

Energetski učinkovito usmjeravanje okretnog momenta na električna vozila s izravnim pogonom na četiri kotača korištenjem algoritma strojnog učenja

Šibenik, Lovro

Undergraduate thesis / Završni rad

2024

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

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:452492>

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

Download date / Datum preuzimanja: **2024-10-20**

Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Lovro Šibenik

Zagreb, 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentor:

Doc. dr. sc. Branimir Škugor, mag. ing.

Student:

Lovro Šibenik

Zagreb, 2024.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se svom mentoru, doc. dr. sc. Branimiru Škugoru, na stručnoj pomoći i podršci koju mi je pružio tijekom pisanja ovog završnog rada. Te vještine i znanja bile su od neprocjenjive vrijednosti i omogućile su mi da uspješno i kvalitetno obradim zadanu temu i napišem ovaj rad.

Lovro Šibenik



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne i diplomske ispite studija mehatronika i robotika



| | |
|-------------------------------------|--------|
| Sveučilište u Zagrebu | |
| Fakultet strojarstva i brodogradnje | |
| Datum | Prilog |
| Klasa: 602 – 04 / 24 – 06 / 1 | |
| Ur.broj: 15 – 24 – | |

ZAVRŠNI ZADATAK

Student: **Lovro Šibenik** JMBAG: **0035239806**

Naslov rada na hrvatskom jeziku: **Energetski učinkovito usmjeravanje okretnog momenta za električna vozila s izravnim pogonom na četiri kotača korištenjem algoritma strojnog učenja**

Naslov rada na engleskom jeziku: **Energy efficient torque vectoring for electric vehicles with direct four-wheel drive based on machine learning**

Opis zadatka:

Pogoni električnih vozila (EV) opremljeni s više električnih motora uvode određenu fleksibilnost u ostvarivanju ukupnog traženog momenta na kotačima, koja se može eksploatirati optimalnom raspodjelom momenta po pojedinačnim motorima u svrhu smanjenja ukupne potrošnje energije iz baterije. Uparivanje motora s kandžastim spojka omogućava njihovo mehaničko odvajanje od kotača, te na taj način izbjegavanje gubitaka praznog hoda kad su ti motori deaktivirani od strane upravljačke strategije pogona. Stoga se pred upravljačku strategiju osim raspodjele momenta po pojedinačnim motorima stavlja zahtjev i na određivanje optimalnog stanja spojki u svakom koraku uzorkovanja.

U sklopu završnog rada potrebno je:

- 1) provesti pregled literature na temu energetski učinkovite raspodjele momenta u pogonima EV opremljenih s više motora
- 2) proučiti postojeći model pogona, te tehniku optimiranja upravljačkih varijabli EV pogona van realnog vremena korištenjem algoritma dinamičkog programiranja (DP)
- 3) provesti statičko optimiranje raspodjele momenta preko širokog raspona brzine vozila i traženog ukupnog momenta na kotačima te pohrana dobivenih rezultata u vidu ogledne tablice
- 4) formulirati problem određivanja referentnog stanja spojki kao binarni logistički regresijski problem
- 5) provesti učenje modela zasnovanog na binarnoj logističkoj regresiji korištenjem rezultata DP optimiranja preko širokog skupa voznih ciklusa
- 6) provesti simulacijsku provjeru dobivene upravljačke strategije pogona EV temeljene na navedenom modelu i oglednoj tablici, te njena usporedba s globalno optimalnim DP rezultatima u smislu ukupne potrošnje električne energije te broja promjena stanja spojki.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

| | | |
|----------------|---|--|
| Zadatak zadan: | Datum predaje rada: | Predviđeni datumi obrane: |
| 24. 4. 2024. | 2. rok (izvanredni): 11. 7. 2024. 3. rok: 19. i 20. 9. 2024. | 2. rok (izvanredni): 15. 7. 2024. 3. rok: 23. 9. – 27. 9. 2024. |

Zadatak zadao:

doc. dr. sc. Branimir Škugor

Predsjednik Povjerenstva:

izv. prof. dr. sc. Petar Čurković

SADRŽAJ

| | |
|--|-----|
| SADRŽAJ | I |
| POPIS SLIKA | II |
| POPIS OZNAKA | III |
| POPIS KRATICA | V |
| SAŽETAK..... | VI |
| SUMMARY | VII |
| 1. UVOD..... | 1 |
| 2. MODELIRANJE EV POGONA | 5 |
| 3. OPTIMIRANJE UPRAVLJAČKIH VARIJABLI EV POGONA VAN REALNOG VREMENA..... | 8 |
| 4. OPTIMALNO USMJERAVANJE MOMENTA U STVARNOM VREMENU | 10 |
| 4.1. Koncept | 10 |
| 4.2. Binarna logistička regresija..... | 10 |
| 4.3. Priprema podataka za učenje modela binarne logističke regresije | 14 |
| 4.4. Validacija modela binarne logističke regresije | 14 |
| 4.5. Integracija modela binarne logističke regresije u cjelokupnu upravljačku strategiju | 17 |
| 5. SIMULACIJSKI REZULTATI..... | 19 |
| 5.1. Implementacija dobivenih podataka u simulaciju..... | 19 |
| 5.2. Provedba simulacije | 20 |
| 5.3. Rezultati | 20 |
| 6. ZAKLJUČAK..... | 28 |
| LITERATURA..... | 29 |

POPIS SLIKA

| | |
|---|----|
| Slika 1 Ilustracija konfiguracije pogona EV s pogonom na sva četiri kotača..... | 5 |
| Slika 2 Graf momenta i brzine prikazan preko stanja spojke dobiven iz svih voznih ciklusa ... | 9 |
| Slika 3 Sigmoidna funkcija | 11 |
| Slika 4 Binarna logistička regresija..... | 12 |
| Slika 5 Funkcija troška | 13 |
| Slika 6 Moment i brzina prikazani pomoću vjerojatnosti pripadanja klasi 1 | 16 |
| Slika 7 WLTP vremenski profil ukupnog traženog momenta uz granice 10-90..... | 21 |
| Slika 8 WLTP vremenski profil ukupnog traženog momenta uz granice 50-50..... | 21 |
| Slika 9 WLTP vremenski profil brzine uz granice 10-90 | 22 |
| Slika 10 WLTP vremenski profil brzine uz granice 50-50 | 22 |
| Slika 11 WLTP moment i brzina uz granice 10-90..... | 23 |
| Slika 12 WLTP moment i brzina uz granice 50-50..... | 23 |
| Slika 13 WLTP Stanja spojke uz granicu 10-90 | 24 |
| Slika 14 WLTP Stanja spojke uz granicu 50-50 | 24 |
| Slika 15 WLTP usporedna analiza performansi LR metode za različita podešenja praga vrijednosti spram globalno optimalne DP Pareto fronte | 25 |
| Slika 16 UDDS usporedna analiza performansi LR metode za različita podešenja praga vrijednosti spram globalno optimalne DP Pareto fronte | 26 |
| Slika 17 NEDC usporedna analiza performansi LR metode za različita podešenja praga vrijednosti spram globalno optimalne DP Pareto fronte | 26 |

POPIS OZNAKA

| Oznaka | Opis | Mjerna jedinica |
|----------------------------|----------------------------------|------------------------|
| A_f | Frontalna površina vozila | m^2 |
| $\mathbf{c}(\mathbf{k})$ | Vektor stanja spojki | - |
| $\mathbf{c}_R(\mathbf{k})$ | Referentni vektor stanja spojki | - |
| C_d | Aerodinamički koeficijent otpora | - |
| $E_{el,i}(\mathbf{k})$ | Komponenta električne energije | J |
| F | Sila na kotače | N |
| g | Gravitacija | m/s^2 |
| h | Prijenosni omjer | - |
| m | Broj uzoraka u skupu podataka | - |
| m_v | Masa vozila | kg |
| N_f | Broj vremenskih koraka | - |
| P_o | Snaga gubitaka praznog hoda | W |
| r | Radijus kotača | m |
| R_0 | Bezdimenzijski faktor | - |
| $s_{x,i}$ | Koeficijent klizanja | - |
| v_v | Brzina vozila | m/s |
| \dot{v}_v | Akceleracija vozila | m/s^2 |
| ρ_z | Gustoća zraka | kg/m^3 |
| $y^{(i)}$ | Stvarna oznaka klase | - |
| α | Nagib ceste | rad |
| $\boldsymbol{\theta}$ | Vektor parametara | - |

| | | |
|--|-------------------------------|-------|
| $h_{\theta}(x)$ | Hipoteza logističke regresije | - |
| τ | Moment | Nm |
| η_{tr} | Korisnost transmisije | - |
| $\frac{\partial J(\theta)}{\partial \theta_j}$ | Gradijentna funkcija | - |
| ω | Kutna brzina | rad/s |

POPIS KRATICA

| | |
|------|---|
| AWD | Pogon na sva četiri kotača (eng. All-wheel drive) |
| DP | Dinamičko programiranje |
| EREV | Električno vozilo produljenog dometa (eng. Extended Range Electric Vehicle) |
| EV | Električno vozilo |
| FWD | Pogon na prednje kotače (eng. Front-wheel-drive) |
| GPS | Globalni pozicijski sustav |
| LR | Logistička regresija |
| RWD | Pogon na stražnje kotače (eng. Rear-wheel drive) |
| 2WD | Pogon na dva kotača (eng. two-wheel drive) |

SAŽETAK

Ovaj završni rad bavi se problemom energetski učinkovitog usmjeravanja okretnog momenta za EV (električna vozila) s izravnim pogonom na četiri kotača, koristeći algoritme strojnog učenja, posebno logističku regresiju. Glavni cilj rada je istražiti, razviti i optimalno kalibrirati upravljačku strategiju koja će omogućiti optimalnu raspodjelu momenta na kotačima vozila, u svrhu unapređenja energetske učinkovitosti.

