

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Jure Soldo

Zagreb, godina.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentori:

Prof. dr. sc. Joško Deur , dipl. ing.
Branimir Škugor, mag.ing.

Student:

Jure Soldo

Zagreb, godina.

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

Zahvaljujem se profesoru Jošku Deuru na mentorstvu i uputama, kolegi Branimiru Škugoru na strpljenju i svoj pomoći koju je pružio pri izradi ovog rada, kolegi Zvonimиру Mandiću koji mi je pomogao u boljem razumijevanju C programskog jezika i svojoj obitelji koja mi je pružila bezuvjetnu potporu kroz cijeli prediplomski studij.

Jure Soldo

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	V
POPIS OZNAKA	VII
SAŽETAK.....	X
SUMMARY	XI
1. Uvod	1
2. Model i sustav upravljanja električnog vozila s produljenim dometom.....	3
2.1. Model pogonskog sustava.....	3
2.1.1. Kinematički model transmisije	3
2.1.2. Model baterije	8
2.2. Upravljačke strategije	9
2.2.1. Upravljačka strategija za električni (CD) režim rada.....	9
2.2.2. Upravljačka strategija za hibridni (CS) režim rada.....	11
2.2.2.1. Strategija minimizacije ekvivalentne potrošnje goriva.....	12
2.2.2.2. Regulator zasnovan na bazi pravila (RB)	14
2.2.2.3. Kombinacija RB regulatora sa 1D-ECMS i 2D-ECMS	15
2.2.3. Složeni hibridni režim rada	16
2.3. Optimiranje upravljačkih varijabli	17
3. Proporcionalni (P) regulatora stanja napunjenoosti baterije.....	20
3.1. Optimiranje parametara proporcionalnog regulatora	20
3.2. Rezultati optimiranja parametara P regulatora.....	22
4. Proporcionalno integralni (PI) regulator regulator stanja napunjenoosti baterije	24
4.1. Diskretni PI regulator	24
4.2. Optimiranje parametara PI regulatora.....	25
4.2.1. Numeričko optimiranje parametara PI regulatora.....	25
4.2.2. Analitičko računanje parametara PI regulatora.....	26
4.3. Rezultati optimiranja parametara PI regulatora	31
5. Simulacijski rezultati	33
5.1. Rezultati simulacija EREV vozila sa optimalnim parametrima P regulatora i pragovima uključivanja/isključivanja benzinskog motora.....	33
5.1.1. CS režim rada.....	33
5.1.2. Složeni hibridni režim rada	36
5.2. Rezultati simulacija EREV vozila sa optimalnim parametrima PI regulatora i pragovima uključivanja/isključivanja benzinskog motora.....	39
5.2.1. CS režim rada.....	39
5.2.2. Složeni hibridni režim rada	42
5.3. Usporedni rezultati	46
6. Zaključak	48

POPIS SLIKA

Slika 1. Chevrolet Volt vozilo.....	1
Slika 2. Funkcionalna shema pogonskog sustava električnog vozila s produljenim dometom.	4
Slika 3. Mape korisnosti i krivulje maksimalnih momenata motora s unutarnjim izgaranjem (a), M/G1 stroja (b), te M/G2 stroja (c).	5
Slika 4. Funkcija disipacije snage u praznom hodu (a), funkcija mehaničke korisnosti (b).	7
Slika 5. Otvoreni krug ekvivalentan modelu baterije (a) , ovisnost napona otvorenog kruga o stanju napunjenoosti baterije (b).	8
Slika 6. Kombinirane korisnosti (a), razlika EV i TMEV korisnosti (b).	10
Slika 7. Granice područja načina rada pogonskog sustava za CD režim rada (a), CS režim rada (b).	12
Slika 8. Optimirane donje granične krivulje koje definiraju područje nad kojim ECMS traži optimalnu radnu točku.	13
Slika 9. RB regulator kombiniran sa SoC regulatorom i 1D-ECMS strategijom.	14
Slika 10. RB regulator kombiniran sa 1D-ECMS i 2D-ECMS (a), Oblik težinske funkcije u ovisnosti o pogrešci upravljanje veličine (b).	15
Slika 11. Složeni hibridni način rada u usporedbi s CD/CS režimu rada za različite vozne cikluse.	17
Slika 12. Grafički prikaz CS režima rada u slučaju RB+1D-ECMS u usporedbi sa globalno optimalnim DP za različite vozne cikluse.	18
Slika 13. Primjer pretraživanja skupa rješenja DIRECT algoritma.	21
Slika 14. Blok dijagram standardnog PI regulatora.	24
Slika 15. Regulacijska petlja s modelom baterije.	27
Slika 16. Blok dijagram regulacijskog kruga lineariziranog modela baterije.	28
Slika 17. Iznosi snage P_{batt} u ovisnosti o regulacijskom odstupanju za CS režim rada (a) i složeni hibridni režim rada (b).	30
Slika 18. Odziv lineariziranog simulacijskog modela baterije.....	32
Slika 19. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s optimiranim parametrima P regulatora za pojedine vozne cikluse.	34
Slika 20. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima P regulatora za pojedine vozne cikluse.	35
Slika 21. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s parametrima P regulatora optimiranim za pojedine vozne cikluse.	37
Slika 22. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima P regulatora.	38
Slika 23. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s optimiranim parametrima PI regulatora za pojedine vozne cikluse.....	40
Slika 24. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima PI regulatora za pojedine vozne cikluse.....	41
Slika 25. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s analitički optimiranim parametrima za pojedine vozne cikluse.....	42
Slika 26. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s parametrima PI regulatora optimiranim za pojedine vozne cikluse.....	43

Slika 27. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima PI regulatora.....	45
Slika 28. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima.....	46

POPIS TABLICA

Tablica 1. Karakteristični načini rada pogosnskog sustava za električno vozilo s produljenim dometom.....	5
Tablica 2. Jednadžbe za brzinu i moment transmisije.....	6
Tablica 3. RB+ECMS u usporedbi sa DP rezultatima optimiranja upravljačkih varijabli za razne vozne cikluse u CD režimu rada i CS režimu rada.....	18
Tablica 4. Optimirani parametri P regulatora i pragovi motora za CS režim rada.....	22
Tablica 5. Optimirani parametri P regulatora i pragovi motora za složeni hibridni režim rada.	22
Tablica 6. Optimalni parametri PI regulatora i pragovi uključivanja/isključivanja motora za CS režim rada.....	31
Tablica 7. Optimalni parametri PI regulatora i pragovi uključivanja/isključivanja motora za složeni hibridni režim rada.....	31
Tablica 8. Rezultati simulacije za CS režim rada sa optimiranim parametrima P regulatora za pojedine vozne cikluse.....	34
Tablica 9. Rezultati simulacije za CS režim rada sa robusno optimiranim parametrima P regulatora za pojedine vozne cikluse.....	35
Tablica 10. Usporedbe rezultata simulacija s optimiranim parametrima P regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora za pojedine vozne cikluse.....	36
Tablica 11. Statistički rezultati simulacije s optimiranim parametrima P regulatora za pojedine vozne cikluse.....	36
Tablica 12. Usporedbe rezultata simulacija s robusno optimiranim parametrima P regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora.....	37
Tablica 13. Statistički rezultati simulacije s robusno optimiranim parametrima P regulatora.	38
Tablica 14. Rezultati simulacije za CS režim rada sa optimiranim parametrima PI regulatora za pojedine vozne cikluse.....	39
Tablica 15. Rezultati simulacije za CS režim rada sa robusno optimiranim parametrima PI regulatora za pojedine vozne cikluse.....	40
Tablica 16. Rezultati simulacije za CS režim rada sa analitički optimiranim parametrima PI regulatora.....	41
Tablica 17. Usporedbe rezultata simulacija s optimiranim parametrima PI regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora za pojedine vozne cikluse.....	42
Tablica 18. Statistički rezultati simulacije s optimiranim parametrima P regulatora za pojedine vozne cikluse.....	43
Tablica 19. Usporedbe rezultata simulacija s robusno optimiranim parametrima PI regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora.....	44
Tablica 20. Statistički rezultati simulacije s robusno optimiranim parametrima PI regulatora.	44
Tablica 21. Usporedbe rezultata simulacija s analitički optimiranim parametrima PI regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora.....	45
Tablica 22. Statistički rezultati simulacije s analitički optimiranim parametrima PI regulatora.	46

Tablica 23. Usporedbe rezultata simulacija za razne slučajeve u odnosu prema rezultatima simulacije s P regulatorom s ne optimiranim parametrima za složeni hibridni režim i različite vozne cikluse.	47
Tablica 24. Usporedbe rezultata simulacija za razne slučajeve u odnosu prema rezultatima simulacije s P regulatorom s ne optimiranim parametrima za CS režim i različite vozne cikluse.	47

POPIS OZNAKA

Oznaka	Jedinica	Opis
ω_{cd}	rad/s	izlazna brzina pogonskog sustava.
τ_{cd}	Nm	izlazni moment pogonskog sustava.
i_0	-	prijenosni omjer zupčanika.
h	-	prijenosni omjer planetarnog prijenosnika.
τ_{mg1}	Nm	moment M/G1 motora.
ω_{mg1}	rad/s	brzina M/G1 motora.
ω_{mg2}	rad/s	brzina M/G2 motora.
τ_{mg2}	Nm	moment M/G2 motora.
τ_e	Nm	moment motora s unutarnjim izgaranjem.
ω_e	rad/s	brzina okretanja motora s unutarnjim izgaranjem.
τ_{rmt}	Nm	gubitci izlaznog momenta pogonskog sustava.
τ_R	Nm	ukupni izlazni moment pogonskog sustava.
P_0	W	snaga gubitka u praznom hodu.
ω_L	rad/s	brzina okretanja osovine na strani tereta.
η_{mt}	-	mehanička korisnost transmisije.
v_v	m/s	brzina vozila.
g	m/s^2	ubrzanje gravitacije Zemlje.
R_0	-	faktor otpora zbog kotrljanja.
m_v	kg	masa vozila.
ρ_{zrak}	kg/m^3	gustoća zraka.
C_d	-	faktor otpora zraka.
A_f	m^2	čeona površina vozila.
SoC	%	stanje napunjenoosti baterije.
SoC_R	%	referenca stanja napunjenoosti baterije.
U_{oc}	V	napon otvorenog kruga.
i	A	struja otvorenog kruga.
R	Ω	otpor otvorenog kruga.
R_{ch}	Ω	otpor otvorenog kruga pri punjenju baterije.
R_{dch}	Ω	otpor otvorenog kruga pri pražnjjenju baterije.
P_{batt}	W	snaga koju SoC regulator zahtjeva.
Q	J	kapacitet baterije.
Q_{max}	J	maksimalni kapacitet baterije.
P_{mg1}	W	snaga M/G1 motora.
P_{mg2}	W	snaga M/G2 motora.

η_{mg1}	-	korisnost M/G1 motora.
η_{mg2}	-	korisnost M/G2 motora.
k_2	-	faktor koji određuje motorski/generatorski način rada MG/2 motora.
k_1	-	faktor koji određuje motorski/generatorski način rada M/G1 stroja.
P_d	W	snaga koju motor s unutarnjim izgaranjem mora postići.
P_e	W	snaga koju motor s unutarnjim izgaranjem.
η_c	-	korisnost baterije pri punjenju.
η_d	-	korisnost baterije pri pražnjenju.
η_{max}	-	korisnost za kombinirani EV/TMEV načine rada.
\dot{m}_{eq}	g/s	ekvivalentni protok energije.
\dot{m}_f	g/s	protok goriva.
m_{batt}	g/s	ekvivalentni tok goriva iz baterije.
m_f	g	potrošnja goriva.
m_{eq}	g	ekvivalentna potrošnja energije.
η_{batt}	-	korisnost baterije.
A_{ek}	g/kWh	specifična potrošnja goriva.
e_{SoC}	-	odstupanje stvarnog stanja napunjenosti baterije od referentnog.
W	-	težinska funkcija.
b	-	faktor težinske funkcije.
t_f	s	krajnje vrijeme simulacije.
t_{dc}	s	trajanje voznog ciklusa.
s_{mode}	-	način rada pogonskog sustava.
K_p	W	proporcionalno pojačanje P regulatora stanja napunjenosti baterije.
x_{m_z}	-	mrtva zona.
P_{off}	W	prag isključivanja motora s unutarnjim izgaranjem.
P_{on}	W	prag uključivanja motora s unutarnjim izgaranjem.
J	-	kriterijska funkcija za složeni hibridni režim rada.
K	-	faktor ponderiranja kriterijske funkcije.
T_I	s	vremenska konstanta PI regulatora.
T	s	vrijeme uzorkovanja.
T_P	Ω	vremenska konstanta integratora.
t	s	vremenska konstanta pražnjenja baterije.
A_{ek_mean}	g/kWh	srednja specifična potrošnja goriva.
e_{RMS}	-	srednje kvadratno odstupanje pogreške stanja napunjenosti baterije.
p_1	%	usporedba potrošnje goriva za CS režim rada s ne optimiranim parametrima

<i>Jure Soldo</i>		<i>Završni rad</i>
p_2	%	usporedba potrošnje goriva za CS režim rada s optimiranim parametrima
p_3	%	usporedba potrošnje goriva za složeno hibridne režime rada
$m_{f,ECMS0}$	g	ukupna potrošnja goriva za simulaciju s ne optimiranim parametrima u CS režimu rada
$m_{f,ECMS}$	g	ukupna potrošnja goriva za simulaciju s optimiranim parametrima u CS režimu rada
$m_{f,DP}$	g	ukupna potrošnja goriva dobivena dinamičkim programiranjem

SAŽETAK

U ovom se radu opisuje upravljačka struktura električnog vozila s produljenim dometom te se predlažu unaprjeđenja regulatora stanja napunjenosti baterije. Optimiraju se parametri postojećeg proporcionalnog regulatora stanja napunjenosti s mrvom zonom te se implementira proporcionalno integralni regulator čiji se parametri također optimiraju. Rezultati optimiranja se uspoređuju s prvotnim rezultatima regulatora stanja napunjenosti baterije te se na osnovi toga daje završni zaključak.

