT in critical infrastructure management, smart cities with intelligent transport/energy infrastructure, and digitalization of transport systems for energy savings and reduction of CO_2 emissions.

Zdenko Kljaić is the author or co-author of four papers in significant scientific journals indexed in CC/SCI databases, 13 papers in conference proceedings with international peer-review, and a number of studies and technical reports. His scientific paper entitled: “Assessment of Railway Train Energy Efficiency and Safety Using Real-time Track Condition Information”, Journal of Sustainable Development of Energy, Water and Environment Systems (2020) doi: 10.13044 / j.sdewes.d8.0352; is among the selected works of the Scientific Council for Transport (HAZU), published in the Annals of the Croatian Academy for the year 2020.

PRILOG 1. – ANKETNI UPITNIK NA HRVATSKOM JEZIKU

ANKETNI UPITNIK

Anketni upitnik za potrebe istraživanja kao dijela doktorske disertacije naslovljene „Model za unaprjeđenje energetske učinkovitosti i prometne sigurnosti željezničkog prijevoza primjenom naprednih pogonskih tehnologija i udaljenih uskopojasnih senzorskih mreža“

Doktorand Zdenko Kljaić, dipl.ing.el./dipl.ing.prom. provodi istraživanje u sklopu izrade doktorske disertacije na Fakultetu prometnih znanosti, Sveučilišta u Zagrebu.

Disertacija ima za cilj razraditi cjelovit i sistematičan pristup, te definirati uspješan model hibridnog pogona željezničkog prometnog entiteta podržanog informacijama iz udaljenih uskopojasnih senzorskih mreža male potrošnje energije, a s ciljem postizanja energetske učinkovitosti i sigurnosti željezničkog prometovanja.

Znanstvena hipoteza istraživanja je da se uspješnost strategije upravljanja željezničkog prometnog entiteta s hibridnim pogonom može povećati prema kriteriju energetske učinkovitosti i prometne sigurnosti ako se u određenom vremenskom odsječku tijekom vozne misije, dodaju strukturirane informacije temeljene na ekspertnom znanju iz udaljenih senzorskih mreža.

Cilj anketnog istraživanja jest definirati vrijednosne odnose između geoprostornih okolišnih informacija iz senzorskih mreža i kritičnih parametara koji služe za korektivno upravljanje sustava ili u ekstremnim uvjetima sprječavanje prometnih akcidenata.

Zahvaljujem Vam na vremenu i sudjelovanju u istraživanju.

Napomena - Anketa je anonimna.
Prikupljeni podaci i mišljenja eksperata iz ankete biti će korišteni izričito u svrhu izrade doktorske disertacije. Svi odgovori će biti tretirani kao anonimni, te pojedina mišljenja neće biti prikazivana pojedinačno niti javno, već će podaci služiti kao alat pomoću kojeg se prikupljaju ulazni podaci za različite analize i statističke pokazatelje.

Anketni upitnik sadrži pitanja koji uključuju ulazne parametre i vrijednosti pokazatelja, definirane na način da obuhvate karakteristične vrijednosti, iz unaprijed definiranih raspona, kao i predloženi postupak za procjenu, koji je temeljen na saznanjima iz postojeće znanstvene literature i istraživanja.
Molim vas da temeljem vlastite ekspertne procijene svakom pitanju pridijelite odgovarajuću vrijednost zaokruživanjem ponuđenih odgovora ili ako prema vašoj procijeni ponuđeni odgovori ne zadovoljavaju, dopišite odgovor na prazan prostor na dnu pitanja. Ako pitanje nije u području vašeg ekspertnog znanja, molim vas naznačite to u danom pitanju.

ANKETNA PITANJA:

► 1. Zaokružite četiri okolišna parametra koji najviše utječu na željeznički promet prema kriteriju energetske učinkovitosti i sigurnosti na brdsko-planinskim prugama Hrvatskih željeznica kroz vremenski period meteorološke godine dana.

a.) temperatura okoline prometne infrastrukture

b.) vlažnost okoline prometne infrastrukture

c.) vjetar

d.) visina snježnog pokrivača

e.) količina padalina (kiša)

f.) magla

g.) osvijetljenost prometne infrastrukture

h.) lišće i biološki nanosi na tračnicama

i.) nečistoće na tračnicama u smislu sitnog zemljanog konglomerata

j.) poplava tračnica

k.) potres na području prolaska željezničke infrastrukture

l.) bujanje vegetacije u okolici prometne infrastrukture

m.) UV zračenje

n.) pitanje nije u mojem području ekspertize

o.) napišite odgovor ili komentar, ako nije ponuđen iznad

_____

► 2. Zaokružite dva odgovora, kao prijedlog najprikladnijeg algoritama za opisivanje parametara utjecaja okoline na željeznički promet