Rad započinje uvodom u EV i njihovim prednostima, nakon čega slijedi pregled autonomnih vozila i sustava prediktivne vožnje. Ovi koncepti postavljaju temelje za razumijevanje važnosti učinkovitog upravljanja momentom u modernim električnim vozilima.

U teorijskom dijelu rada objašnjava se osnova longitudinalne dinamike vozila, s posebnim naglaskom na sustave raspodjele momenta kod vozila s više motora. Bit će objašnjeni ključni pojmovi kao što su dinamika vozila, raspodjela momenta, upravljačke strategije i algoritmi optimiranja. Također, detaljno će biti objašnjena logistička regresija, njezini principi, te način na koji se koristi za određivanje optimalne raspodjele momenta u kontekstu električnih vozila.

Praktični dio rada uključuje izradu simulacijskih modela koji će omogućiti analizu različitih scenarija raspodjele momenta u stvarnim uvjetima vožnje. Simulacije će biti provedene pomoću algoritma dinamičkog programiranja (DP) koji optimira upravljačke varijable u širokom rasponu brzina i uvjeta na cesti. Bit će prikazani rezultati simulacija, uključujući grafove raspodjele momenta, potrošnje energije, te analizu promjena u performansama vozila za različita podešenja upravljačke strategije.

Uz tekstualni dio, rad će sadržavati brojne slike i grafove koji će vizualizirati dinamiku vozila, strukturu modela, rezultate simulacija te usporedbe različitih strategija optimiranja. Prikazani će biti i dijagrami tokova podataka koji ilustriraju proces obrade podataka u sustavu za prediktivnu vožnju i primjenu logističke regresije.

Rad završava zaključkom u kojem se sumiraju glavni rezultati i doprinosi istraživanja, te se predlažu smjernice za buduće radove i primjene istraženih metoda u praksi.

Ključne riječi: električno vozilo, strojno učenje, dinamičko programiranje, optimiranje, simulacije, usmjeravanje momenta, učinkovitost

SUMMARY

This thesis addresses the problem of energy-efficient torque vectoring for EVs (electric vehicles) with four-wheel direct drive, using machine learning algorithms, specifically logistic regression. The main goal of the thesis is to investigate, develop, and optimally calibrate a control strategy that will enable the optimal distribution of torque across the vehicle's wheels to enhance energy efficiency.

The thesis begins with an introduction to EVs and their advantages, followed by a review of autonomous vehicles and predictive driving systems. These concepts lay the foundation for understanding the importance of efficient torque management in modern electric vehicles.

The theoretical part of the thesis explains the basics of longitudinal vehicle dynamics, with a particular focus on torque vectoring systems in multi-motor vehicles. Key concepts such as vehicle dynamics, torque distribution, control strategies, and optimization algorithms will be explained. Logistic regression will be thoroughly detailed, including its principles and how it is used to determine the optimal torque distribution in the context of electric vehicles.

The practical part of the thesis involves the development of simulation models that will allow for the analysis of various torque distribution scenarios under real driving conditions. Simulations will be conducted using a dynamic programming (DP) algorithm that optimizes control variables across a wide range of speeds and road conditions. The simulation results will be presented, including torque distribution graphs, energy consumption data, and performance analysis for different control strategy settings.

In addition to the textual content, the thesis will include numerous images and graphs that visualize vehicle dynamics, model structures, simulation results, and comparisons of different optimization strategies. Data flow diagrams illustrating the data processing in predictive driving systems and the application of logistic regression will also be presented. The thesis concludes with a summary of the main results and contributions of the research, as well as suggestions for future work and the practical application of the explored methods.

Keywords: electric vehicle, machine learning, dynamic programming, optimization, simulations, torque vectoring, efficiency

1. UVOD

Električna vozila (EV), vozila su koja koriste električnu energiju kao izvor energije umjesto tradicionalnih goriva, poput benzina ili dizela. EV predstavljaju ključnu tehnologiju u danas sve izraženijoj i bitnijoj borbi protiv zagađenja okoliša i klimatskih promjena jer elektromotori ne ispuštaju štetne plinove koji mogu značajno ugroziti stanje atmosfere i naše okoline. Električna vozila mogu se podijeliti na razne načine, ali najjednostavnija podjela je zapravo na način pretvorbe energije gdje poznajemo: potpuno električna vozila, hibridna električna i hibridna vozila. Nadalje drugu podjelu karakterizira sama dobava energije. Tako poznajemo nezavisna električna vozila koja električnu energiju za pogon dobivaju iz dijelova ugrađenih u samo vozilo poput baterija i akumulatora i zavisna vozila koja su cijelo vrijeme spojena na elektroenergetsku mrežu (tramvaji).

Duga povijest električnih vozila [1] u svojim počecima je bila puna izazova i obrata. Mnogi ljudi ne znaju da je na prijelazu u 20. stoljeće zapravo bilo više EV-a na cesti nego vozila na benzinski pogon. Međutim, ta je rasprostranjenost dovedena u pitanje kada je Fordova pokretna montažna linija učinila osobne automobile pristupačnijim.

Koncept električnog vozila osmišljen je s ciljem unaprjeđenja vozila pogonjenih na neobnovljive izvore energije gdje vidimo prvu, ako ne i najveću njihovu prednost. Glavna prednost električnih vozila je u tome što elektromotori imaju značajno viši stupanj učinkovitosti u usporedbi s tradicionalnim motorima s unutarnjim izgaranjem. Motori koji se provode po Ottovom procesu [2] imaju stupanj učinkovitosti od samo 25%-35% dok je Dieslov motor [2] nešto korisniji sa prosječnim stupnjem korisnosti od 40%, ali to nije ni približno dobro elektromotorima koji imaju stupanj učinkovitosti preko 90%. EV su potpuno okrenuta obnovljivim izvorima energije, specifičnije, struji iz samog razloga neobnovljivosti energenata korištenih za pogon konvencionalnih vozila. Električna energija sama po sebi teško, gotovo nemoguće je pronalazljiva u prirodi, odnosno možemo je dobiti samo pretvorbom energije. Električna energija vrlo često se dobiva iz drugih, potpuno obnovljivih izvora kao što su vjetar, voda i geotermalna energija što ju čini idealnim energentom za budućnost. Sljedeća velika prednost EV je značajno tiši rad

elektromotora u odnosu na konvencionalni motor s unutarnjim izgaranjem. Osim što negativno utječe na kvalitetu života ljudi, buka značajno utječe i na oblikovanje flore i faune u današnjem svijetu. Iz ovoga možemo vidjeti da su elektromotori mnogo bolji od starih konvencionalnih

motora baziranih na unutarnjem izgaranju, ali postoje i čimbenici koji priječe njihov širi prodor u cestovni promet.

Današnji svijet teško i nerado prihvaća promjene, a to se lako može uočiti i na primjeru odnosa tradicionalnih i električnih vozila, a ponajviše automobila na cestama. Iako se već zadnjih 20-ak godina stalno govori o katastrofalnim klimatskim promjenama i o tome kako su sami automobili najveći ugrozitelji zdravlja našeg planeta [3], ljudi se jednostavno na tu činjenicu oglušše prilikom izbora vozila. Ovaj problem ne odabira EV može se sagledati i sa druge strane, nejednolika razvijenost svijeta i infrastrukture značajno utječe na odluke ljudi vezane za električna vozila. Nažalost, u zemljama trećeg svijeta ne postoji gotovo nikakva infrastruktura koja bi mogla pridonijeti povećanju broja EV na cestama. Glavni problem su punionice za takva vozila, odnosno današnje električne mreže ne bi mogle podnijeti toliku potražnju za strujom kada bi se ljudi teoretski samo prebacili na EV. Zato su potrebna značajna i izdašna ulaganja u infrastrukturu, ne samo za punionice, već i cijele elektro-energetske mreže, zajedno sa idejom o pametnim gradovima (eng. smart city). Jedan od problema samih električnih vozila su njihove performanse. Tehnologija još nije dovoljno razvijena da bi se EV mogla uspoređivati sa konvencionalnim vozila po pitanju performansi, a na kraju i samog dosega automobila između dva punjenja.

Zadatak većine izuma bio je olakšavanje života ljudima i pojednostavljivanje njihovih svakodnevnih zadataka, odnosno rutina. Jedna takva ideja pojavila se usporedno s razvojem alata umjetne inteligencije [5] je prediktivna vožnja. Takva vrsta vožnje predstavlja napredni koncept u razvoju autonomnih vozila i sustava za pomoć vozaču, čiji je cilj optimirati performanse vozila, povećati sigurnost i smanjiti potrošnju energije. Ona se odnosi na korištenje podataka u stvarnom vremenu, algoritama strojnog učenja i različitih senzora kako bi samo vozilo moglo predvidjeti buduće uvjete na cesti i prilagoditi svoje ponašanje u skladu s tim. To uključuje prilagodbu brzine, upravljanje potrošnjom energije, izbjegavanje prepreka i održavanje optimalne putanje. Prediktivna vožnja služi za vožnju u trenucima kada vozač nije u potpunosti siguran u svoje sposobnosti vožnje čime u svakom slučaju povećava sigurnost sebe, a tako i drugih sudionika u prometu. Nadalje, sam pojam „prediktivna“ ukazuje na mogućnosti vozila u smislu očitavanja sadašnjih i predviđanja budućih stanja koja postoje u okolini, a vezana su za vozilo i vožnju. Tako vozilo može analizirati cestu, promet, vremenske uvjete i još mnogo toga kako bi optimiralo svoje kretanje i time smanjilo energetske potrošnju, optimiralo putanju i u krajnju ruku povećalo sigurnost i udobnost putnika, ali i drugih sudionika

u prometu. Glavno pitanje koje se nameće je: “Kako radi sustav predikcije i prediktivne vožnje”? Vozilo je opremljeno velikim brojem senzora [3] po sebi, od senzora topline, blizine, sve do kamera i GPS-a kojima prikuplja podatke koje nakon toga analizira. Prikupljeni podaci se obrađuju pomoću naprednih algoritama strojnog učenja i modeliranja kako bi se izgradile predikcije potencijalnih budućih događaja. Primjerice, takav sustav može odlučiti usporiti vozilo prije dolaska do opasnog zavoja, promijeniti traku radi izbjegavanja gužve, ili prilagoditi snagu motora kako bi se produžio domet vozila na električni pogon. No, takvi sustavi nisu idealni i postoje mnoge prepreke i problemi s kojima se takvi sustavi susreću, stoga se svakim danom sve više i više usavršavaju i nadograđuju. Prvi problem je točnost podataka i ispravnost modela koji najviše ovise o kvaliteti samih senzora. Također, potrebno je osigurati sukladnost i međusobnu povezanost sustava prediktivne vožnje [4] sa već postojećim upravljačkim sustavima vožnje. Na kraju, vjerojatno i najveći i najbitniji problem je osiguranje kvalitete i ispravnosti rada takvih sustava i njihova vrlo brza prilagodba na nove situacije.