Ključne riječi: Automobilska mehatronika, Regulacija, Optimiranje.

SUMMARY

This paper describes control strategy of extended range electric vehicle and proposes improvements for the state of charge controller. Parameters of current proportional state of charge controller with dead zone are optimized, new proportional-integral state of charge controller is introduced and its parameters are also optimized. Simulations are conducted for the cases of using P and PI state-of-charge controllers with optimized parameters. Finally, conclusions based on simulation results are given.

Key words: Automotive Mechatronics, Control Strategy, Optimization.

1. Uvod

Električno vozilo s produljenim dometom (eng. Extended Range Electric Vehicle, EREV) kombinira prednosti električnog vozila, kao što su visoka korisnost, niska razina buke, nulti nivo emisije ispušnih plinova, niska cijena energije i prednosti hibridnog električnog vozila kao što su visoka specifična gustoća energije i veći domet vožnje.

U ovom radu korišten je simulacijski model Chevrolet Volt automobila. Chevrolet Volt je utično električno vozilo s produljenim dometom (eng. Extended Range Vehicle, EREV) koji koristi motor s unutarnjim izgaranjem za održanje stanja napunjenoosti baterije i produljenja dometa vozila. Volt je jedan od najučinkovitijih automobila sa benzinskim motorom no postoji težnja za dalnjim unapređenjem korisnosti i voznim dometom. Prepreka komercijalnom uspjehu električnih vozila je ograničenje voznog dometa no s ovom inovacijom ta se prepreka može premostiti. Volt radi kao električno vozilo dok stanje napunjenoosti baterije ne dođe do određene razine, te se tada se uključuje motor s unutarnjim izgaranjem koji održava stanje napunjenoosti baterije. Dok je motor s unutarnjim izgaranjem uključen može se periodički povezivati s generatorom pomoću spojke. Regenerativno kočenje također doprinosi punjenju baterije.



Slika 1. Chevrolet Volt vozilo.

Kako bi se minimizirala potrošnja goriva u voznim ciklusima, te povećala učinkovitost i vozni domet, potrebno je projektirati približno optimalan upravljački sustav električnog vozila s produljenim dometom. Projektiranje upravljačkog sustava uključuje sintezu metode odabira

optimalnog načina rada, odabiranje najboljih radnih točaka pogonskih motora, odabiranje najboljih kombinacija načina rada za zadane vozne cikluse, optimiranje pragova uključivanja/isključivanja motora s unutarnjim izgaranjem i optimiranje parametara regulatora stanja napunjenosti.

U ovom radu opisana je postojeća struktura sustava upravljanja električnim vozilom s produljenim dometom te su predložena moguća poboljšanja regulatora stanja napunjenosti baterije kako bi se smanjila potrošnja goriva. U drugom poglavlju opisan je model pogonskog sustava i upravljačke strategije s osvrtom na važnost optimiranja upravljačkih varijabli. U trećem poglavlju predloženo je unaprjeđenje trenutnog proporcionalnog regulatora stanja napunjenosti baterije s mrvom zonom. U četvrtom poglavlju postavljen je proporcionalno integralni regulator stanja napunjenosti baterije te su pokazani rezultati optimiranje parametra regulatora. U petom poglavlju prikazani su rezultati svih simulacija, a u šestom poglavlju dan je zaključak.

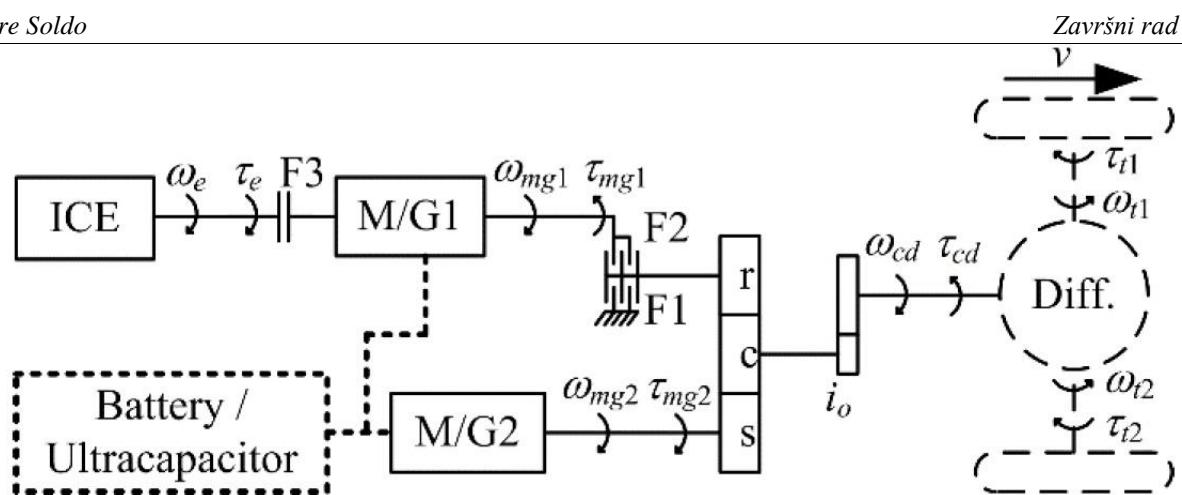
2. Model i sustav upravljanja električnog vozila s produljenim dometom

U ovom radu razmatran je model pogonskog sustava EREV vozila. Transmisija EREV-a sastoji se od motora sa unutarnjim izgaranjem, dva električna motora, tri spojke i elektrokemijske baterije. Ovisno o stanju sklopki pogonski sustav može raditi u različitim načinima rada kao što su jedno-motorni (eng. Electric Vehicle, EV) i dvo-motorni (eng. Two Motor Electric Vehicle, TMEV) načini rada koji su aktivni prilikom pražnjenja baterije te serijski (eng. Serial Hybrid Electric Vehicle, SHEV) i serijsko paralelni hibridni (eng. Serial Parallel Hybrid Vehicle, SPHEV) načini rada, koji su uz EV i TMEV načine rada, aktivni prilikom održavanja stanja napunjenosti baterije. Za upravljanje EREV-om koristi se regulator zasnovan na bazi pravila (eng. Rule Based controller, RB regulator) proširen regulatorom stanja napunjenosti baterije (eng. State of Charge controller, SoC regulator) te strategijom minimizacije ekvivalentne potrošnje (eng. Equivalent Consumption Minimization Strategy, ECMS) koja rezultira radnim točkama pogonskog sustava s približno optimalnom korisnošću.

2.1. Model pogonskog sustava

2.1.1. Kinematicki model transmisijske

Pogonski sustav električnog vozila s produljenim dometom sastoji se od motora sa unutarnjim izgaranjem (eng. Internal Combustion Engine, ICE), dva električna stroja koji mogu raditi i u motorskom i u generatorskom načinu rada (Motor/Generator, M/G1 i M/G2), planetarnog prijenosnika koji služi kao razdjelnik izlazne snage, tri spojke (F1, F2 i F3) koje služe za prebacivanje između različitih načina rada i elektrokemijske baterije.



Slika 2. Funkcionalna shema pogonskog sustava električnog vozila s produljenim dometom.

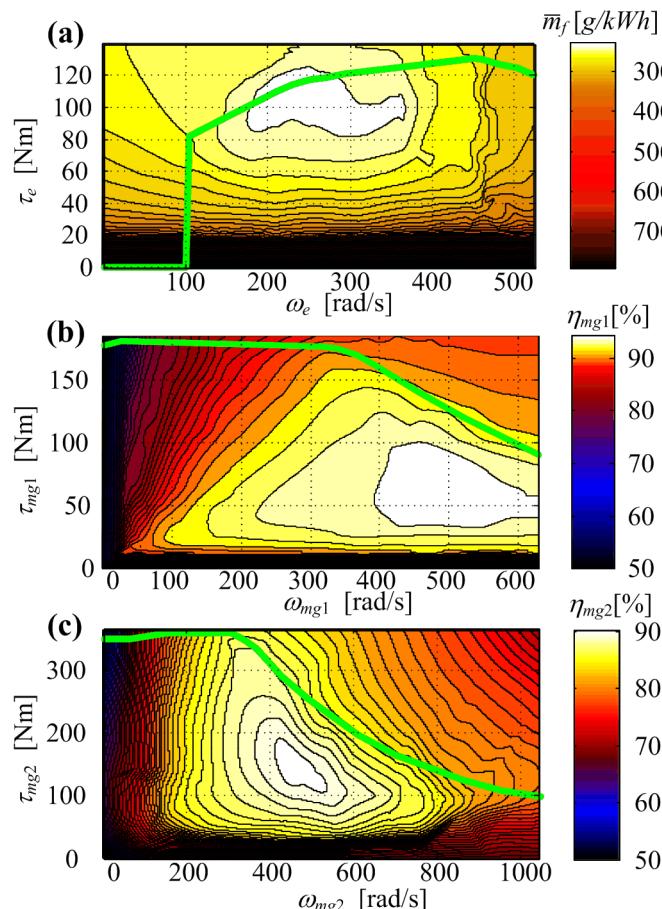
Postoji 5 karakterističnih načina rada pogonskog sustava, koji se mogu podijeliti u 3 skupine. U prvoj skupini, u kojoj nema podijele izlazne snage preko planetarnog prijenosnika, spojka F1 je aktivna ($F1=ON$), a spojka F2 je neaktivna ($F2=OFF$) gdje je planetarni prijenosnik sveden na standardni zupčani prijenosnik s jednim ulazom i jednim izlazom pa je brzina motora M/G2 direktno proporcionalna izlazu pogonskog sustava ω_{cd} kao kod EV načina rada ili SHEV načina rada. Spojka F3 služi za prebacivanje između električkog načina rada ($F3=OFF$) i serijsko hibridnog načina rada ($F3=ON$). Druga skupina uključuje raspodjelu izlazne snage preko planetarnog prijenosnika ($F1=OFF, F2=ON$), gdje spojka F2 povezuje motor M/G1 sa planetarnim zupčanikom, kombinirajući izlaze električnih motora tako da su im brzine međusobno ovisne i ovisne o izlaznoj brzini ω_{cd} . U ovu skupinu ubrajaju se serijsko paralelni način rada (SPHEV, $F3=ON$) i električni dvomotorni način rada (TMEV, $F3=OFF$). Treća grupa načina rada pogonskog sustava odnosi se na prazni hod pogonskog sustava kad su spojke F1 i F2 neaktivne dok spojka F3 može biti aktivna za punjenje baterije (eng. battery charging, BC) ili pokretanje vozila ili može biti neaktivna za potpuno prazni hod.

Tablica 1. prikazuje sve načine rada pogonskog sustava, stanja spojki u tim načinima rada te režime rada EREV-a gdje CD označava režim pražnjenja baterija, a CS režim održavanje stanja napunjenoosti baterije.

Tablica 1. Karakteristični načini rada pogosnskog sustava za električno vozilo s produljenim dometom.

Način rada	F1	F2	F3	Režim rada	Podjela snage
EV	1	0	0	CD	Nema
SHEV	1	0	1	CS	Nema
TMEV	0	1	0	CD	Ima
SPHEV	0	1	1	CS	Ima
BC	0	0	1	CS	-
Prazan hod	0	0	0	-	-

Na slici 2 prikazane su mape korisnosti motora s unutarnjim izgaranjem i dva električna stroja zajedno sa pripadnim krivuljama maksimalnih momenta.



Slika 3. Mape korisnosti i krivulje maksimalnih momenata motora s unutarnjim izgaranjem (a), M/G1 stroja (b), te M/G2 stroja (c).

Tablica 2 sadrži jednadžbe za izlaznu brzinu i moment transmisije za različite načine rada.