a.) sustavi neizrazite (fuzzy) logike

b.) genetski algoritmi

c.) umjetne neuronske mreže

d.) ekspertni sustavi

e.) sustavi strojnog učenja

f.) pitanje nije u mojem području ekspertize

g.) napišite odgovor ili komentar, ako nije ponuđen iznad

_____

► 3. Zaokružite dva odgovora koji najbolje indiciraju potencijalno opasne uvjete na željezničkoj infrastrukturi, a prema kriteriju optimizacije ulaznih parametara i izlazne korisnosti indeksa za uspješno upravljanje voznim misijama željezničke kompozicije

a.) visoka apsolutna vlažnost zraka (> 15 g/m^3) i srednje visoka temperatura zraka (> 20 °C)

b.) niska apsolutna vlažnost zraka (< 5 g/m^3) i srednje visoka temperatura zraka (> 20 °C)

c.) visoka apsolutna vlažnost zraka (> 15 g/m^3) i niska temperatura zraka (< 2 °C)

d.) niska apsolutna vlažnost zraka (< 5 g/m^3) i niska temperatura zraka (< 2 °C)

e.) visoka temperatura zraka (> 40 °C), bez obzira na vlažnost zraka

f.) pitanje nije u mojem području ekspertize

g.) napišite odgovor ili komentar, ako nije ponuđen iznad

_____

PRILOG 2. – ANKETNI UPITNIK NA ENGLESKOM JEZIKU

QUESTIONNAIRE

Questionnaire for the purpose of research as a part of the doctoral thesis titled "Model for improving energy efficiency and traffic safety of railway transport using advanced propulsion technologies and remote narrowband sensor networks"

Doctoral student Zdenko Kljaic, mag.ing.el./mag.ing.traff. is conducting research as an integral part of the preparation of his doctoral dissertation at the Faculty of Transport and Traffic Sciences, University of Zagreb.

The dissertation aims to develop a comprehensive and systematic approach, and to define an efficient model of hybrid propulsion of a railway transport entity supported by information from low energy consumption remote narrowband sensor networks, with the aim of achieving energy efficiency and safety of railway traffic.

The scientific hypothesis of the research is that the effectiveness of the management strategy of a hybrid railway transport entity can be increased according to the criteria of energy efficiency and traffic safety if structured information based on expert knowledge from remote sensor networks is included within the particular time frame during the driving mission.

The aim of the survey is to define the value relationships between geospatial environmental information from sensor networks and critical parameters that serve for corrective system management or in extreme conditions to prevent traffic accidents.

Thank you for your time and participation in the research.

Note - This survey is anonymous.

The collected data and opinions of experts from the survey will be used explicitly for the purpose of preparing the said doctoral dissertation. All responses will be treated as anonymous, and individual opinions will not be presented individually or publicly, but the data will serve as a tool to collect input data for various analyzes and statistical indicators.

This survey questionnaire contains questions that include input parameters and indicator values, defined in a way that includes characteristic values, from predefined ranges, as well as a proposed assessment procedure, based on knowledge from the existing scientific literature and research.
Please, based on your own expert assessment, assign an appropriate value to each question by circling the offered answers, or if, according to your assessment, the offered answers are not satisfactory, write the answer in the blank space at the bottom of the question. If the question is not in your area of expertise, please indicate this for the particular question.

SURVEY QUESTIONS:

► 1. Encircle the four environmental parameters that have the greatest impact on railway traffic according to the criteria of energy efficiency and safety on the mountain railways of the Croatian Railways over a period of one meteorological year.

a.) ambient temperature of the transport infrastructure

b.) humidity of the transport infrastructure environment

c.) wind

d.) depth of the snow cover

e.) amount of precipitation (rain)

f.) fog

g.) illumination of transport infrastructure

h.) leaves and biological deposits/residue on rails

i.) impurities on the rails in terms of a fine earth conglomerate

j.) flooding of rails

k.) earthquake in the area of railway infrastructure passage

l.) growth of vegetation in the vicinity of transport infrastructure

m.) UV radiation

n.) this question is not within my area of expertise

o.) write your own response or comment, if not offered above

_____

► 2. Encircle the two answers, as a proposal of the most appropriate algorithm for describing the parameters of environmental impact on the railway traffic

a.) fuzzy logic systems

b.) genetic (evolutionary) algorithms

c.) artificial neural networks

d.) expert systems

e.) machine learning

f.) this question is not within my area of expertise

g.) write your own response or comment, if not offered above

_____

► 3. Encircle the two answers that best indicate the potentially dangerous conditions on the railway infrastructure according to the criteria of optimization of input parameters and output utility of the index for successful management of railway train driving missions

a.) high absolute humidity (> 15 g/m^3) and medium-high air temperature (> 20 °C)

b.) low absolute humidity (<5 g/m^3) and medium-high air temperature (> 20 °C)

c.) high absolute humidity (> 15 g/m^3) and low air temperature (<2 °C)

d.) low absolute humidity (<5 g/m^3) and low air temperature (<2 °C)

e.) high air temperature (> 40 °C), regardless of humidity

f.) this question is not within my area of expertise

g.) write your own response or comment, if not offered above

_____