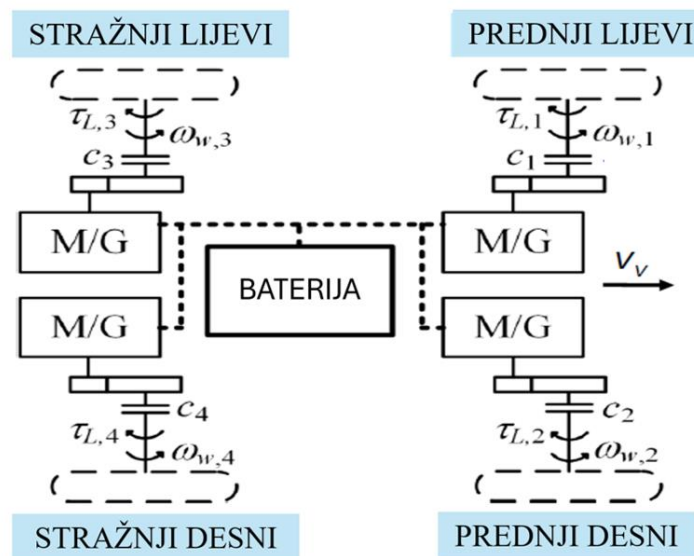
Glavni zadatak ovog završnog rada je osmisliti prediktivni model koji će ovisno o danim uvjetima vožnje moći predvidjeti koji model pogona, odnosno stanja spojki bi bio najkorisniji misleći pritom na korisnost vožnje zajedno sa brojem promjena stanja spojke odnosno o trošenju same spojke. U ovom radu razmatra se pravocрно gibanje modela EV koji na svakom kotaču posjeduje po jedan motor koji time daje vrlo dobru fleksibilnost u isporuci traženog momenta na kotačima. Glavni zadatak je minimizirati potrošnju energije na način da se traženi moment optimalno rasporedi po pojedinim spojkama (prednjoj i stražnjoj). Model je napravljen pomoću logističke regresije koja ovisno o stanjima na ulazu odlučuje o idealnom stanju spojke (optimalni način rada) kojim se dobiva najkorisniji način rada.

Kroz sljedeća poglavlja koja se nalaze u ovom radu detaljnije se objašnjavaju svi postupci i koraci provedeni u ovom radu. Ostatak rada podijeljen je na još pet poglavlja gdje se drugo po redu poglavlje (Modeliranje EV pogona [5]) bavi optimiranjem raspodjele momenta i upravljanjem spojkama kod EV s više motora s ciljem smanjenja potrošnje energije i svim osnovama za bolje razumijevanje ovog koncepta. Treće poglavlje (Optimiranje upravljačkih varijabli EV pogona van realnog vremena [5]) govori o optimiranju varijabli iz prethodnog poglavlja u svrhu što većeg poboljšanja i točnijih rezultata, dok se četvrto poglavlje (Optimalno upravljanje momentom u stvarnom vremenu) prebacuje na korištenje prethodno stečenih znanja u stvarnom vremenu, odnosno u realnim situacijama kako bi EV moglo samostalno donositi odluke kada se nađe u dotad neviđenim situacijama. Također su u poglavlju opisane sve nužne

teorijske osnove binarne logističke regresije, njene prednosti i nedostaci kao i uporaba u klasifikaciji podataka. Kraj četvrtog poglavlja govori o optimiranju podataka za model i implementaciji modela u cjelokupnu upravljačku strategiju. Peto poglavlje predstavlja provedbu simulacijskih procesa i detaljno opisuje zaključke do kojih smo došli analizirajući dobivene rezultate u obliku tablica i grafova. Posljednje, šesto poglavlje daje zaključak na cijeli rad i u njemu dobivene rezultate.

2. MODELIRANJE EV POGONA

Model EV-a koji koristimo posjeduje direktni pogon na sve kotače, pri čemu su svi kotači povezani s jednakim električnim motorima i spojkama (slika 1). Parametri za dinamičke karakteristike vozila preuzeti su iz Chevrolet Volt produženog dosega (EREV, eng. Extended Range Electric Vehicle) uz određene prilagodbe mase vozila i visine težišta kako bi se uzela u obzir dodatna masa baterije.



slika 1. Ilustracija konfiguracije pogona EV s pogonom na sva četiri kotača

Model koristi pristup unatrag [4], gdje se varijable pogonskog sklopa računaju od kotača prema motorima. Ukupni traženi moment dobiva se iz brzine vozila v_v , akceleracije \dot{v}_v i nagiba ceste α :

$$\tau_{w,t} = (m_v \dot{v}_v + m_v g \sin \alpha + R_0 m_v g \cos \alpha + 0.5 \rho_z C_d A_f v_v^2) r \quad (1)$$

U ovom radu razmatramo pravocrtno gibanje pa su momenti kotača uravnoteženi kako bi moment skretanja ostao 0 gdje $\tau_{w,1}$, $\tau_{w,2}$, $\tau_{w,3}$ i $\tau_{w,4}$ predstavljaju momente na kotačima .

$$\tau_{w,1} - \tau_{w,2} + \tau_{w,3} - \tau_{w,4} = 0 \quad (2)$$

Raspodjela momenta između prednjih i stražnjih osovina određena je bezdimenzijskim koeficijentom σ .

$$\sigma = \frac{(\tau_{\omega,1} + \tau_{\omega,2})}{2} \quad (3)$$

Koeficijent σ računa se iz momenta na suprotnim kotačima (lijevom i desnom). Taj bezdimenzijski faktor objašnjava raspodjelu ukupnog momenta $\tau_{\omega,t}$ na prednju i stražnju spojku.

$$\begin{aligned} \tau_{\omega,1} &= \sigma \rho_f \tau_{\omega,t} \\ \tau_{\omega,2} &= \sigma(1 - \rho_f) \tau_{\omega,t} \\ \tau_{\omega,3} &= (1 - \sigma)\rho_r \tau_{\omega,t} \\ \tau_{\omega,4} &= (1 - \sigma)(1 - \rho_r) \tau_{\omega,t} \end{aligned} \quad (4)$$

U ovom radu bazirali smo se na linearno gibanje te su u tom slučaju faktori raspodjele momenta na lijeve i desne kotače pojedine spojke (ρ_f , ρ_r) 0.5 te dolazimo do zaključka da nema razlike iznosa momenta između suprotnih kotača iste spojke. Ukoliko je $\sigma = 1$, sav moment se nalazi na prednjoj spojci, ako je $\sigma = 0$, tada je cjelokupni iznos momenta na stražnjoj spojci, a ukoliko je vrijednost 0.5, tada je moment ravnomjerno raspoređen na sva 4 kotača.

Ukoliko je spojka povezana s motorom, moment kotača pretvara se u moment motora pomoću:

$$\tau_{m,i} = \frac{1}{h} (\tau_{w,i} \eta_{tr} (\tau_{w,i}) + \frac{P_o(\omega_{w,i})}{\omega_{w,i}}) \quad (5)$$

Gdje $\tau_{m,i}$ predstavlja momenta na i-tom motoru, a $\tau_{w,i}$ moment na i-tom kotaču h je prijenosni omjer, η_{tr} učinkovitost prijenosa, $P_o(\omega_{w,i})$ razvijenu snagu na kotačima, a $\omega_{w,i}$ brzinu rotacije i-tog kotača.

Brzinu motora određuju brzina kotača i prijenosni omjer, ili detaljnije, prijenosni omjer h , linearna brzina v_v , radijus kotača r i faktor klizanja je kako $s_{x,i}$:

$$\omega_{m,i} = h\omega_{w,i} = h \frac{v_v}{r(1-s_{x,i})} \quad (6)$$

Električna snaga i -tog motora $P_{el,i}$ određena je momentom i brzinom rotacije motora, kao i snagom gubitaka koji se javljaju na motoru $P_{m,loss,i}$:

$$P_{el,i} = \tau_{m,i}\omega_{m,i} + P_{m,loss,i}(\omega_{m,i}, \tau_{m,i}) \quad (7)$$

Određivanje stanja spojki u sustavu pogona električnog vozila modelira se kroz diskretnu vremensku jednadžbu stanja (jednadžbe: 6, 7 i 8). Stanje spojke određuje se prema referentnim vrijednostima putem sljedećih jednadžbi gdje $\mathbf{c}(k)$ predstavlja vektor kontrolnih varijabli, $\mathbf{c}_R(k)$ vektor referentnih kontrolnih varijabli, a $\mathbf{c}_i(k+1)$ stanje kontrolnih varijabli za sljedeći korak bazirajući se na referentno stanje trenutnog koraka.

$$\mathbf{c}(k) = [c_1(k) \ c_2(k) \ c_3(k) \ c_4(k)]^T \quad (8)$$

$$\mathbf{c}_R(k) = [c_{R_1}(k) \ c_{R_2}(k) \ c_{R_3}(k) \ c_{R_4}(k)]^T \quad (9)$$

$$\mathbf{c}_i(k+1) = \mathbf{c}_{R,i}(k) \quad (10)$$

Prema pretpostavci, proces promjene stanja spojke odvija se unutar vremenskog intervala koje je manje od vremena uzorkovanja. Tijekom prijelaznog razdoblja (uključivanja ili isključivanja spojke) moment se ne prenosi na kotače.