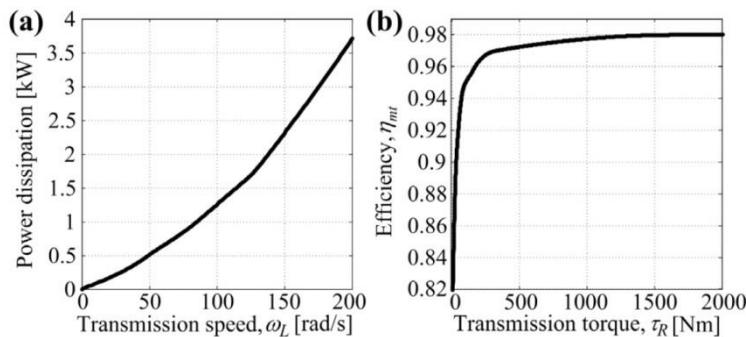
Tablica 2. Jednadžbe za brzinu i moment transmisije.

Način rada	ω_{cd}	τ_{cd}
EV i SHEV	$\frac{1}{i_0(h+1)}\omega_{cd}$	$i_0(h+1)\tau_{mg2}$
SPHEV i TMEV	$\frac{1}{i_0(h+1)}(\omega_{mg2} + h\omega_{mg1})$	$i_0(h+1)\tau_{mg2} = i_0(h+1)h^{-1}(\tau_e - \tau_{mg1})$
Način rada	ω_e	τ_e
EV	0	0
SHEV	ω_{mg1}	τ_{mg1}
SPHEV	ω_{mg1}	$h\tau_{mg2} + \tau_{mg1}$
TMEV	0	0

Pri EV i SHEV načinima rada pogonskog sustava brzina i moment glavnog pogonskog motora M/G2 su proporcionalni brzini (ω_{cd}) i momentu (τ_{cd}) koje vozač zahtjeva u voznom ciklusu. U TMEV i SPHEV načinu rada, moment motora M/G2 je balansiran momentom motora M/G1 koji je manje snage, dok oba motora određuju izlaznu brzinu pogonskog sustava. Gubitak mehaničke snage pogonskog sustava dodan je u izlazni model tako da je izlazni moment τ_{cd} iz tablice 2 umanjen za gubitak momenta τ_{rmt} tako da je ukupni izlazni moment τ_R jednak:

$$\tau_{cd} = \tau_R + \tau_{rmt} = \frac{P_0(\omega_L)}{\omega_L} + \frac{\tau_R}{\eta_{mt}(\tau_R)} , \quad (1)$$

gdje formula za gubitak momenta sadrži disipaciju snage zbog praznog hoda P_0 / ω_L (slika 3a) i gubitak koji ovisi o opterećenju i mehaničkoj korisnosti transmisije.



Slika 4. Funkcija disipacije snage u praznom hodu (a), funkcija mehaničke korisnosti (b).

Standardni ciklusi vožnje su unaprijed definirani trajanjem i profilom brzine v_v uz pretpostavku nultog nagiba ceste, a u simulacijskim modelima zamjenjuju ulogu vozača. Ukupni izlazni moment pogonskog sustava τ_R može se izračunati preko jednadžbe gibanja vozila.

$$\tau_R = \left(\dot{v}m_v + R_0 m_v g + 0.5 \rho_{zrak} C_d A_f v_v^2 \right). \quad (2)$$

Prvi izraz ove jednadžbe odnosi se na moment akceleracije vozila, drugi izraz odnosi se na otpor kotrljanja dok se treći izraz odnosi na aerodinamički otpor.

2.1.2. Model baterije

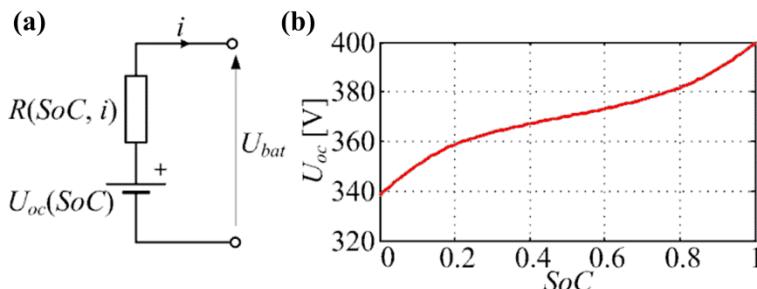
Model baterije opisan je jednadžbom stanja :

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

gdje SoC predstavlja stanje napunjenosti baterije i za njega vrijedi $0 \leq SoC \leq 1$. Stanje napunjenosti baterije definirano je kao omjer trenutnog kapaciteta baterije i maksimalnog kapaciteta baterije :

$$SoC = \frac{Q(t)}{Q_{\max}}. \quad (4)$$

U_{oc} predstavlja napon otvorenog kruga, R predstavlja unutarnji otpor otvorenog kruga koji poprima vrijednost R_{ch} prilikom punjenja odnosno R_{dch} prilikom pražnjenja baterije. Q_{\max} označava maksimalni kapacitet baterije. Model baterije koji se koristi u ovom radu prikazan je na slici 5.



Slika 5. Otvoreni krug ekvivalentan modelu baterije (a), ovisnost napona otvorenog kruga o stanju napunjenosti baterije (b).

U ovom modelu napon U_{oc} ovisan je o stanju napunjenosti baterije dok je otpor R ovisan o stanju napunjenosti baterije i o smjeru struje (različite vrijednosti se koriste prilikom punjenja i pražnjenja baterije). Snaga baterije se računa prema :

$$P_{batt} = P_{mg2} - P_{mg1} = \eta_{mg2}^{k_2} \omega_{mg2} \tau_{mg2} - \eta_{mg1}^{k_1} \omega_{mg1} \tau_{mg1}, \quad (5)$$

gdje $\eta_{mg1,2}$ predstavljaju korisnost M/G1 električnih stroja, odnosno M/G2 električnog stroja. Koeficijenti $k_{1,2}$ su jednak –1 kada električni strojevi rade u motorskom načinu rada, a +1 kad rade u generatorskom načinu rada. Prilikom punjenja, korisnost baterije je :

$$\eta_c = \frac{P_d(t)}{|P_c(t)|} = \frac{U_{oc}(t) - R_{idc}|i(t)|}{U_{oc}(t) + R_{ic}|i(t)|}, \quad (6)$$

gdje $P_c(t)$ i $P_d(t)$ označavaju potrebnu snagu za punjenje odnosno pražnjenje baterije

Pri pražnjenju baterije, njezina korisnost je jednaka :

$$\eta_d = \left(1 + \frac{i^2(t)R_{idc}}{P_{batt}} \right)^{-1}. \quad (7)$$

2.2. Upravljačke strategije

Dva osnovna režima rada električnog vozila s produljenim dometom su pražnjenje baterije (eng. Charge Depletion, CD), koji traje dok stanje napunjenosti baterije ne padne do unaprijed zadane vrijednosti (kod Chevrolet Volta je to 30%), te održavanje stanja napunjenosti baterije (eng. Charge Sustaining, CS) u kojem se održava stanje napunjenosti baterije koje je postignuto na kraju ciklusa pražnjenja. Kombinacija ova dva režima rada EREV-a naziva se i CD/CS režim rada. CD režim rada uključuje EV i TMEV načine rada pogonskog sustava dok CS režim uključuje sve načine rada pogonskog sustava, EV, TMEV, SHEV i SPHEV. Ako je unaprijed poznato trajanje voznog ciklusa, što je slučaj kod standardiziranih voznih ciklusa, baterija se može postepeno prazniti kombinirajući sve načine rada pogonskog sustava kroz cijeli ciklus vožnje. Takav režim rada naziva se složeni hibridni režim rada (eng. Blended, BLND). Na ovaj se način može bolje upravljati pogonskim sustavom i smanjiti potencijalne gubitke i potrošnju goriva.

Za testiranje i uspoređivanje različitih načina rada EREV-a koriste se standardizirani vojni ciklusi s unaprijed definiranim trajanjem ciklusa, profilom brzine vozila i profilom izlaznog momenta pogonskog sustava. Vozni ciklusi korišteni u ovom radu su NEDC (New European Driving Cycle), UDDS (Urban Dynamometer Driving Schedule), HWFET (Highway Fuel Economy Test) i US06.

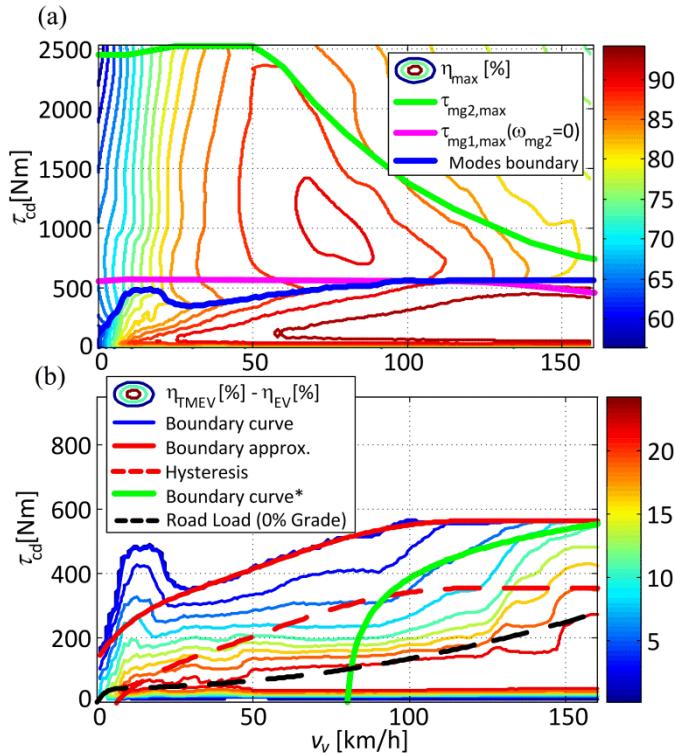
2.2.1. Upravljačka strategija za električni (CD) režim rada

Upravljačka strategija za CD režim rada sastoji se od dva dijela. U prvom dijelu određuje se optimalni način rada pogonskog sustava koji u slučaju CD-a mogu biti EV ili TMEV, dok se u drugom dijelu traže optimalne radne točke pogonskog sustava za odabrani

način rada i vozačeve zahtjeve pazeći pritom na fizikalna ograničenja momenta i brzine. U EV načinu rada za pokretanje vozila koristi se samo M/G2 električni motor. Radne točke (ω_{mg2}, τ_{mg2}) i korisnost pogonskog sustava određuju se u ovisnosti o brzini vozila v_v i izlaznom momentu τ_{cd} . U TMEV načinu rada za pogon vozila koriste se oba električna motora, M/G1 i M/G2. Električni motori se mogu kombinirati kako bi se zadovoljili vozačevi zahtjevi za momentom pri zadanim brzinama. Momenti električnih motora τ_{mg1} i τ_{mg2} ovisni su o zahtijevanom momentu τ_{cd} dok je za brzine ω_{mg1} i ω_{mg2} uveden jedan stupanj slobode što znači da im iznosi mogu varirati kako bi se postigla najveća moguća korisnost prema formuli:

$$\eta_{msx} = \frac{\eta_{mg1} P_{mg1} + \eta_{mg2} P_{mg2}}{P_{mg1} + P_{mg2}} . \quad (8)$$

Ova jednadžba daje mapu korisnosti na slici 5a. Za neke brzine vozila i izlazne momente efikasnije je raditi u EV načinu rada, dok je za neke druge radne točke TMEV način rada efikasniji. Podebljana plava linija na slici označuje granicu između područja gdje su EV odnosno TMEV načini rada efikasniji. Na slici 5b prikazana je mapa razlika korisnosti između EV i TMEV načina rada pogonskog sustava. Ovdje je granična krivulja aproksimirana monotono rastućom crvenom krivuljom.



Slika 6. Kombinirane korisnosti (a), razlika EV i TMEV korisnosti (b).

Nadzorni regulator prebacuje između dva načina rada kad god izlazna radna točka pogonskog sustava prelazi graničnu krivulju. Kako bi se izbjegla česta promjena između načina rada uvedene je histereza oko granične krivulje.