Načine stanja spojki pa tako i uključenosti motora u pet mogućih slučajeva, a to su: RWD-0, RWD-1 (eng. Rear-wheel drive, pogon na stražnje kotače), FWD-0 (0 predstavlja stanje iskopčanih suprotnih spojki), FWD-1 (1 znači da su suprotne spojke uključene) (eng. front-wheel drive, pogon na prednje kotače) i AWD (eng. All-wheel drive, pogon na sva četiri kotača). U ovom radu ograničili smo se samo na AWD i 2WD (eng. Two-wheel drive) gdje FWD-0 predstavlja način pogona na dva kotača [4].

3. OPTIMIRANJE UPRAVLJAČKIH VARIJABLI EV POGONA VAN REALNOG VREMENA

Optimizacija [5] je matematički postupak koji omogućuje pronalaženje najboljeg mogućeg rješenja za ekonomsku ili tehničku odluku prema odabranim kriterijima. U kontekstu upravljanja pogonom električnih vozila, optimiranje van realnog vremena koristi simulacije i algoritme za unaprijed određivanje optimalnih parametara upravljanja, čime se izbjegava potreba za računanjima tijekom stvarne vožnje. Ovaj postupak omogućava detaljno istraživanje različitih scenarija vožnje i konfiguraciju upravljanog sustava kako bi se pronašli optimalni parametri za upravljanje pogonom.

Optimiranje raspodjele momenta [6] u vozilu s električnim pogonom temelji se na dinamičkom modelu koji uzima u obzir funkcionalnost isključenja spojki i povezane gubitke pri prebacivanju. Kada se ne razmatra opcija isključenja spojki, model vozila postaje statičan, a problem optimiranja svodi se na trenutno optimiranje raspodjele momenta (σ). U tom slučaju, optimiranje raspodjele momenta između prednje i stražnje osovine koristi se za postizanje optimalne ravnoteže između dva pogonska načina: pogon na sve kotače (AWD), pogon na dva kotača (2WD). Optimalna raspodjela momenta između prednje i stražnje osovine ovisi o zahtjevima za ukupnim momentom kotača ($\tau_{w,t}$) i brzini vozila (v_v).

Nakon što smo analizirali statički problem raspodjele momenta, gdje se optimalna distribucija momenta između prednje i stražnje osovine postiže putem trenutnog optimiranja, razmatramo složeniji slučaj s omogućenim isključenjem i uključenjem pojedinih spojki. Ovaj pristup uvodi dinamičke promjene u raspodjelu momenta tijekom vožnje, što zahtijeva sofisticiraniji alat optimiranja, odnosno dinamičko programiranje.


Dinamičko programiranje (DP) metoda je koja se koristi za pronalaženje globalno optimalnih rješenja za probleme optimiranja u kojima su promjenjive varijable nelinearne i diskontinuirane. To se postiže tako da se problem optimiranja [8] dijeli na manje, međusobno povezane podprobleme, a rješenja se traže unatrag od krajnjeg stanja sustava prema početnom stanju. DP je posebno korisno za optimiranje u sustavima niskih dimenzija, poput ovog modela vozila s binarnim promjenama stanja spojki.

U ovom slučaju, primijenili smo DP za optimiranje (koja se obavlja kroz cijeli vremenski interval vožnje) trajektorija upravljačkih varijabli $\sigma(k)$ i $c_R(k)$, koje predstavljaju raspodjelu momenta i stanja spojki, kroz cijeli vozački ciklus. Glavni cilj je minimizirati ukupnu potrošnju

energije i smanjiti učestalost prebacivanja spojki kako bi se smanjili gubici i povećala trajnost spojki. Trošak za minimizaciju je definiran kao:

$$J = \sum_{k=0}^{N_f-1} \left((F_{sw}(k) + \sum_{i=1}^4 \frac{E_{el,i}(k)}{4}) \right) \quad (11)$$

DP u ovom kontekstu omogućuje optimiranje kroz vrijeme, uzimajući u obzir dinamički model vozila i diskretne promjene stanja spojki, te pruža optimalne upravljačke strategije za vožnju koje uključuju promjene između AWD i 2WD načina rada, dok se maksimizira energetska učinkovitost.



Slika 2. Graf momenta i brzine prikazan preko stanja spojke dobiven iz svih voznih ciklusa

Slika 2 prikazuje tražena stanja spojki koja smo dobili iz izmjerenih rezultata. Ti rezultati odgovaraju vrijednostima dobivenima u voznim ciklusima: WLTP, US06, UDDS, NEDC, HWFET te DUB-1, DUB-2 i DUB-3). Ovaj prikaz podataka služi nam za vizualni prikaz gdje možemo očekivati granice klasifikacije i na kraju, služi nam za trening modela.

4. OPTIMALNO USMJERAVANJE MOMENTA U STVARNOM VREMENU

4.1. Koncept

Temeljem rezultata dobivenih primjenom DP strategije na globalno optimalnoj razini, u svakom uzorku voznog ciklusa moguće je naučiti model strojnog učenja koji će donositi odluku o stanju spojki. Ovaj pristup koristi podatke prikupljene tijekom DP optimiranja kako bi se stvorio aproksimacijski model koji može donijeti brže i točnije odluke u stvarnom vremenu, bez potrebe za ponovnim izvođenjem cijelog DP algoritma. U tu svrhu, koristimo se modelom binarne logističke regresije za trening modela na temelju dobivenih optimalnih rezultata, gdje model učimo obrascima ponašanja, odnosno promjena stanja spojki u odnosu na ulazne parametre kao što su traženi moment na kotačima i brzina vozila. Ovaj pristup osigurava nam izuzetno brzo donošenje odluka s dovoljno dobrom preciznošću, temeljenom na naučenim obrascima iz DP optimiranja. Temeljem ovog modela, u svakom koraku uzorkovanja donosi se odluka o stanju spojki, tj. treba li vozilo koristiti pogon na sva četiri kotača ili na samo dva ovisno o brzini vozila i traženom okretnom momentu. Ova odluka omogućava optimiranje trenutne raspodjele momenta, a time i poboljšanje performansi vozila u različitim uvjetima vožnje. Osim toga, nastojimo ostvariti kompromis između potrošnje energije, performansi i broja prebacivanja stanja spojki kako bismo smanjili trošenje spojki i unaprijedili udobnost vožnje.


4.2. Binarna logistička regresija

Regresija je matematička metoda koja se koristi za modeliranje odnosa između zavisne varijable (ciljne varijable) i jedne ili više nezavisnih, ulaznih varijabli (prediktora). Pomoću regresije moguće je razumjeti i predvidjeti kako promjene u nezavisnim varijablama utječu na zavisnu varijablu, tj. kako ulazi utječu na izlaze sustava. U matematičkom obliku, zavisna varijabla može se zapisati kao $y_i = f(x_i) + e_i$, gdje e_i predstavlja slučajnu pogrešku s normalnom raspodjelom i očekivanom vrijednošću nula. Regresijska analiza traži krivulju koja minimizira razliku između stvarnih podataka i modelirane funkcije.

Regresija ima široku primjenu u različitim područjima znanosti i tehnologije. U ekonomiji se često koristi za predviđanje tržišnih trendova na temelju ekonomskih pokazatelja, dok se u


medicini koristi za analizu učinkovitosti različitih terapija. U inženjerstvu, regresija pomaže u modeliranju i optimiranju procesa, predviđanju trajnosti materijala te procjeni pouzdanosti sustava. Na primjer, regresija se koristi za analiziranje kako različiti faktori (npr. temperatura, tlak, brzina) utječu na performanse strojeva, predviđanje habanja materijala i optimiranje proizvodnih procesa. Postoji nekoliko vrsta regresije koje se koriste u analizi podataka, a najčešći su: linearna (koristi se za modeliranje odnosa zavisne i nezavisne varijable pomoću pravca), polinomna (prikazuje odnos ulazne i izlazne varijable pomoću krivulje višeg reda) i logistička regresija (koristi se za klasifikaciju podataka u dvije klase, npr. 0 i 1).

Logistička regresija [14] koristi se kada je zavisna varijabla binarna, odnosno može poprimiti samo dvije vrijednosti, kao što su 0 i 1 (npr. uspjeh/neuspjeh). Ova vrsta regresije predviđa vjerojatnost određenog ishoda na temelju skupa ulaznih varijabli. Umjesto da direktno predviđa rezultat, koristi logističku ili sigmoidnu funkciju $g(z)$, koja osigurava da predviđena vjerojatnost bude unutar intervala od 0 do 1.



Slika 3. Sigmoidna funkcija, slika preuzeta iz [10]

Posebna vrsta ove metode je binarna logistička regresija, koja se primjenjuje kada je zavisna varijabla ograničena na dvije vrijednosti. Primjeri uključuju predviđanje hoće li se neki događaj dogoditi (npr. hoće li pacijent razviti određenu bolest ili hoće li sustav ispravno funkcionirati).



Slika 4. Binarna logistička regresija, slika preuzeta iz [10]

Osnovna komponenta binarne logističke regresije [10] je sigmoidna funkcija (jednadžba 10) koja pretvara linearne kombinacije nezavisnih varijabli u vjerojatnosti između 0 i 1. Na temelju praga koji je unaprijed postavljen, te vjerojatnosti se zatim prevode u binarne ishode. Ovaj pristup omogućuje logističkoj regresiji da učinkovito klasificira podatke i predvidi događaje na temelju skupa ulaznih varijabli. Matematički, logistička funkcija se izražava kao:

$$h_{\theta}(x) = \frac{1}{1+e^{-\theta^T x}} \quad (12)$$


Binarna logistička regresija koristi se za klasifikaciju podataka u jednu od dvije klase (0 ili 1). Funkcija predviđanja koristi sigmoidnu funkciju, koja uzima ulazne podatke sadržane u vektoru \mathbf{x} i parametre θ , te vraća vjerojatnost da određeni podatak pripada klasi 1, u našem slučaju to će biti vjerojatnost pripadanja AWD načinu. Model se trenira tako da se minimizira funkcija troška, koja mjeri pogrešku između stvarnih vrijednosti i predviđenih vjerojatnosti. Kako bi se postigli optimalni parametri θ [9], koristi se gradijentni spust, koji iterativno ažurira parametre tako da smanjuje funkciju troška.

Proces treniranja uključuje prolazak kroz skup podataka, izračunavanje gradijenta i prilagođavanje parametara θ kako bi se model što bolje prilagodio podacima. Kada se idealni parametri pronađu, model može klasificirati nove primjere na temelju izračunatih vjerojatnosti (ako je vjerojatnost veća od 0.5, klasificiramo kao 1, inače kao 0). U nekim složenijim

problemima koristi se dinamičko programiranje za rješavanje zadataka optimiranja, jer ono učinkovito dekomponira problem u manje, međusobno povezane podzadatke i osigurava optimalna rješenja pri donošenju odluka.

U ovom radu, binarnu logističku regresiju koristimo kako bismo istrenirali model putem zadanih podataka o momentu i brzini vozila da on prvo izračuna idealne parametre funkcije i koristeći njih na kraju kao izlaz što točnije vraća konačni ishod za neke nove vrijednosti momenta i brzine. Prvi korak bio je razumjeti što predstavlja tzv. funkcija troška (eng. cost function) [13] koja je prikazana jednadžbom 13. Ona kod logističke regresije mjeri koliko dobro naš model predviđa izlazne vrijednosti u usporedbi sa stvarnim vrijednostima iz skupa podataka.

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m \left[y^{(i)} \log(h_{\theta}(x)^{(i)}) + (1 - y^{(i)}) \log(1 - h_{\theta}(x)^{(i)}) \right] \quad (13)$$



Slika 5. Funkcija troška, slika preuzeta iz [15]

Nadalje, druga izuzetno bitna stvar u razumijevanju binarne logističke regresije je pojam gradijenta funkcije [10]. Gradijent funkcije u kontekstu optimiranja i strojarskog učenja odnosi se na vektor parcijalnih derivacija funkcije u odnosu na njene parametre. Gradijent (jednadžba 14) nam govori u kojem smjeru trebamo mijenjati parametre modela kako bismo minimizirali funkciju troška.

$$\frac{\partial J(\theta)}{\partial \theta_j} = \frac{1}{m} \sum_{i=1}^m (h\theta(x^{(i)}) - y^{(i)}) x_j^{(i)} \quad (14)$$

U kontekstu logističke regresije, gradijent nam pomaže odrediti kako promijeniti parametre θ kako bi se smanjila funkcija troška $J(\theta)$, odnosno kako bismo poboljšali performanse modela. Jedna od glavnih prednosti logističke regresije je njena jednostavnost i lakoća interpretacije. Model pruža jasnu sliku o tome kako svaka nezavisna varijabla utječe na vjerojatnost događaja. Također, logistička regresija ne zahtijeva pretpostavku linearne veze između zavisne i nezavisnih varijabli, što je prednost u mnogim stvarnim scenarijima. Međutim, logistička regresija također ima svoja ograničenja. Kao prvo, ona radi dobro samo kada je odnos između nezavisnih varijabli i log-odds linearan. Ako su ovi odnosi složeniji, model možda neće biti dovoljno precizan. Drugo, logistička regresija je osjetljiva na outliere, koji mogu iskriviti rezultate. Konačno, model se može otežano nositi s velikim brojem nezavisnih varijabli, posebno ako među njima postoji jaka kolinearnost.

4.3. Priprema podataka za učenje modela binarne logističke regresije

Dobiveni podaci o različitim stanjima tijekom vožnje odnosili su se na: silu koja se javlja na kotačima, ubrzanje vozila, naprezanje, brzinu vožnje i idealno stanje spojke. Od svih tih mjerenja, nama su bili potrebni podaci o sili kako bismo dobili moment, brzini i traženom stanju spojke. Podaci vezani za silu predstavljali su nam problem jer su neke vrijednosti bile negativne te bismo množenjem tih vrijednosti sa polumjerom kotača dobili iznose momenta od kojih bi neki također bili negativnog predznaka što bi značajno utjecalo na kvalitetu rada funkcija kojima dolazimo do optimalnih parametara i u na kraju krajeva do klasifikacije podataka. Iz tog razloga koristili smo se apsolutnim iznosima momenata kako bismo osigurali točan rad modela.

4.4. Validacija modela binarne logističke regresije


Validacija modela binarne logističke regresije odnosi se na proces procjene performansi modela koji se koristi za predviđanje binarne ovisne varijable (koja može imati samo dvije kategorije, npr. "uspjeh" ili "neuspjeh"). Kao što je već navedeno, u ovom radu, trening podaci

klasificirani su u dvije skupine ovisno o traženom načinu stanja spojki. Naš problem sastojao se od nekoliko podproblema. Prva stvar koju je trebalo napraviti bilo je vizualizirati preddefinirane trening podatke momenta i brzine prikazane u dvije boje koje predstavljaju tražene klase kako bismo jednostavnije uočili kako optimirati sustav.

Prvo smo morali implementirati sigmoidnu funkciju $g(z)$ kako bi ju model mogao pozivati. To smo napravili pomoću Matlab funkcije `sigmoid(g)`. Nakon toga bilo je bitno upisati funkcije troška koju pokušavamo minimizirati koliko god je to moguće kako bismo dobili bolji i točniji rad modela i funkciju gradijentnog spusta koji iterativno ažurira parametre i konstantno smanjuje funkciju troška. Ona predstavlja rasipanje vrijednosti odnosno udaljenost točne, trening vrijednosti od dobivene te smo kao kriterij modela postavili minimiziranje te funkcije čime dobivamo najtočniji model, a samim time i najbolju separaciju podataka u klase. Po završetku tog dijela, za ispravan i što točniji rad modela bili su nam potrebni optimalni parametri θ . Mi te optimalne vrijednosti ne znamo pa smo na početku postavili početne (potpuno proizvoljne) parametre $\theta_{initial}$ te smo računali vrijednosti funkcije troška i gradijentne funkcije. Kako bismo dobili optimalne parametre i što točniji rad modela, odredili smo kako nam je glavni zadatak što više umanjiti vrijednost funkcije troška te smo se iz tog razloga koristili ugrađenom Matlab funkcijom `fminunc`. To je funkcija koja se koristi za nelinearno optimiranje bez ograničenja. Radi na način da minimizira zadanu funkciju troška koristeći gradijent za iterativno traženje optimalnih parametara. Optimalni parametri θ u modelu binarne logističke regresije predstavljaju težine koje se pridružuju ulaznim značajkama (varijablama) u svrhu predviđanja izlazne klase. Svaki parametar θ_j povezan je s jednom značajkom x_j , a model koristi ove parametre kako bi izračunao linearnu kombinaciju ulaznih podataka. Ta linearna kombinacija se zatim koristi unutar sigmoidne funkcije kako bi se predvidjela vjerojatnost da primjer pripada klasi 1. Drugim riječima, optimalni parametri θ definiraju kako svaki ulazni podatak utječe na odluku modela. Tijekom treniranja modela, parametri se iterativno prilagođavaju kako bi minimizirali funkciju trošenja i što bolje prilagodili model stvarnim podacima. Optimalni parametri omogućuju modelu da precizno klasificira nove, nepoznate primjere na temelju ulaznih podataka.

Sve u svemu, ovaj model pregledava svaku točku (njene iznose momenta i brzine te stanje spojke) i pomoću modela binarne logističke regresije traži najbolju granicu između dva stanja spojke kako bi mogao za nove ulazne podatke brzine i momenta predvidjeti stanje spojke koje bi se trebalo koristiti i vjerojatnost da je donio dobru odluku. Dobivenu granicu između dva

stanja spojke, a tako i kvalitetu rada modela možemo vidjeti na slici 7, u grafu momenta i brzine, ali na način da točke nisu obojane prema klasama u kojima se nalaze, već u paleti boja koja predstavlja vjerojatnost da će ta točka pripadati pojedinoj klasi. U prvom grafu crvenom smo bojom označili točke koje pripadaju klasi 1, a plavom točke klase 0, pa smo tako i u paleti prikazali točke.



Slika 6. Moment i brzina prikazani pomoću vjerojatnosti pripadanja klasi 1

Usporedbom slika 2 i 6 možemo zaključiti da naš model jako dobro prati idealni, preddefinirani model jer jasno uočavamo granice klasifikacije između dva stanja. Valja naglasiti kako su ove granice linearnog karaktera te za ovaj skup podataka ne mogu dati točnije i bolje granice klasifikacije. Ukoliko želimo dobiti bolje granice možemo promijeniti karakteristiku granice uvrštavanjem novih, nelinearnih članova kako bismo klasifikaciju obavljali parabolama višeg reda.

Ovaj model pomoću binarne logističke regresije koristi se za predviđanje vjerojatnosti da točka određena apsolutnim iznosom momenta i brzinom vozila pripada jednoj od dvije klase. U ovom slučaju, model je napravljen tako da vraća vjerojatnost da vozilo radi u AWD načinu vožnje (stanje 1). Temeljem navedenih ulaznih podataka, model preko sigmoidne funkcije,

gradijentne i funkcije troška zajedno sa ugrađenom *fminunc* funkcijom dobivajući optimalne parametre računa vjerojatnost za AWD način, gdje je rezultat bliži 1 ako je vozilo u AWD stanju, a bliži 0 ako je traženo stanje 2WD.