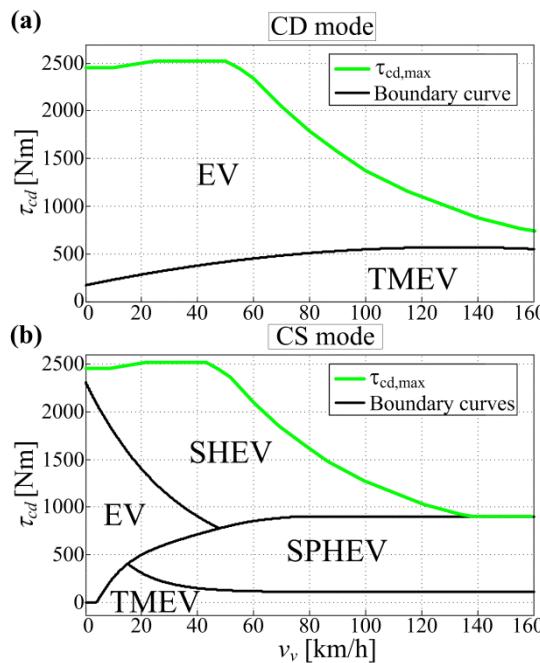
Odabir radnih točaka električkog motora M/G2 prilikom EV načina rada provodi se jednostavno prema formulama iz Tablice 2. Pri odabiranju radnih točaka motora M/G1 i M/G2 prilikom TMEV načina rada, momenti električnih motora ovisni su o zahtijevanom izlaznom momentu τ_{cd} prema tablici 2. Optimalne brzine motora M/G1 i M/G2, koje su međusobno ovisne, nalaze se pretragom skupa rješenje u rasponu od nula do $\omega_{mg1,max}$, gdje je $\omega_{mg1,max}$ maksimalna brzina motora M/G1.

Kod uvođenja histereze oko granične krivulje između EV i TMEV načina rada, broj prebacivanja između ta dva načina rada se znatno smanjuje čime se poboljšavaju vozne karakteristike. No u tom slučaju gubi se na korisnosti što je izraženije kod širih histereza.

2.2.2. Upravljačka strategija za hibridni (CS) režim rada

Kad stanje napunjenosti baterije dosegne unaprijed određeni iznos (30% u ovom slučaju) aktivira se CS režim rada sa ciljem održavanja stanja napunjenosti na 30%. Regulator zasnovan na bazi pravila (RB) određuje kada će se motor s unutarnjim izgaranjem (ICE) uključiti ili isključiti. Ako je ICE motor ugašen odabiru se EV ili TMEV načini rada pogonskog sustava prema kriterijima opisanim u prošlom poglavljtu. Kada je ICE motor upaljen optimalni način rada pogonskog sustava odabire se prema kriteriju strategije minimizacije ekvivalentne potrošnje (eng. equivalent consumption minimization strategy, ECMS) koja minimizira potrošnju goriva za zadane izlaze pogonskog sustava. Za svaku radnu točku zadalu sa brzinom vozila v_v i izlaznim momentom τ_{cd} izračunava se ECMS kriterijska funkcija za SHEV i SPHEV načine rada. Onaj način rada koji minimizira ECMS kriterijsku funkciju je optimalni za tu radnu točku. RB regulator proširen je sa dodatnim pravilima kada je stanje napunjenosti baterije oko 30% kako bi se povećala ukupna korisnost.

Prvo, ako je SPHEV način rada određen kao optimalan način rada a vozačev zahtjev momenta za zadalu brzinu vozila je ispod SPHEV-TMEV granične krivulje TMEV način rada se odabire kao optimalni. Drugo, ako je SHEV način rada odabran kao optimalan a vozačev je zahtjev momenta za zadalu brzinu vozila ispod SHEV-EV granične krivulje, odabire se EV način rada.



Slika 7. Granice područja načina rada pogonskog sustava za CD režim rada (a), CS režim rada (b).

2.2.2.1. Strategija minimizacije ekvivalentne potrošnje goriva

Kako bi se dodatno smanjila potrošnja goriva RB regulator dopunjen je strategijom minimizacije ekvivalentne potrošnje (ECMS). Tok snage baterije zamjenjuje se takozvanim ekvivalentnim tokom goriva baterije \dot{m}_{batt} i dodaje se stvarnoj potrošnji goriva ICE motora :

$$\dot{m}_{eq} = \dot{m}_f + \dot{m}_{batt}(P_{batt}, \eta_{batt}, A_{ek}) , \quad (9)$$

što se može zapisati kao :

$$\dot{m}_{eq} = \begin{cases} A_{ek} P_e + A_{ek} \eta_{batt} P_{batt}, & P_{batt} < 0 \\ A_{ek} P_e + \bar{A}_{ek} \eta_{batt}^{-1} P_{batt}, & P_{batt} > 0 \end{cases} , \quad (10)$$

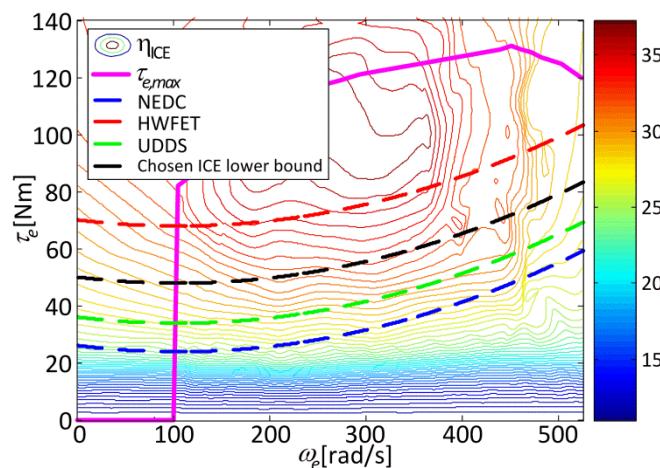
gdje je P_{batt} snaga punjenja odnosno pražnjenja baterije dana u jednadžbi (4), η_{batt} je korisnost baterije definirana u (5) a A_{ek} specifična potrošnja goriva motora koja se može očitati iz mape specifične potrošnje goriva na slici 2.

$$A_{ek} = \bar{m}_{fuel}(\omega_{cd}, \tau_{cd}) [g / Ws] . \quad (11)$$

U slučaju pražnjenja baterije ekvivalentna potrošnja goriva motora je \bar{A}_{ek} , radi jednostavnosti uzima se da je \bar{A}_{ek} prosječna specifična potrošnja goriva na krivulji maksimalnog momenta

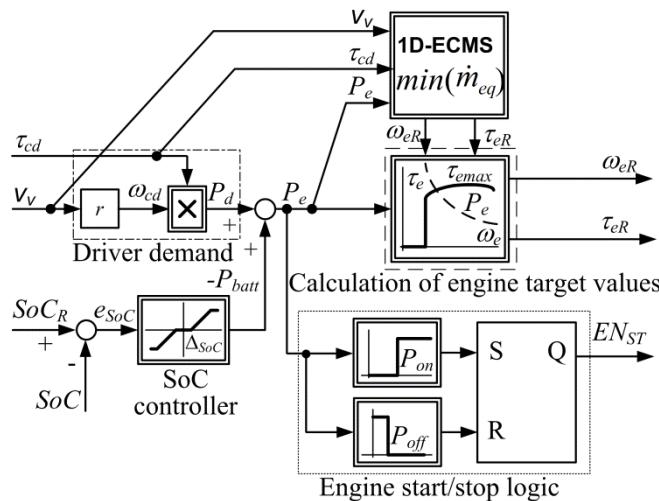
ICE motora. Cilj ECMS-a je minimizirati funkciju (10) u svakom vremenu uzorkovanja, kako bi se našla optimalna radna točka pogonskog sustava u tom trenutku.

Dva su pristupa ECMS optimiranju su 1D-ECMS i 2D-ECMS. 1D-ECMS traži optimalne radne točke na krivulji konstantne snage ICE motora P_e . 2D-ECMS traži optimalne točke u 2D području mape ICE motora. U oba slučaja koriste se Hooke-Jeeves algoritam za usmjereni pretraživanje. Područje pretraživanje mape ICE motora treba se ograničiti samo na visoke momente zato što će ECMS u suprotnom pokušavati naći optimalne radne točke u području nižih momenata kako bi smanjio potrošnju goriva u SPHEV načinu rada. Ako područje pretraživanja mape ICE motora nije ograničena samo na radne točke visoke snage motora stanje napunjenosti baterije će se polako smanjivati jer ICE motor ne održava adekvatno punjenje baterije, RB regulator će eventualno to ispraviti ali pri nižoj korisnosti. Slika 8 prikazuje optimirane donje granične krivulje za različite vozne cikluse te prosječnu graničnu krivulju za sve vozne cikluse.



Slika 8. Optimirane donje granične krivulje koje definiraju područje nad kojim ECMS traži optimalnu radnu točku.

2.2.2.2. Regulator zasnovan na bazi pravila (RB)



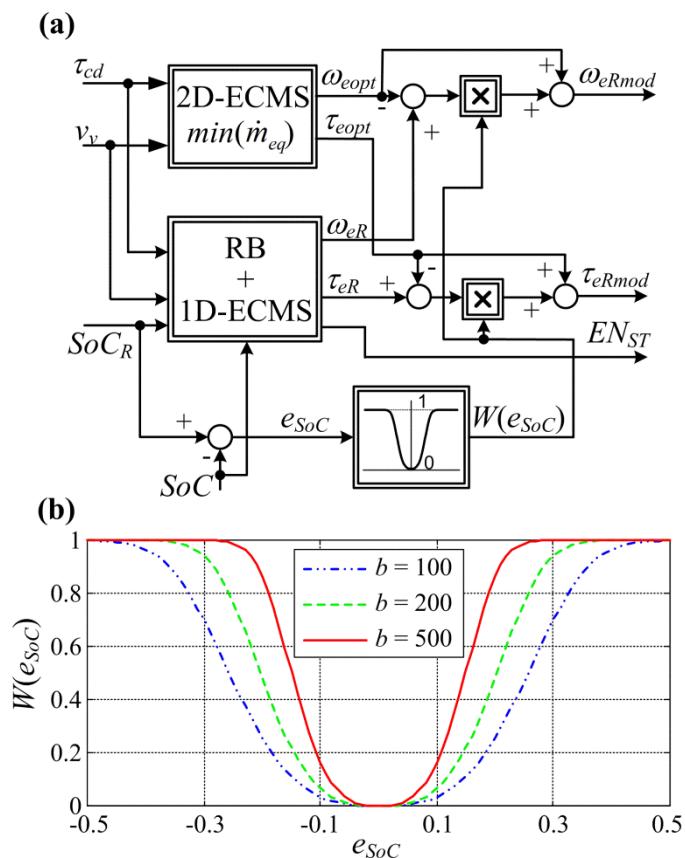
Slika 9. RB regulator kombiniran sa SoC regulatorom i 1D-ECMS strategijom.

Slika 9 prikazuje blok dijagram RB regulatora proširenog sa 1D-ECMS optimizacijskim algoritmom. RB regulator kombinira vozačev zahtjev za snagom P_d i snagu baterije P_{batt} koju zahtjeva SoC regulator kako bi se izračunala potrebna snaga motora P_e . 1D-ECMS traži optimalne radne točke duž krivulje konstantne snage P_e koju motor mora postići kako bi se minimizirala funkcija (10).

SoC regulator je zadužen za održavanje stanja napunjenoosti SoC baterije oko njezine reference SoC_R . Kad SoC počne odstupati od svoje reference SoC regulator mjeri pogrešku SoC -a te na osnovi toga računa snagu P_{batt} koja se zbraja s vozačevim zahtjevom snage P_d te šalje u ICE motor i 1D-ECMS optimizacijski algoritam. Ako je SoC niži od SoC_R bateriju treba napuniti, P_{batt} je pozitivan te se zbraja s P_d što znači da ICE motor mora ostvariti snagu $P_e = P_d + P_{batt}$ kako bi udovoljio svim zahtjevima snage. Ako je SoC viši od SoC_R bateriju treba prazniti, P_{batt} je negativan a motora sad mora ostvariti snagu $P_e = P_d - P_{batt}$ koja je manja od one u prethodnom slučaju jer sad je cilj sniziti razinu SoC -a do referentne vrijednosti. Kod SoC regulatora uvedena je i mrtva zona koja predstavlja određeni stupanj slobode za ECMS optimizacijski algoritam jer na taj način ECMS optimizacijski algoritam može tražiti radne točke ICE motora veće korisnosti za vrijeme dok je SoC u granicama mrtve zone. Kad SoC dosegne granice mrtve zone SoC regulator se aktivira i korigira zahtjeve snage.

RB regulator posjeduje još i logiku za isključenje/uključenje motora sa unutarnjim izgaranjem sa pripadnim donjim P_{off} i gornjim P_{on} pragovima. Kada u hibridnom načinu rada zahtijevana snaga P_e prijeđe prag uključivanja P_{on} ICE motor se uključuje, a kad P_e prijeđe prag isključivanja P_{off} ICE motor s isključuje. Ovim se načinom eliminiraju radne točke pri niskim snagama P_e koje su niže korisnosti.

2.2.2.3. Kombinacija RB regulatora sa 1D-ECMS i 2D-ECMS



Slika 10. RB regulator kombiniran sa 1D-ECMS i 2D-ECMS (a), Oblik težinske funkcije u ovisnosti o pogrešci upravljanje veličine (b).

1D-ECMS minimizira ekvivalentnu potrošnju goriva duž krivulje konstantne snage ICE motora zadovoljavajući tako zahtjeve snage P_e i održavajući stanje napunjenosti baterije SoC . Kada se SoC nalazi oko referentne vrijednosti 2D-ECMS-u se daje više važnosti pri odabiru optimalne radne točke kako bi se smanjila potrošnja goriva. 2D-ECMS ima dva stupnja slobode (ω_{cd}, τ_{cd}) pri odabiru radne točke što mu omogućuje da odabire radne točke ICE motora sa što većom efikasnošću u cijelom operacijskom području. On se kombinira sa

RB+1D-ECMS upravljačkom strukturu preko funkcije promjenjive težine koja je ovisna o pogrešci e_{SoC} koja je definirana $e_{SoC} = SoC_R - SoC$. Oznaka za težinsku funkciju je $W(e_{soc})$.

Kad je SoC blizu SoC_R -a 2D-ECMS je dominantan, a kad se SoC opet počne značajnije udaljavati od referentne vrijednosti RB+1D-ECMS regulator postane dominantan. Oblik težinske funkcije prikazan je na slici 11b i jednak je :

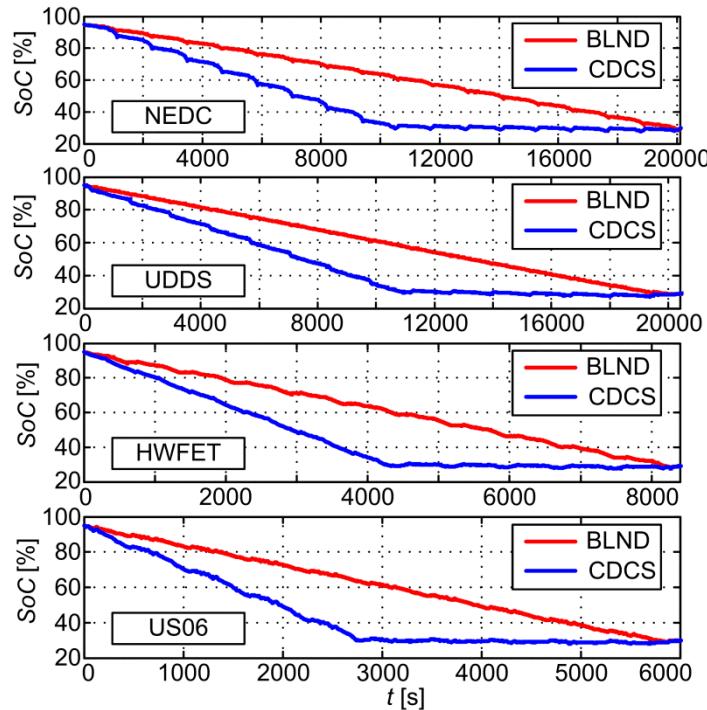
$$W(e_{SoC}) = \left| \tanh \left\{ b [e_{SoC} - \tanh(e_{SoC})] \right\} \right| . \quad (12)$$

2.2.3. Složeni hibridni režim rada

Upravljačka strategija razvijena za CD/CS (slike 8 i 9) režim rada može se primijeniti i za složeni hibridni režim rada. SoC regulator sada treba pratiti referencu koja se mijenja kroz vrijeme, za razliku od CS režima gdje je referenca konstantna. Optimalna SoC trajektorija linearog je oblika i njezin je nagib ovisan o trajanju voznog ciklusa t_{cd} :

$$SoC_R(t) = SoC_R(0) + \frac{(SoC_R(t_f) - SoC_R(0))}{t_{dc}} . \quad (13)$$

Složeni hibridni režim rada sadrži istu upravljačku strategiju kao i CD/CS režim rada samo s drukčjom referencom SoC -a koja je ovisna o duljini vremena voznog ciklusa. Tokom svakog voznog ciklusa, bez obzira na njegovo trajanje, SoC kreće od 95% i na kraju se spusti na 30%.



Slika 11. Složeni hibridni način rada u usporedbi s CD/CS režimu rada za različite vozne cikluse.

Složeni hibridni režim rada nudi više slobode pri optimiranju radnih točaka pogonskog sustava gdje ICE motor pokriva zahtjeve za visokim momentom, gdje mu je veća korisnost, a električni motori pokrivaju područja nižeg momenta kako bi minimizirali gubitke baterije. Ovim načinom postiže se značajnije uštede goriva.

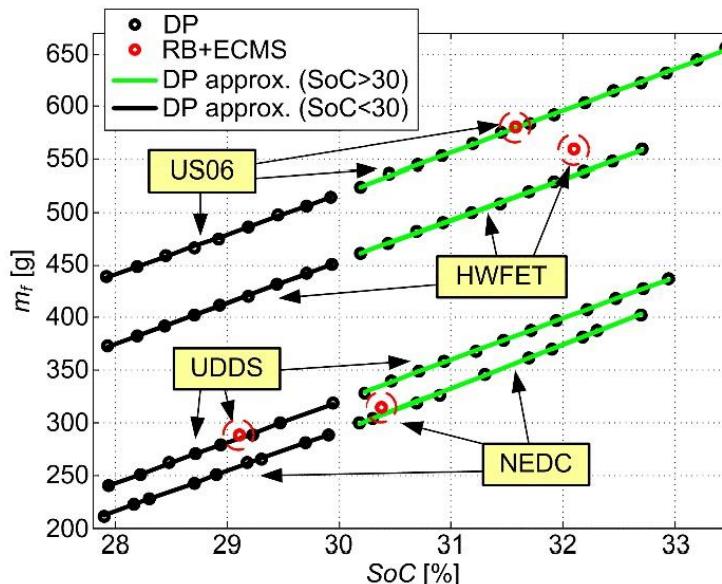
2.3. Optimiranje upravljačkih varijabli

Kako bi se minimizirala potrošnja goriva potrebno je optimirati upravljačke varijable. Pod upravljačke varijable RB+ECMS spadaju moment ICE motora τ_e , brzina električkog motora M/G1 ω_{mg1} te način rada pogonskog sustava s_{mode} (EV, TMEV, SHEV, SPHEV). Za zadani ciklus vožnje u kojem su unaprijed definirani profili brzine vozila i izlaznog momenta RB+ECMS regulator mora naći optimalnu kombinaciju upravljačkih varijabli. Rezultati realne regulacije RB+ECMS regulatorom odstupaju od globalno optimalnih rezultata dobivenih dinamičkim programiranjem (DP). Algoritam dinamičkog programiranja koristi off-line optimizaciju upravljačkih varijabli pogonskog sustava EREV-a s ciljem minimizacije potrošnje goriva pazeći na ograničenja SoC-a i upravljačkih varijabli. U tablici 3 prikazani su usporedbe rezultata optimiranja RB+ECMS-a i DP-a.

Tablica 3. RB+ECMS u usporedbi sa DP rezultatima optimiranja upravljačkih varijabli za razne vozne cikluse u CD režimu rada i CS režimu rada.

CD režim ($SoC_i=95\%$)	DP		RB+ECMS	
	SoC_f [%]	$SoC_i - SoC_f$ [%]	SoC_f [%]	$SoC_i - SoC_f$ [%]
NEDC	87.68	7.32	87.62	7.38 (0.8%)
UDDS	83.74	11.26	83.74	11.26 (0.0%)
HWFET	87.07	7.92	86.51	8.49 (7.2%)
US06	81.65	13.35	81.63	13.37 (0.2%)
CS režim ($SoC_i = 30\%$)	DP		RB+ECMS	
	SoC_f [%]	m_f [g]	SoC_f [%]	m_f [g]
NEDC	30.39	307.5	30.39	314.7 (2.3%)
UDDS	32.10	535.1	32.10	559.4 (4.5%)
HWFET	29.11	285.4	29.11	288.6 (1.1%)
US06	31.58	579.3	31.58	580.1 (0.1%)

Na slici 14 su prikazani rezultati iz Tablice 3. Za različite konačne postotke SoC -a provedene su DP optimizacije kako bi se mogli usporediti rezultati RB+ECMS koji ne rezultiraju konačnim iznosom SoC -a od 30%. Rezultati DP optimiranja interpolirani su ravnom linijom koje imaju različite nagibe ispod i iznad 30% SoC -a.



Slika 12. Grafički prikaz CS režima rada u slučaju RB+1D-ECMS u usporedbi sa globalno optimalnim DP za različite vozne cikluse.

Iz Tablice 3 može se vidjeti da RB+ECMS odstupa od DP-a u prihvatljivim granicama od nekoliko postotaka no RB+ECMS se može daljnje poboljšati kako bi se dodatno smanjila

odstupanja od globalno optimalnih rezultata dinamičkog programiranju što je analizirano u sljedećim poglavljima.

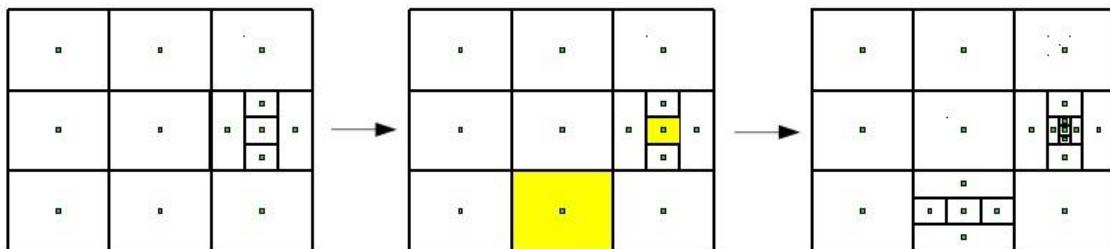
3. Proporcionalni (P) regulatora stanja napunjenoosti baterije

3.1. Optimiranje parametara proporcionalnog regulatora

Kako bi se poboljšali rezultati optimiranja RB+ECMS i smanjila potrošnja goriva može se poboljšati izvedba SoC regulatora. SoC regulator mjeri odstupanje stvarnog SoC -a od referentne vrijednosti SoC_R te na osnovi odstupanja izračunava snagu potrebnu za punjenje ili pražnjenje baterije u danom trenutku ovisno o tome je li SoC iznad ili ispod SoC_R . SoC regulator sadrži i mrtvu zonu odnosno pojas oko SoC_R unutar kojeg se SoC može kretati bez regulacijskog djelovanja. Na taj način se ECMS algoritmu daje sloboda da bira radne točke ICE motora s većom efikasnošću koje ne održavaju SoC nužno na točno 30%, nego negdje oko 30%. Ako je pojas mrtve zone preširok SoC regulator neće djelovati na odstupanje SoC -a od SoC_R -a sve dok SoC ne dođe do granice mrtve zone. Ako je odstupanje dosta veliko, što je slučaj kod širokog pojasa mrtve zone, 1D-ECMS će biti dominantniji u traženju radnih točaka ICE motora od 2D-ECMS-a što će na kraju voznog ciklusa rezultirati većom potrošnjom goriva. 2D-ECMS ima veću slobodu odabira radnih točaka ICE motora kada je SoC blizu SoC_R koje daju veću korisnost, kad je 1D-ECMS dominantniji prednosti 2D-ECMS se manje koriste što rezultira većom potrošnjom goriva. Ako je mrtva zona jednaka nuli SoC regulator će stalno djelovati na odstupanje SoC -a, prisiljavat će ga da strože prati SoC_R , čime će konstantno djelovati na potrebnu snagu ICE motora P_e pri čemu će potrošnja goriva biti veća jer je sloboda odstupanja od SoC -a ograničena.

Potrebno je naći optimalnu širinu mrtve zone i optimalno pojačanje proporcionalnog regulatora kako bi se dodatno smanjila potrošnja goriva i poboljšali rezultati RB+ECMS optimiranja u odnosu na DP. Uz optimiranje parametara SoC regulatora moguće je optimirati i pragove uključivanja/isključivanja ICE motora. Za optimiranje pojačanja proporcionalnog regulatora, mrtve zone te pragova uključivanja/isključivanja ICE motora korišten je DIRECT algoritam. DIRECT algoritam rješava probleme globalnog optimuma s obzirom na zadane granice. DIRECT algoritam [2] će polako konvergirati prema globalnom minimumu funkcije

zadanog problema u svakom koraku uzorkovanja. Ime DIRECT dolazi od eng. 'DIviding RECtangles' što u biti opisuje njegov način rada. DIRECT dijeli skupove rješenja, uspoređuje koja rješenja daju rezultate bliže globalnom minimumu, dijeli dalje taj skup rješenja na sitnije skupove te na kraju postupka odabire rješenje s globalnim minimumom.



Slika 13. Primjer pretraživanja skupa rješenja DIRECT algoritma.

Za CS režim rada DIRECT traži iznose pojačanja proporcionalnog regulatora, mrtve zone te pragove uključivanja/isključivanja ICE motora koji će minimizirati potrošnju goriva .