4.5. Integracija modela binarne logističke regresije u cjelokupnu upravljačku strategiju

Upravljačka strategija predstavlja plan i skup metoda koje se koriste za optimiranje funkcionalnosti i performansi sustava ili procesa kroz donošenje odluka o upravljačkim varijablama. U kontekstu sustava, to uključuje određivanje pravila i algoritama za upravljanje ulazima i parametrima s ciljem postizanja željenih izlaznih rezultata. Upravljačka strategija nastoji maksimizirati učinkovitost, stabilnost i fleksibilnost sustava, često koristeći metode analize, modeliranja i optimiranja kako bi se prilagodila promjenjivim uvjetima i ciljevima.

Upravljačka strategija ovog rada za cilj ima dobiti optimalni odnos između broja prekapčanja spojki (čime apeliramo na mehaničko trošenje) i performansi voznog ciklusa. Ova upravljačka strategija u sebi sadrži granice po kojima se određuje stanje spojke u svakom idućem koraku. Te granice predstavljene su postocima koji govore koliko je model siguran da treba koristiti način vožnje 1, odnosno AWD. Na primjer, ako su granice postavljene na 90-10 to bi značilo da je strategija napravljena tako da se način vožnje postavlja na AWD (sve spojke su uključene što znači da motori prenose okretni moment na kotače) kada je model preko 90% siguran da traži taj način, a kada je manje od 10% siguran za to (odnosno 90% siguran u drugi način), onda postavlja 2WD način vožnje (uključene samo suprotne prednje spojke). U kodu postoji mogućnost promjene granica odabira iz razloga što niti jedan vozni ciklus nije isti.

$$\mathbf{c}_R = \begin{cases} [1 \ 1 \ 0 \ 0]^T & \text{ako je } p < 20 \\ [1 \ 1 \ 1 \ 1]^T & \text{ako je } p > 80 \\ \mathbf{c}(k-1) & \text{ako je } 20 \leq p \leq 80 \end{cases} \quad (15)$$

Na primjer, može se desiti da u nekom trenutku želimo najbolje performanse vozila i u tom trenu granice promjene stanja spojki postaviti ćemo na vjerojatnost od 50% što bi značilo da model čim je malo sigurniji u jedan način da će se spojke postaviti na taj način. Taj način je u teoriji najbolji ukoliko zanemarimo trošenja i mehanička oštećenja spojki, no znamo kako to u

stvarnosti nije slučaj. Odabirom ovakvog načina rada spojke će se najčešće prespajati, a tako i najbrže potrošiti. S druge strane teoretski možemo postaviti granice na 0 i 100% što bi značilo da upravljačka strategija mijenja stanja spojki samo kada je model apsolutno siguran da želi traženi način. Takvim upravljanjem spojke će se prekapčati najrjeđe, no tako će najviše patiti performanse i same spojke jer će opterećenja konstanto biti na uključenoj spojki u tom trenutku.

5. SIMULACIJSKI REZULTATI

5.1. Implementacija dobivenih podataka u simulaciju

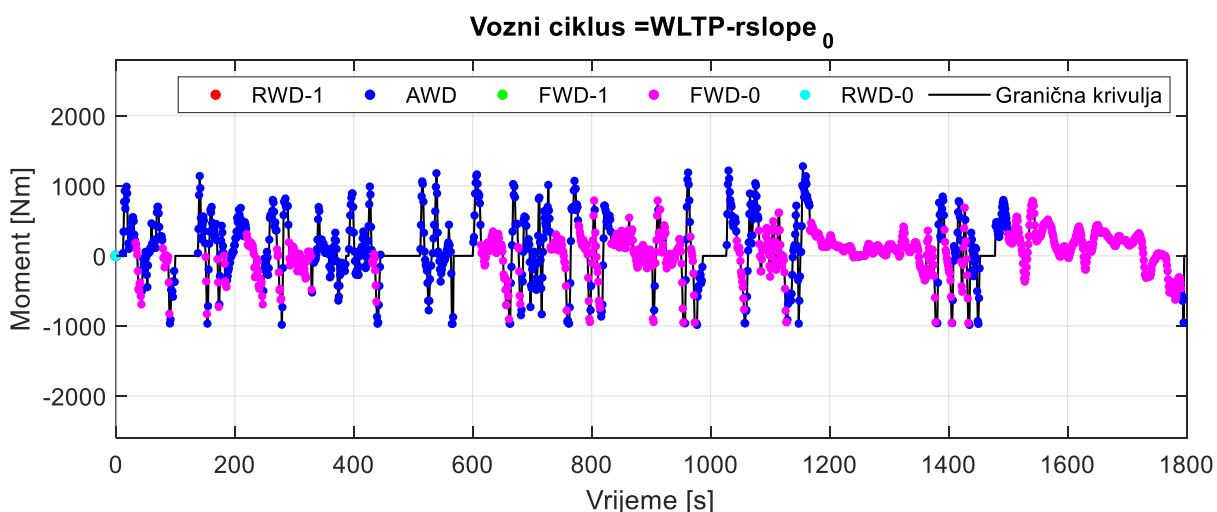
Po završetku pisanja svih kodova i dobivanja dobrog i kvalitetnog treninga podataka, došli smo do najboljih parametara za klasifikaciju pomoću kojih smo prema kriteriju minimiziranja funkcije trošenja (smanjenja odstupanja podataka i krivulje) došli do najboljih linearnih granica kojima smo raspodijelili zadane podatke u dvije klase. Te klasificirane podatke potom koristimo u simulaciji koja predstavlja vožnju EV s uključenim prediktivnim odabirom stanja spojke/ načina vožnje. U simulacijski kod su uključeni vozni ciklusi koje smo prethodno koristili za treniranje modela u kojima se nalaze rezultati mjerenja momenta i brzine u pojedinim trenutcima. Ideja simulacijskog koda je prikazati kako odabir granica za promjenu spojki utječe na zahtijevane performanse vozila zajedno s brojem prekapčanja spojki. Granice koje postavljamo u kodu su zapravo sigurnost modela, odnosno vjerojatnost koju smo dobili putem trening modela da određena točka (definirana vrijednostima momenta i brzine) pripada stanju spojke 1 (AWD). U idealiziranom slučaju u kojem nema trošenja spojki najbolje bi bilo postaviti granicu na vjerojatnost od 50% što bi zapravo značilo da model čim je sigurniji da točka pripada jednom stanju prebacuje spojku u traženo stanje. No, kako znamo da je to u stvarnom svijetu fizikalno nemoguće, granica od 50% značila bi najčešće prekapčanje spojki, istina i najbolje performanse vožnje, ali bi dovela i do najvećeg mehaničkog trošenja i najbržeg kvara na spojci. Sljedeći krajnji slučaj je postaviti granice promijene na izrazito visoke i niske vrijednosti. To bi značilo da EV mijenja stanje spojki samo u slučajevima gdje je gotovo 100% sigurno da traži određeno stanje. To bi uistinu dovelo do najmanjih mehaničkih oštećenja na spojci i ona bi mogla izdržati najdulji vijek trajanja, ali time bi značajno unazadili performanse vožnje EV. Generalna ideja je kompromis između performansi vožnje i mehaničkih oštećenja ne samo spojke, već i svih drugih dijelova EV. U ovom simulacijskom modelu, na početku je dana mogućnost odabira gore objašnjenih granica kako bi osoba koja će u budućnosti koristiti EV s ovim prediktivnim modelom mogla sama odlučiti kakav način vožnje želi koristiti u kojem trenutku.

5.2. Provedba simulacije


Kako bismo ispravno pokrenuli simulaciju trebali smo najprije odabrati ciklus vožnje u iz kojega smo na samom početku uzeli izmjerene vrijednosti momenta i brzine za koji želimo dobiti širu sliku o stanjima spojki tijekom vremena, ovisno o odabranim granicama koje su objašnjene u prošlom paragrafu te vrijednostima momenta i brzine. Kako je prije navedeno, nakon treninga podataka sve vjerojatnosti pripadanja točke stanju spojke 1 spremljene su u vektor p . Taj vektor sadrži sve vjerojatnosti, uključujući sva mjerenja. Vektor p smo podijelili na vektore p_1 - p_8 , gdje svaki od tih vektora sadrži samo vrijednosti koje odgovaraju pojedinom voznom ciklusu. To smo napravili kako bismo na početku simulacije, nakon odabira voznog ciklusa, odabrali valjane vjerojatnosti za dobar odabir stanja spojki. Nakon pokretanja simulacija nam daje prikaz brojnih grafova koji će biti detaljnije objašnjeni u sljedećem poglavlju.

5.3. Rezultati

Simulacijski rezultati uključuju prikaz grafova momenta i brzine u vremenu, ali prikazani preko načina pogona koji se koristio u tom trenutku, graf momenta na kotačima i rotacijske brzine, prikaz električkog i mehaničkog trošenja preko čega dobivamo uvid u ukupne gubitke u sustavu, grafove rotacijske brzine, momenta i sile na pojedinim kotačima i na kraju graf prekapčanja spojki u kojem su prikazani trenutci u kojima se spojke prespajaju i koliko dugo zadržavaju to stanje. Simulacije smo proveli za sve vozne cikluse kako bismo dobili što jasniju sliku o funkcionalnosti simulacije te kako bismo došli do zaključka o njenoj kvaliteti.




Slika 7. WLTP vremenski profil ukupnog traženog momenta uz granice 10-90




Slika 8. WLTP vremenski profil ukupnog traženog momenta uz granice 50-50

Na grafovima momenta u vremenu (slika 7, slika 8) možemo uočiti da pri manjim iznosima momenta model upravljačke strategije želi koristiti 2WD pogon dok pri višim vrijednostima traženog momenta, model vraća da je veća vjerojatnost da će se koristiti AWD način. Glavna razlika ovih slika je u različitim pragovima odabira stanja spojke. Ako malo bolje pogledamo, na slici 8. možemo uočiti češće promijene između plavih i roza točaka što ukazuje na češće promjene stanja spojki zbog granice koja je postavljena na 50-50 dok na slici 7 vidimo više grupirane podatke zbog dosta široke granice od 10-90 što ukazuje na rjeđe prekapćanje spojki.