Kriterijska funkcija koju DIRECT minimizira za slučaj CS režima rada je :

$$m_f = \int_{t_0}^{t_f} \dot{m}_f(K_p, x_{m_z}, P_{off}, P_{on}) . \quad (14)$$

Ukupna potrošnja goriva na kraju voznog ciklusa uspoređuje se u postotcima sa potrošnjom goriva dobivenom dinamičkim programiranje za isti vozni ciklus i isti iznos konačnog SoC -a. Za složeni hibridni način rada DIRECT također traži pojačanje proporcionalnog regulatora, mrtve zone te pragova uključivanja/isključivanja motore koji će minimizirati potrošnju goriva i istovremeno svesti konačni $SoC(t_f)$ što bliže konačnoj referenci $SoC_R(t_f)$. Za složeni hibridni režim rada koristi se kriterijska funkcija drukčijeg oblika od one za CS :

$$J = K |SoC_R(t_f) - SoC(t_f)| + m_f(t_f) , \quad (15)$$

gdje je faktor težine $K = 100$ sa ciljem da se utjecaj devijacije SoC -a od SoC_R uravnoteži sa potrošnjom goriva. Granice optimiranja za oba načina rada (CS i BLND) su :

$$\begin{aligned} 0 &\leq K_p \leq K_{p_{\max}} \\ 0 &\leq x_{m_z} \leq x_{m_z,\max} \\ 0 &\leq P_{off} \leq P_{off,\max} \\ 0 &\leq P_{on} \leq P_{on,\max} \\ P_{off} + 1000 &\leq P_{on} \end{aligned} \quad (16)$$

K_p mora biti veći od 0 jer u suprotnom proporcionalni regulator daje P_{batt} suprotnog

predznaka što remeti iznos P_e . Parametar x_{m_z} označava širinu mrtve zone (eng. dead zone) i

njegov iznos je ograničen na iznose veće od nule zbog načina na koji je ova veličina definirana u strukturi programa koji se koristi za simulaciju.

3.2. Rezultati optimiranja parametara P regulatora

Optimirani parametri P regulatora s mrtvom zonom te pragovima uključivanja/isključivanja ICE motora za CS i složeni hibridni režim rada, za sve vozne cikluse i složeni vozni ciklus, su prikazani u tablicama 4 i 5. Kombinirani vozni ciklus sastoji se od kombinacije NEDC, HWFET, UDDS te US06 ciklusa.

Tablica 4. Optimirani parametri P regulatora i pragovi motora za CS režim rada.

CS parametri	K _p	Mrtva zona	P _{off} [W]	P _{on} [W]
NEDC	1.6667*10 ⁸	0.0111	3.3333*10 ³	7.7778*10 ³
UDDS	8.3333*10 ⁸	0.0056	5.5556*10 ³	7.7778*10 ³
HWFET	5.5556*10 ⁷	0.0033	6.2963*10 ³	10000
US06	5.5556*10 ⁷	0.0078	5.5556*10 ³	1.4444*10 ⁴
Kombinirani	3.8889*10 ⁸	0.0011	9.2593*10 ³	1.4444*10 ⁴

Tablica 5. Optimirani parametri P regulatora i pragovi motora za složeni hibridni režim rada.

Složeni hibridni parametri	K _p	Mrtva zona	P _{off} [W]	P _{on} [W]
NEDCx17	1.8519*10 ⁸	0.0130	1.2222*10 ⁴	1.4444*10 ⁴
UDDSz15	1.4198*10 ⁹	8.6420*10 ⁻⁴	6.2963*10 ³	7.5309*10 ³
HWFETx11	2.1605*10 ⁹	0.0142	7.7778*10 ³	1.6667*10 ⁴
US06x10	6.1728*10 ⁷	0.0011	1.2469*10 ⁴	1.9630*10 ⁴
Kombiniranix4	8.1550*10 ⁹	0.0041	1.1893*10 ⁴	1.3951*10 ⁴

Uočeno je da optimalni iznos mrtve zone ovisi o proporcionalnom pojačanju, za različite iznose proporcionalnog pojačanja SoC regulatora različiti su optimalni iznosi mrtve zone. Ako je proporcionalno pojačanje optimirano, ono u velikoj mjeri zadovoljava zahtjeve vozognog ciklusa pa se pojas mrtve zone može suziti na uže područje oko SoC_R . Zahtjev snage od strane SoC regulatora P_{batt} vjernije će pratiti zahtjeve vozognog ciklusa, a uži pojas mrtve zone ograničit će odstupanje SoC -a. 2D-ECMS biti će dominantniji pri odabiru radnih točaka motora. Izlazna snaga ICE motora neće odstupati puno od zahtijevane snage motora P_e koja je zbog optimiranja pojačanja P regulatora sada preciznija. Iako optimalne vrijednosti mrtve zone teže prema nuli u samoj nuli one ne daju globalne minimume kriterijskih funkcija

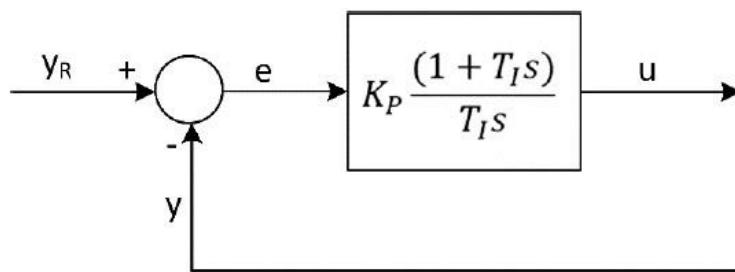
za CS i složeni hibridni režim rada dane funkcijama (14) i (15). Pragovi uključivanja/isključivanja ICE motora se podešavaju tako da je ICE motor aktivan samo kad se njegovim radom postiže maksimalna moguća korisnost u danom trenutku. Optimalni parametri za kombinirane vozne cikluse predstavljaju jedinstvene robusne parametre koji daju najbolje rezultate za sve vozne cikluse.

4. Proporcionalno integralni (PI) regulator stanja napunjenosti baterije

Kako bi se dodatno poboljšalo slijedeće reference *SoC*-a implementiran je regulator stanja napunjenosti proporcionalno integralnog (PI) tipa. P regulator nije u stanju eliminirati regulacijsko odstupanje reguliranje veličine no za razliku od njega PI regulator privodi upravljačku veličinu referentnoj vrijednosti integrirajući regulacijsko odstupanje koje na taj način može svesti na nulu na nulu. Jedino kad je regulacijsko odstupanje jednako nuli PI regulator neće biti aktivan dok u svim ostalim situacijama teži smanjenju pogrešku sustava. Zbog toga je vrlo raširen u industriji. Zbog vremenski diskretnog opisa i implementacije EREV modela te upravljačke strategije potrebno je izvesti i implementirati diskretnu inačicu PI regulatora.

4.1. Diskretni PI regulator

Blok dijagram standardnog PI regulatora je prikazan na slici 13.



Slika 14. Blok dijagram standardnog PI regulatora.

Jednadžba PI regulatora u Laplaceovoj domeni glasi

$$u(s) = K_p \frac{(1+T_i s)}{T_i s} e(s) . \quad (17)$$

$$T_i u(s) s = K_p e(s) + K_p T_i e(s) s$$

U vremenskoj domeni ta jednadžba je :

$$T_i u'(t) = K_p e(t) + K_p T_i e'(t) . \quad (18)$$

Ako se ta formula prebaci u diskretnu vremenski domenu onda će biti :

$$T_i \frac{u(k) - u(k-1)}{T} = K_p e(k) + K_p T_i \frac{e(k) - e(k-1)}{T} , \quad (19)$$

što se može raspisati kao :

$$\begin{aligned} u(k) - u(k-1) &= K_p \frac{T}{T_i} e(k) + K_p e(k) - K_p e(k-1) \\ u(k) &= u(k-1) + K_p \left(1 + \frac{T}{T_i} \right) e(k) - K_p e(k-1) \end{aligned} \quad (20)$$

Za SoC regulator unutar RB+ECMS regulatora, jednadžba za diskretni PI regulator stanja napunjenoosti baterije glasi :

$$\begin{aligned} P_{batt}(k) &= P_{batt}(k-1) + K_p \left(1 + \frac{T}{T_i} \right) e(k) - K_p e(k-1) \\ e(k) &= SoC(k) - SoC_R(k) \\ e(k-1) &= SoC(k-1) - SoC_R(k-1) \end{aligned} \quad (21)$$

4.2. Optimiranje parametara PI regulatora

Kako bi se iskoristio maksimalni potencijal SoC regulatora PI tipa, a time i smanjila ukupna potrošnja goriva potrebno je optimirati njegove parametre. Kao i kod optimiranja SoC regulatora P tipa i ovdje se uz optimiranje parametara regulatora, optimiraju pragovi uključivanja/isključivanja ICE motora. Parametri su računati numerički, odnosno analitički za složeni hibridni i CS režime rada.

4.2.1. Numeričko optimiranje parametara PI regulatora

Za optimiranje parametara PI regulatora i pragova uključivanja/isključivanja ICE motora korišten je DIRECT optimizacijski algoritam. Parametri PI regulatora koji se optimiraju su pojačanje regulatora K_p , vremenska konstanta regulatora T_i i širina mrtve zone x_{m_z} . Uz parametre SoC regulatora optimiraju se i pragovi uključivanja/isključivanja ICE motora. Kriterijske funkcije DIRECT algoritma za evaluaciju CS i složeni hibridnog režima rada ostaju iste. Za CS režim rada u obzir se uzima samo ukupna potrošnja goriva što predstavlja kriterijsku funkciju za DIRECT algoritam :

$$m_f = \int_{t_0}^{t_f} \dot{m}_f(K_p, T_i, x_{m_z}, P_{off}, P_{on}) \quad . \quad (22)$$

Za složeni hibridni tržim rada kriterijska funkcija je :

$$J = K \left| SoC_R(t_f) - SoC(t_f) \right| + m_f(t_f) , \quad (23)$$

u kojoj se uz potrošnju goriva minimizira i odstupanje SoC od reference SoC_R na kraju voznog ciklusa definiranog vremenskim trenutkom t_f . Granice optimiranja ovih parametara u oba režima rada za DIRECT algoritam su :

$$\begin{aligned} 0 &\leq K_P \leq K_{P_{\max}} \\ 0 &\leq x_{m_z} \leq x_{m_z,\max} \\ 0 &\leq T_i \leq T_{\max} \\ 0 &\leq P_{off} \leq P_{off,\max} \\ 0 &\leq P_{on} \leq P_{on,\max} \\ P_{off} &+ 1000 \leq P_{on} \end{aligned} \quad (24)$$

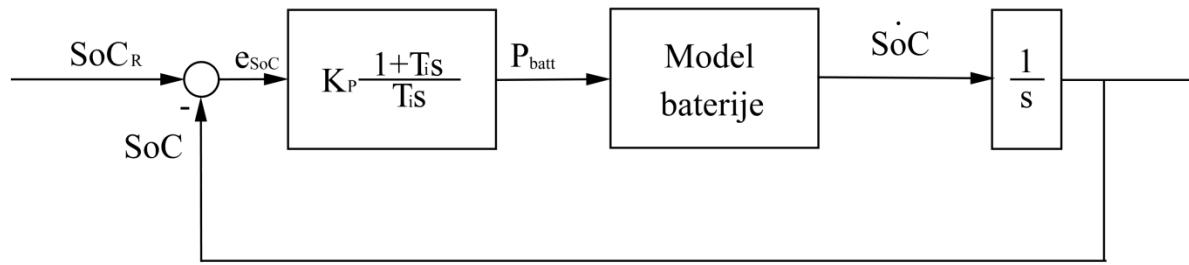
K_P mora biti veći od nule kako P komponenta regulatora ne bi imala suprotan učinak, mrtva zona mora biti veća od nule jer je u simulacijskom programu definirana kao absolutna veličina, a vremenska konstanta regulatora T_i fizikalno ne može biti manja od nule. SoC regulator će sada na osnovi odstupanja e_{SoC} izračunavati snagu P_{batt} koja će se zahtijevati od ICE motora, no ta će se vrijednost zbog integracijskog djelovanja polako mijenjati dok regulacijsko odstupanje ne padne na nulu.

4.2.2. Analitičko računanje parametara PI regulatora

Analitički se parametri mogu naći pomoću modela baterije prema slici 4 . Model baterije je opisan pomoću izraza (3) u kontinuiranoj vremenskoj domeni pa ga nije potrebno prebacivati u diskretnu domenu :

$$\frac{dSoC}{dt} = \frac{\sqrt{U_{oc}^2(SoC) - 4R(SoC,i)P_{batt}} - U_{oc}}{2Q_{\max}R(SoC,i)} . \quad (25)$$

Regulacijska petlja s obzirom na ovaj model baterije je prikazana na slici 15.



Slika 15. Regulacijska petlja s modelom baterije.

Kako bi se dinamika baterije pojednostavnila potrebno ju je linearizirati oko neke radne točke. Linearizirani oblik funkcije $f(x)$ oko radne točke x_R glasi :

$$f_{lin}(x) = f'(x_R)(x - x_R) + f(x_R). \quad (26)$$

Linearizirani oblik modela baterije oko radne točke $P_{batt,R}$ imati će oblik :

$$\frac{dsoc}{dP_{batt}} = \frac{-1}{Q_{\max} \sqrt{U_{oc}^2 - 4RP_{batt,R}}} (P_{batt} - P_{batt,R}) + \frac{\sqrt{U_{oc}^2 - 4RP_{batt,R}} - U_{oc}}{2Q_{\max} R}, \quad (27)$$

gdje se mogu uvesti supstitucije :

$$A = \frac{-2R}{Q_{\max} \sqrt{U_{oc}^2 - 4RP_{batt,R}}}$$

$$B = \frac{\sqrt{U_{oc}^2 - 4RP_{batt,R}} - U_{oc}}{Q_{\max}} \quad (28)$$

$$\frac{dsoc}{dt} = \frac{A}{2R} (P_{batt} - P_{batt,R}) + \frac{B}{2R}$$

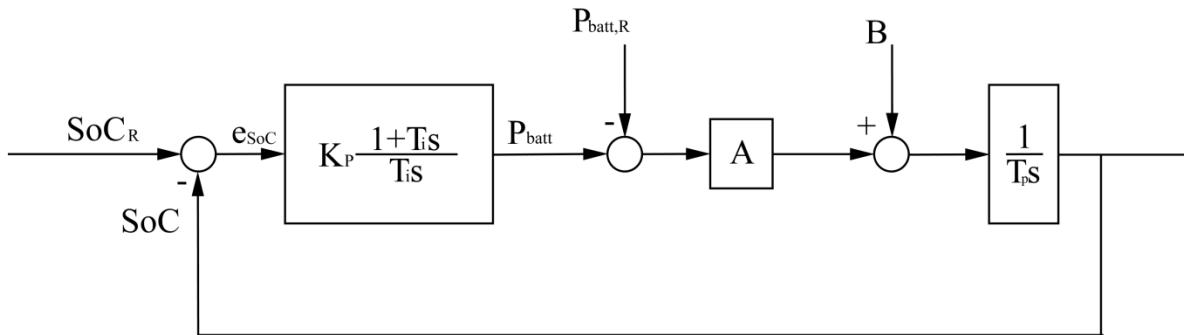
Daljnjim sređivanjem funkcija glasi :

$$\frac{dSoC_{lin}}{dt} = \left(-\frac{AP_{batt,R}}{2R} + \frac{B}{2R} \right) + \frac{AP_{batt}}{2R} . \quad (29)$$

gdje su $P_{batt,R}$, A i B konstantne veličine, a P_{batt} je varijabla funkcije. $P_{batt,R}$ je aproksimacija zahtijevane snage od strane SoC regulatora P_{batt} pri nekom iznosu SoC-a. Radi jednostavnosti može se uzeti srednja vrijednost \bar{P}_{batt} tokom cijelog voznog ciklusa koja će za svaki vozni ciklus biti različita. Ova se pretpostavka može uvesti jer u slučaju korištenja PI regulator SoC neće značajno odstupati od zadane reference. Nadalje, radi pojednostavljenja modela može se uzeti da je vrijednost napona otvorenog kruga U_{oc} konstantna, a za otpor umjesto posebne vrijednosti prilikom punjenja R_{ch} i pražnjenja R_{dch} može se uzeti njihova

srednja vrijednost.

Blok dijagram regulacijske petlje za lineariziranu dinamiku baterije prikazan je na slici 16.



Slika 16. Blok dijagram regulacijskog kruga lineariziranog modela baterije.

Prijenosna funkcija regulacijskog kruga SoC -a je :

$$G_c(s) = \frac{SoC(s)}{SoC_R(s)} = \frac{\frac{T_i s + 1}{T_i T_p}}{\frac{T_i T_p}{K_p A} s^2 + T_i s + 1}, \quad (30)$$

gdje je $T_p = 2R$ vremenska konstanta integratora, K_p proporcionalno pojačanje regulatora i T_i vremenska konstanta PI regulatora. Parametri PI regulatora, K_p i T_i , računaju se korištenjem optimuma dvostrukog odnosa (ODO). ODO postupak se zasniva na izjednačavanju karakterističnog polinoma prijenosne funkcije kaskadnog regulacijskog kruga kod kojeg su omjeri D_i susjednih vremenskih konstanti postavljeni kao slobodne varijable.

$$A(s) = D_n D_{n-1}^2 \dots D_2^{n-1} T_e^n s^n + D_{n-1} D_{n-2}^2 \dots D_2^{n-2} T_e^{n-1} s^{n-1} + \dots + D_2 T_e^2 s^2 + T_e s + 1 \quad (31)$$

Postavljanjem svih karakterističnih odnosa na iznos 0.5 ($D_2 = D_3 = \dots = D_n = 0.5$) postiže se kvaziperiodski odziv. Karakteristični polinom iz (33) se uzima za slučaj sustava drugog reda te se izjednačava s karakterističnim polinomom prijenosne funkcije (32).

$$\frac{T_i T_p}{K_p A} s^2 + T_i s + 1 = D_2 T_e^2 s^2 + T_e s + 1 \quad (32)$$

Za ekvivalentnu vremensku konstantu zatvorenog regulacijskog kruga T_e , uzima se $T_I = 10T_p$.

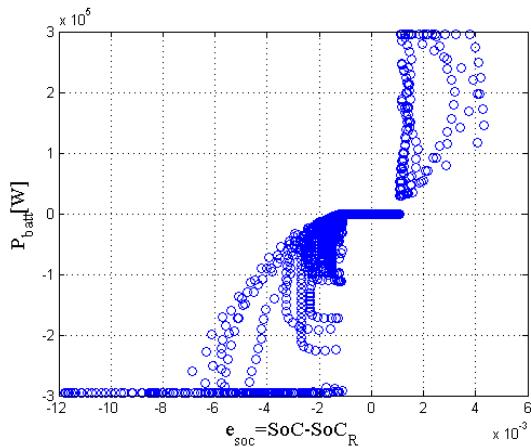
Izrazi za izračunavanje parametara PI regulatora su :

$$T_I = T_e = 10T_p \quad . \quad (33)$$

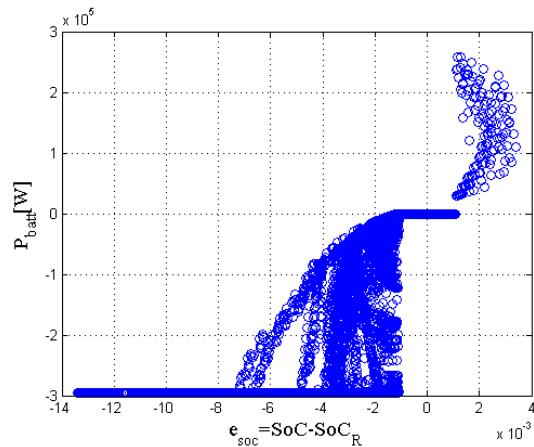
$$K_p = \frac{T_p}{AT_I D_2}$$

Otpor R poprima vrijednost $R_{ch} = 0.05\Omega$ kad se baterija puni odnosno $R_{dch} = 0.11\Omega$ kad se baterija prazni. Za ovaj proračun uzeta je prosječna vrijednost otpora $\bar{R} = 0.08\Omega$. Maksimalni kapacitet baterije je $Q_{max} = 162000 J$, a aproksimirana snaga koju SoC regulator zahtjeva $P_{batt,R}$ uzima se iz dijagrama ovisnosti P_{batt} o e_{SoC} koji je prikazan na slici 18. Za $P_{batt,R}$ mogu se uzeti neke karakteristične točke za sve vozne cikluse. Slika 18 prikazuje iznose P_{batt} u ovisnosti o regulacijskom odstupanju e_{SoC} za CS i složeni hibridni režim rada za složene vozne cikluse. Iz slike 19 vidljivo je da je P_{batt} jednak nuli kad je e_{SoC} unutar mrtve zone, a kad se regulacijsko odstupanje poveća do granice mrtve zone P_{batt} se naglo poveća do graničnog iznosa $P_{batt,max}$. Za različite vozne cikluse P_{batt} će poprimiti različite iznose i različite srednje vrijednosti. Tokom jednog voznog ciklusa SoC regulator će zahtijevati različite iznose P_{batt} -a u rasponu od 0 do $\pm P_{batt,max}$ tako da je za linearizirani model baterije nemoguće odabrati jednu radnu točku snage $P_{batt,R}$ koja će biti približno jednaka za sve iznose koje će P_{batt} poprimiti tokom voznog ciklusa. Regulaciju ovakvog lineariziranog modela bilo bi moguće ostvariti adaptivnim regulatorom koji će mijenjati iznos $P_{batt,R}$ ovisno o regulacijskom odstupanju tokom voznog ciklusa kako bi $P_{batt,R}$ bio približno jednak stvarnom P_{batt} u svakom trenutku.

Primjera radi u ovom se radu koristi $P_{batt,R} = -2.95 \cdot 10^5 W$ što je jednako iznosu donje granice koju P_{batt} može poprimiti.



(a)



(b)

Slika 17. Iznosi snage P_{batt} u ovisnosti o regulacijskom odstupanju za CS režim rada (a) i složeni hibridni režim rada (b).

Važno je napomenuti da će regulator s ovako izračunatim parametrima uspijevati smanjiti regulacijsko odstupanje tokom voznog ciklusa no neće značajnije pridonositi smanjenju potrošnje goriva. U pojednostavljenom modelu baterije koji se koristio nigdje nije zastupljena potrošnja goriva i glavni je naglasak na održavanju SoC -a oko SoC_R . Zato numeričkim postupkom optimiranja parametara, koji se zasniva na metodi pokušaja i promašaja, možemo dobiti povoljnije parametre. Upravljački sustav EREV-a je veoma kompleksan upravljački sustav koji se analitički teško može optimirati bez uvođenja puno pojednostavljenja. Uvođenjem tih pojednostavljenja zanemaruju se utjecaj brojnih čimbenika u regulaciji EREV-a što ne daje optimalne rezultate.

4.3. Rezultati optimiranja parametara PI regulatora

Numerički optimirani parametri PI regulatora za sve vozne cikluse i složeni vozni ciklus u složeni hibridnom i CS režimu rada su prikazani u tablicama 6 i 7.

Tablica 6. Optimalni parametri PI regulatora i pragovi uključivanja/isključivanja motora za CS režim rada.

CS parametri	K _p [W]	T _i [s]	x _{m_z}	P _{off} [W]	P _{on} [W]
NEDC	1.6667*10 ⁶	1.6667	0.0100	3.3333*10 ³	7.7778*10 ³
UDDS	3.8889*10 ⁶	1.6667	0.0056	5.5556*10 ³	7.7778*10 ³
HWFET	3.8889*10 ⁶	7.2222	0.0033	5.5556*10 ³	10000
US06	5000000	1.6667	0.0078	5.5556*10 ³	1.4444*10 ⁴
Kombinirani	8.3333*10 ⁶	1.6667	0.0011	3.3333*10 ³	7.7778*10 ³

Tablica 7. Optimalni parametri PI regulatora i pragovi uključivanja/isključivanja motora za složeni hibridni režim rada.

BLND parametri	K _p [W]	T _i [s]	x _{m_z}	P _{off} [W]	P _{on} [W]
NEDCx17	3.8889*10 ⁹	6.1111	0.0033	3.3333*10 ³	1.2222*10 ⁴
UDDSz15	2.0370*10 ⁹	3.8889	0.0011	4.0741*10 ³	10000
HWFETx11	5.0000*10 ⁹	5	0.0100	1.2222*10 ⁴	1.4444*10 ⁴
US06x10	6.5638*10 ⁹	3.1481	0.0012	1.2222*10 ⁴	1.8889*10 ⁴
Kombiniranix4	4.7531*10 ⁹	8.3196	0.0023	1.2222*10 ⁴	1.4444*10 ⁴

Analitičkim postupkom dobiveni parametri PI regulatora su :

$$K_p = 4.156 \cdot 10^7 W \quad (34)$$

$$T_i = 1.6$$

a širina mrtve zone te pragovi uključivanja/isključivanja motora su preuzeti iz tablice 7 za složeni vozni ciklus :

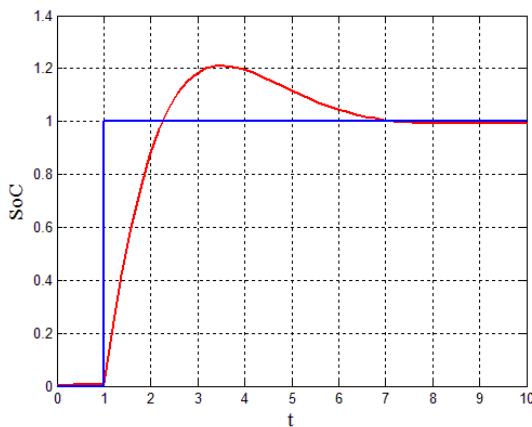
$$x_{m_z} = 0.0023 \quad (35)$$

$$P_{off} = 1.2222 \cdot 10^4 W$$

$$P_{on} = 1.4444 \cdot 10^4 W$$

Radi provjere ispravnosti analitički dobivenih parametara pomoću Matlabovog Simulinka provedena je simulacija samog modela baterije izdvojenog iz upravljačkog sustava EREV-a oko radne točke $P_{batt,R} = -295000$. U ovom modelu referenca SoC_R je step funkcija, a cilj stvarnog SoC -a je postići kvaziperiodski odziv. Uspješnost ostvarivanja ovakvog

odziva ovisit će o odabiru slobodne varijable T_e . Za $T_e = 10T_p$ ne dobiva se točni kvaziperiodski odziv, da bi se to ispravilo potrebno je naći točan iznos T_e za koji će nadvišenje SoC -a biti jednako 4.6 %. No iz ovoga se vidi da je linearizirani model baterije dobro postavljen.