Slika 9. WLTP vremenski profil brzine uz granice 10-90




Slika 10. WLTP vremenski profil brzine uz granice 50-50

Na slikama 9 i 10 prikazani su vremenski profili brzina prikazani preko stanja spojki. Možemo zaključiti da je 2WD način korišten pri konačnim ubrzanjima i potom usporavanjima dok je „prijelazno“ stanje karakterizirano AWD pogonom. Kao i na grafovima momenata (slike 7 i 8) kod prikaza profila brzine pri pragu 50-50 (slika 10) možemo uočiti češće promjene stanja spojke dok nešto rjeđe promjene vidimo na slici 9 koja predstavlja profil brzina za granicu 10-90.




Slika 11. WLTP moment i brzina uz granice 10-90

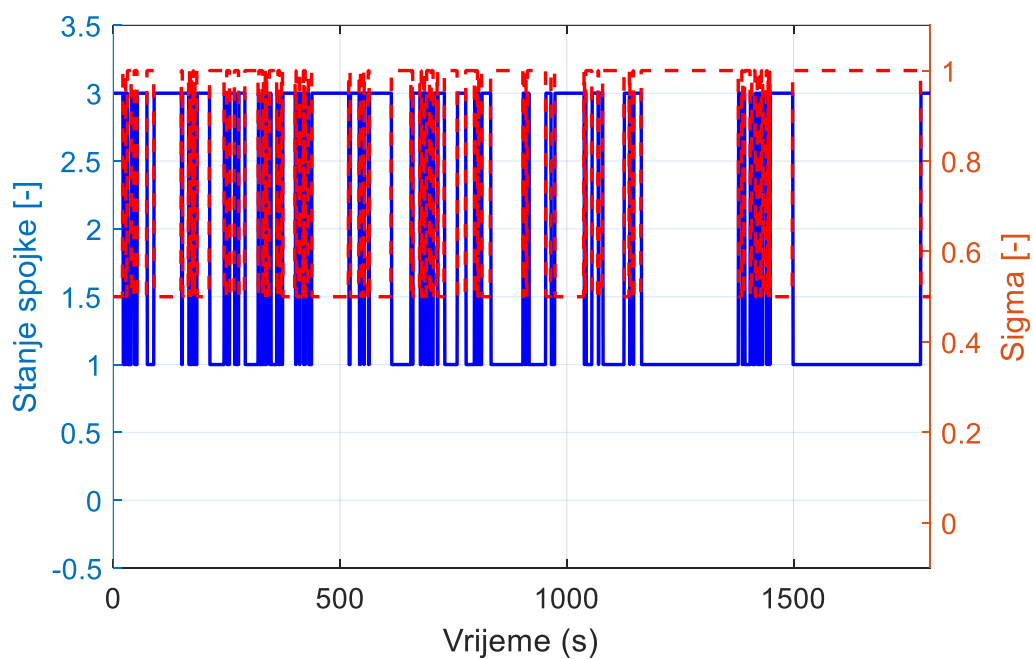


Slika 12. WLTP moment i brzina uz granice 50-50

Iz prikaza momenta i brzine (slike 11 i 12) možemo zaključiti da pri nižim brzinama, posebno tokom ubrzavanja EV, sustav preferira AWD pogon. Kako brzina raste, prelazi na dvomotorni način rada, što je energetski efikasnije pri većim brzinama. Pri istim vrijednostima momenta, model može zahtijevati različite načine pogona, ovisno o brzini vozila. To ukazuje na dinamičko upravljanje pogonom, gdje se sustav prilagođava uvjetima vožnje kako bi optimirao performanse i smanjio energetske potrošnje. Ovakav pristup osigurava stabilnost vozila i učinkovito korištenje energije.



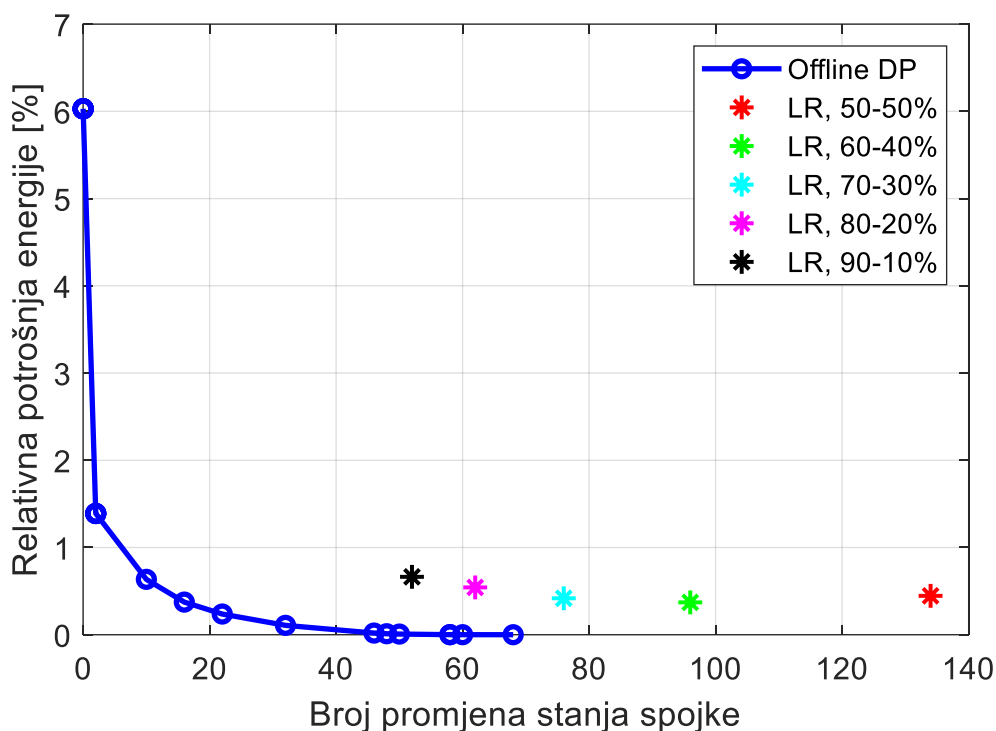
Slika 13. WLTP Stanja spojke uz granicu 10-90



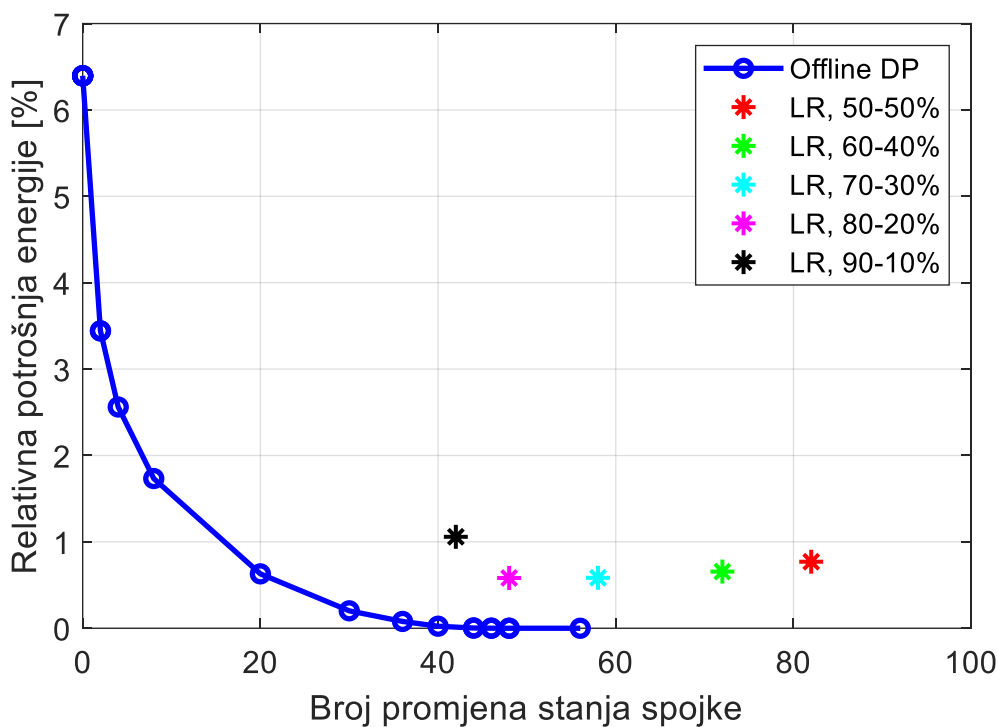
Slika 14. WLTP Stanja spojke uz granicu 50-50

Simulacijski grafovi koji prikazuju stanja spojki kroz cijeli vozni ciklus (slike 13 i 14) pružaju vrlo koristan uvid u dinamiku mijenjanja načina vožnje. Kroz ove grafove možemo jasno pratiti kako se mijenjaju stanja spojki tijekom vožnje, što nam daje detaljan pregled učestalosti tih promjena. Štoviše, ovi prikazi potvrđuju tezu o većem broju promjena stanja spojki pri nižim pragovima promjene (slika 14) dok se spojke rjeđe uključuju/isključuju pri izraženijim i sigurnijim granicama (slika 13) Takav prikaz omogućuje analizu koliko često dolazi do prijelaza između različitih stanja, poput uključenja, isključenja ili prijelaza u drugo operativno stanje.

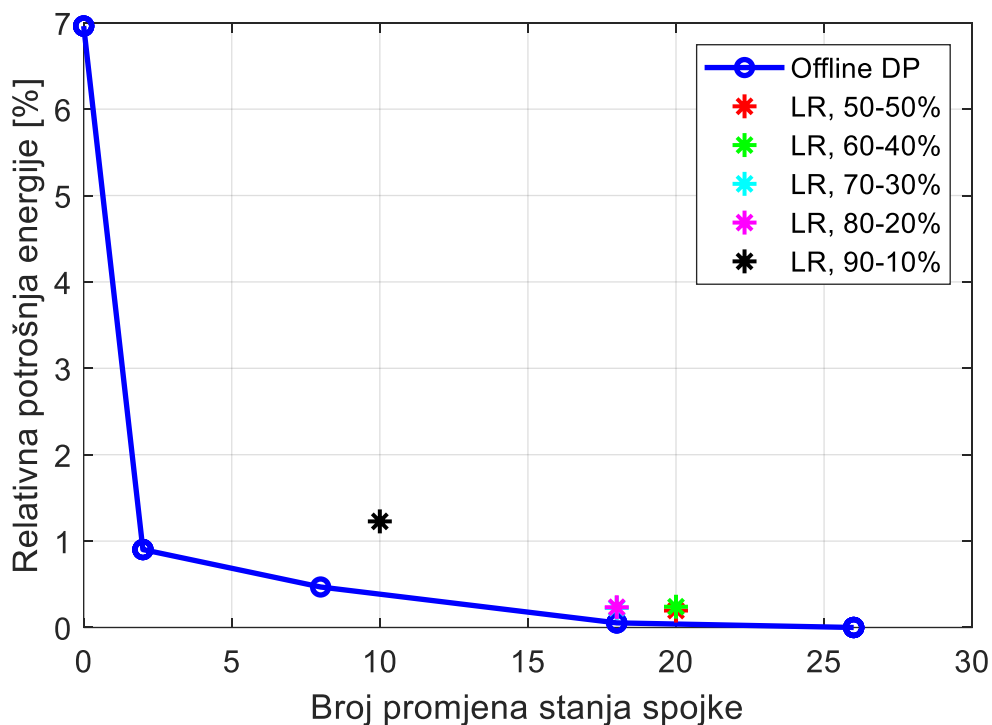
Također, grafovi prikazuju koliko dugo svako stanje spojke traje prije nego što dođe do ponovne promjene. Ovo je ključno za procjenu učinkovitosti prijenosa snage i stabilnosti sustava tijekom vožnje.



Slika 15. WLTP usporedna analiza performansi LR metode za različita podešenja praga vrijednosti spram globalno optimalne DP Pareto fronte



Slika 16. UDDS usporedna analiza performansi LR metode za različita podešenja praga vrijednosti spram globalno optimalne DP Pareto fronte



Slika 17. NEDC usporedna analiza performansi LR metode za različita podešenja praga vrijednosti spram globalno optimalne DP Pareto fronte

Prikazani grafovi (slike: 15, 16 i 17) važni su jer prikazuju usporedbu između optimalnih rješenja dobivenih metodom dinamičkog programiranja (DP) i rezultata strategije logističke regresije (LR) za smanjenje potrošnje energije i broja prebačaja stanja spojke. Ova usporedba omogućuje razumijevanje koliko se realistične strategije, poput LR, približavaju globalno optimalnim rezultatima te kako se balansiraju energetska učinkovitost i broj promjena stanja spojke.

DP Pareto fronta pokazuje optimalnu liniju kompromisa između broja promjena stanja spojke i relativne potrošnje energije. Kako broj prebačaja raste, relativna potrošnja energije opada, ali na mnogo nižim razinama dolazi do sve manjeg poboljšanja u potrošnji.

LR strategije daju rješenja koja su vrlo blizu DP Pareto fronti (unutar 1% razlike), što znači da je odabrana strategija optimiranja vrlo efikasna i približava se teoretski optimalnim rezultatima. Pogotovo kod omjera 90-10% (crne zvjezdice), broj promjena stanja spojke se značajno smanjuje dok je potrošnja energije unutar prihvatljivih granica.

Iz grafova ovog poglavlja (slike: 15, 16 i 17.) možemo uspoređivati broj promjena stanja spojki sa relativnom potrošnjom energije kao i razlike u Pareto strategiji dobivenoj dinamičkim programiranjem i strategiji logističke regresije.

Svi zaključci iz ovog poglavlja, koji se odnose na WLTP ciklus mjerenja i rezultate, primjenjivi su i na ostale vozne cikluse. Bez obzira na specifičnosti pojedinog ciklusa, obrasci ponašanja strategija upravljanja, kompromisi između potrošnje energije i broja promjena stanja spojke te učinkovitost predloženih metoda ostaju konzistentni. Stoga, rezultati i usporedbe dobivene za WLTP mogu se generalizirati na sve vozna cikluse koji su već spomenuti u ovom radu.

6. ZAKLJUČAK

Kroz ovaj rad došli smo do niza važnih zaključaka, s naglaskom na učinkovitost primjene logističke regresije (LR) u rješavanju specifičnih "binarnih" problema, odnosno problema koji uključuju samo dva moguća ishoda. Pokazali smo da se modelom LR vrlo elegantno može pristupiti ovakvim izazovima, te da nije bilo posebno zahtjevno modelirati ovaj pristup nakon što smo vizualno prikazali skup podataka i definirali tražena rješenja.

Jedan od najzanimljivijih aspekata rada bio je proces treniranja modela. Kroz ovaj proces, koristili smo prethodno prikupljene podatke kako bismo model naučili prepoznavanju obrazaca i donošenju odluka u budućim situacijama. Definirali smo specifične zahtjeve modelu, poput minimizacije funkcije troška, kako bi mogao donositi što preciznije odluke u realnim uvjetima. Trening modela omogućio je da LR metoda uči iz poznatih podataka te zatim primjenjuje naučeno na nove, nepoznate situacije, s ciljem optimiranja odnosa između potrošnje energije i broja prebačaja stanja spojke.

Nakon što je model bio treniran, implementirali smo ga na stvarne podatke, uspoređujući rezultate s optimalnim rješenjima dobivenim pomoću metode dinamičkog programiranja. Cilj je bio analizirati kako se LR strategija, s unaprijed definiranim granicama za promjenu stanja spojke, nosi u odnosu na DP optimalne Pareto fronte, koje predstavljaju najbolje moguće rješenje kompromisa između energijskih gubitaka i broja prebačaja.

Na kraju, možemo zaključiti da je LR model pokazao iznimnu konkurentnost u odnosu na idealizirani slučaj, budući da su rezultati LR-a u gotovo svim mjerenjima unutar 1% razlike u odnosu na DP optimalna rješenja. Ova činjenica pokazuje da je LR strategija sposobna vrlo učinkovito balansirati između potrošnje energije i broja promjena stanja spojki, čineći je odličnim izborom za praktične primjene.

LITERATURA

- [1] Halasz, B.: Uvod u termodinamiku, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zagreb, 2021.
- [2] Grilec, J., Zorc, J.: Osnove elektronike, Školska knjiga, Zagreb, 2002.
- [3] Europski parlament, Smanjenje emisija ugljičnih plinova: ciljevi i mjere EU-a
- [4] <https://www.europarl.europa.eu/topics/hr/article/20180305STO99003/smanjenje-emisija-ugljicnih-plinova-ciljevi-i-mjere-eu-a>
- [5] Deur, J. , Škugor, B. , Chen, W. , Zhang, Y. ,Dai, E.: Energy-efficient Straight-line Driving Torque Vectoring for Electric Vehicles with Multiple Motors Equipped with Disconnect Clutches, 18th conference on sustainable development of energy, water and environment systems (SDEWES), Dubrovnik, Croatia, 2023.
- [6] Škugor, B. , Deur, J. , Chen, W. , Zhang, Y. , Dai, E.: Optimization of straight-line driving torque vectoring for energy-efficient operation of electric vehicles with multiple motors and disconnect clutches, Optimization and Engineering, 2024.,
<https://doi.org/10.1007/s11081-024-09902-7>
- [7] E-učenje@FSB – kolegij autonomni sustavi
<https://e-ucenje.fsb.hr/course/view.php?id=2034>
- [8] E-učenje@FSB – kolegij Električni strojevi i pogoni
<https://e-ucenje.fsb.hr/course/view.php?id=2088>
- [9] Matija Miković: Optimiranje upravljačkih varijabli hibridnog električnog vozila serijsko-paralelne konfiguracije korištenjem Pontrjaginovog principa minimuma, diplomski rad, Zagreb, 2023.
<https://zir.nsk.hr/islandora/object/fsb%3A9492/datastream/PDF/view>
- [10] Carnet-Arhiva 2021 Loomen

- <https://arhiva-2021.loomen.carnet.hr/mod/book/view.php?id=1608460&chapterid=196885>
- [11] ResearchGate [Internet]. Šimunović, G. :Application of Artificial Neural Networks to Multiple Criteria Inventory Classification, Sveučilište u Slavonskom Brodu, srpanj 2009.
https://www.researchgate.net/figure/Graph-of-a-Sigmoid-transfer-function-Slika-5-Prikaz-sigmoidne-prijenosne-funkcije_fig4_299049668
- [12] doc.dr.sc. Marko Čupić, FER - Duboko učenje - Optimizacija parametara modela
<https://www.zemris.fer.hr/~ssegvic/du/du3optimization.pdf>
- [13] Augustin Lukić: Analiza podataka korištenjem metoda regresije i klasifikacije podataka, završni rad, Varaždin, 2023.
<https://zir.nsk.hr/islandora/object/foi%3A7952/datastream/PDF/view>
- [14] Šnajder, Jan – Strojno učenje, logistička regresija, FER, 2021.
[https://www.fer.unizg.hr/download/repository/SU-2020-06-LogistickaRegresija\[1\].pdf](https://www.fer.unizg.hr/download/repository/SU-2020-06-LogistickaRegresija[1].pdf)
- [15] Java Point – Machine learning
<https://www.javatpoint.com/cost-function-in-machine-learning>
- [16] Mathworks help center - scatter
<https://www.mathworks.com/help/matlab/ref/scatter.html>
- [17] Mathworks help center - Control Automatic Selection of Colors and Line Styles in Plots
https://www.mathworks.com/help/matlab/creating_plots/defining-the-color-of-lines-for-plotting.html