Slika 18. Odziv lineariziranog simulacijskog modela baterije.

5. Simulacijski rezultati

U ovom poglavlju prikazani su svi rezultati simulacija sa optimiranim parametrima za sve vozne cikluse i režime rada. Također u zadnjem potpoglavlju dani su usporedni rezultati svih simulacija te pripadni zaključci.

5.1. Rezultati simulacija EREV vozila sa optimalnim parametrima P regulatora i pravovima uključivanja/isključivanja benzinskog motora

Optimalni parametri za P regulator stanja napunjenosti baterije navedeni su u 3. poglavlju zajedno sa pravovima uključivanja/isključivanja motora. U ovom potpoglavlju nalaze se simulacijski rezultati za složeni hibridni i CS režime rada. Kako bi se procijenio doprinos optimiranja parametara P regulatora, provedene su također simulacije za slučaj korištenja P regulatora stanja napunjenosti baterije sa ne optimiranim parametrima.

5.1.1. CS režim rada

U prvom stupcu tablice 8 za CS režim rada navedeni su svi vozni ciklusi. U drugom stupcu navedeni su razlike potrošnje goriva simulacije sa ne optimiranim parametrima P regulatora i optimalne potrošnje goriva dobivene DP optimiranjem. U četvrtom stupcu navedene su razlike potrošnje goriva simulacije sa optimiranim parametrima P regulatora i potrošnje goriva dobivene dinamičkim programiranjem. U petom i šestom stupcu pokazani su postotci rada 1D-ECMS-a i 2D-ECMS-a. Ovi postotci pokazuju koliko je koji algoritam bio aktivran u odnosu na cijeloukupno trajanje voznog ciklusa. U sedmom stupcu pokazane su vrijednosti srednje specifične potrošnje goriva, a u osmom stupcu prikazane su srednja odstupanja SoC -a od SoC_R -a (RMS, eng. Root Mean Square). Usporedba potrošnje goriva simulacije sa ne optimiranim parametrima P regulatora i optimalne potrošnje goriva dobivene DP optimiranjem računa se kao :

$$p_1 = \frac{m_{f,RB+ECMS0} - m_{f,DP}}{m_{f,DP}} \cdot 100 . \quad (36)$$

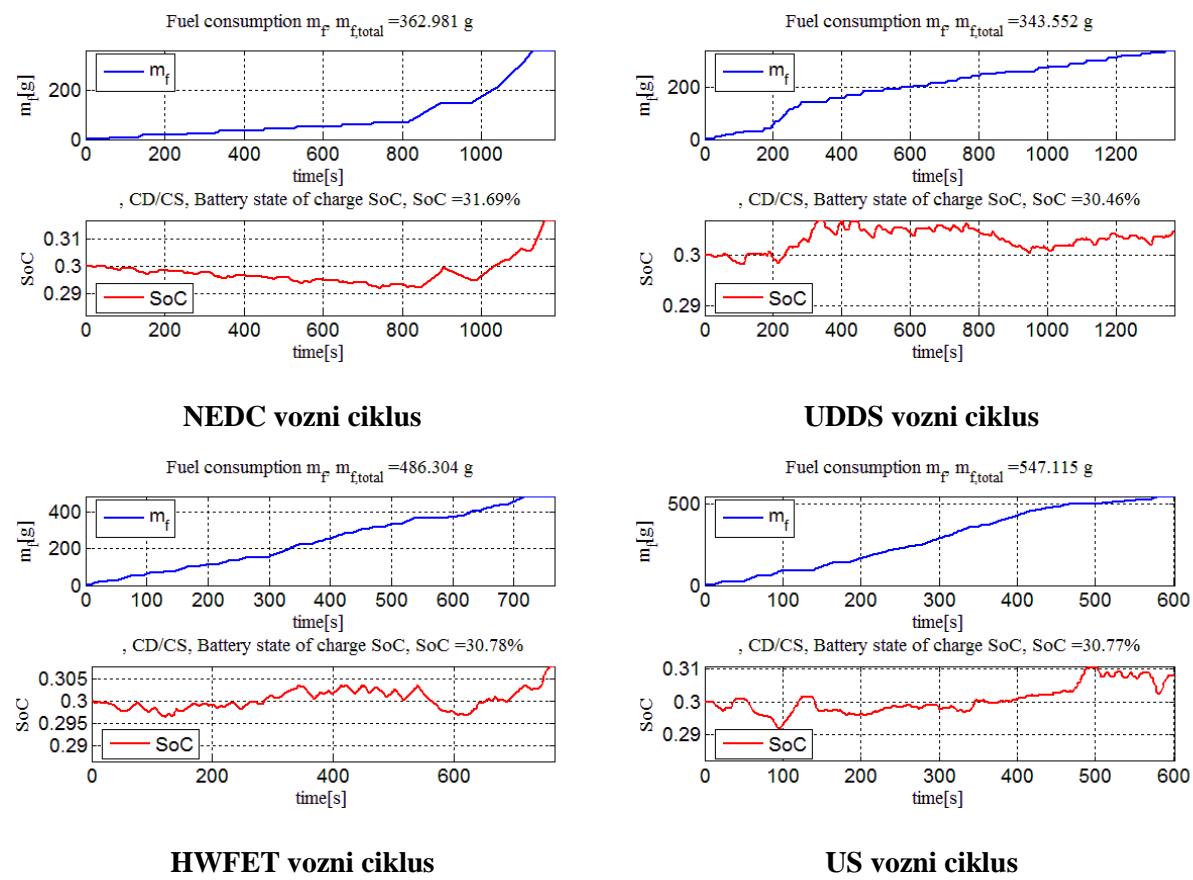
Usporedba potrošnje goriva simulacije sa optimiranim parametrima P regulatora i potrošnje goriva dobivene dinamičkim programiranjem računa se kao :

$$p_2 = \frac{m_{f,RB+ECMS} - m_{f,DP}}{m_{f,DP}} \cdot 100. \quad (37)$$

Tablica 8. Rezultati simulacije za CS režim rada sa optimiranim parametrima P regulatora za pojedine vozne cikluse.

CS statistika	p ₁ [%]	p ₂ [%]	1D-ECMS [%]	2D-ECMS [%]	A _{ek_mean} [g/kWh]	e _{RMS}
NEDC	3.28	0.53	3.96	96.04	247.24	0.0054
UDDS	4.41	1.53	1.19	98.81	246.20	0.0038
HWFET	6.47	0.47	0.32	99.68	241.50	0.0022
US06	1.69	-0.04	2.26	97.74	239.95	0.0043
Komb.	N/A	N/A	0.38	99.62	249.98	0.0019

Na slici 19 prikazani su dijagrami SoC-a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s optimiranim parametrima za pojedine vozne cikluse.

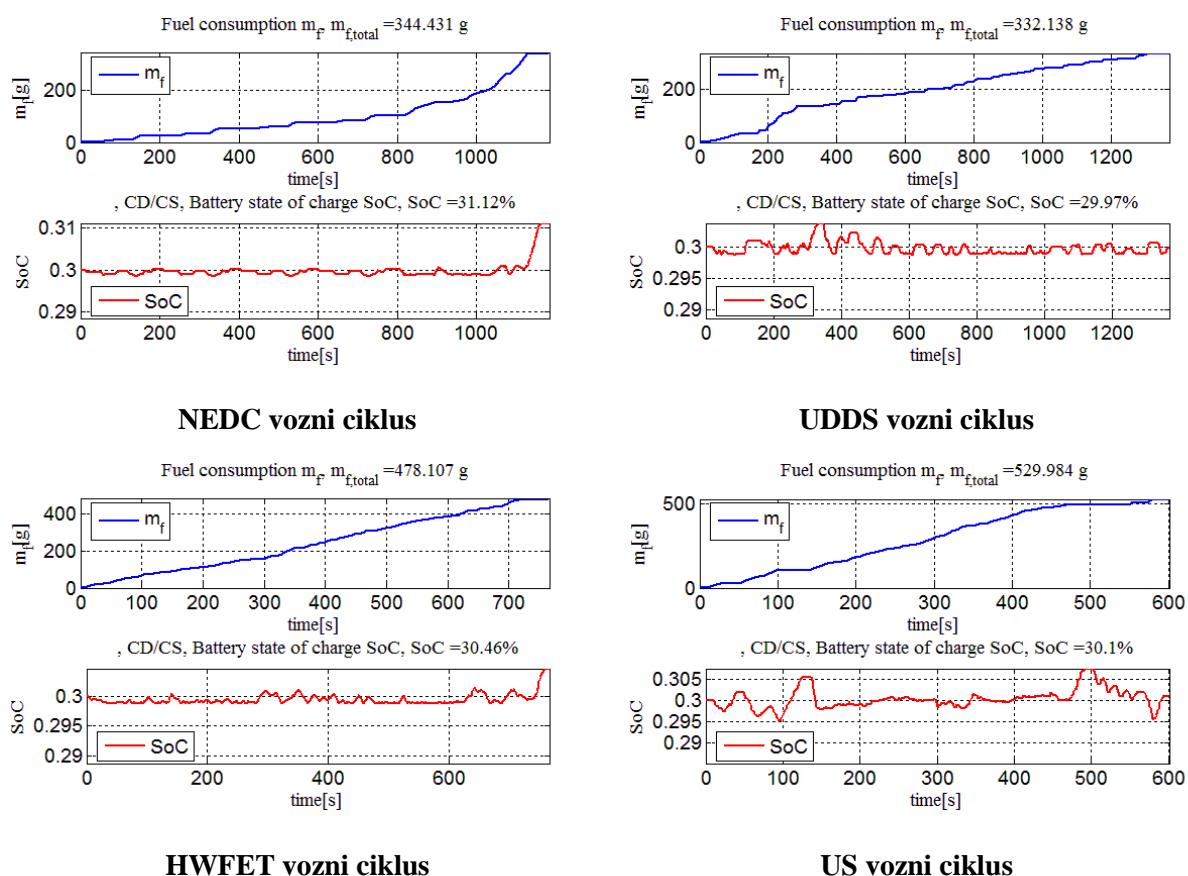


Slika 19. Dijagrami SoC-a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s optimiranim parametrima P regulatora za pojedine vozne cikluse.

Tablica 9. Rezultati simulacije za CS režim rada sa robusno optimiranim parametrima P regulatora za pojedine vozne cikluse.

CS rezultati	p ₁ [%]	p ₂ [%]	1D-ECMS [%]	2D-ECMS [%]	A _{ek_mean} [g/kWh]	e _{RMS}
NEDC	3.28	2.01	0.65	99.35	253.62	0.0021
UDDS	4.41	4.12	0.03	99.97	257.89	0.0010
HWFET	6.47	1.41	0.04	99.96	243.64	0.0011
US06	1.69	1.84	0.04	99.60	245.41	0.0023

Na slici 20 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima za pojedine vozne cikluse.



Slika 20. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima P regulatora za pojedine vozne cikluse.

5.1.2. Složeni hibridni režim rada

Za uspoređivanje upravljačke strukture u složeno hibridnom režimu rada koriste se dvije tablice. U prvoj tablici (tablica 10) pokazuju se konačni iznos *SoC*-a i potrošnje goriva m_f za vozne cikluse za simulacije sa ne optimiranim parametrima i simulacija s optimiranim. U zadnjem stupcu prikazano je za koliko se rezultati simulacije s optimiranim parametrima razlikuju od rezultata simulacije s ne optimiranim parametrima. Negativan predznak označuje da će se u slučaju simulacije s optimiranim parametrima potrošiti manje goriva. Taj pototak se računa prema jednadžbi :

$$p_3 = \frac{m_{f,RB+ECMS} - m_{f,ECMS0}}{m_{f,ECMS0}} \cdot 100$$

U drugoj tablici (tablica 11) navedeni su statistički parametri, postotci rada 1D-ECMS-a i 2D-ECMS-a, srednja specifična potrošnja goriva te srednje odstupanje *SoC*-a.

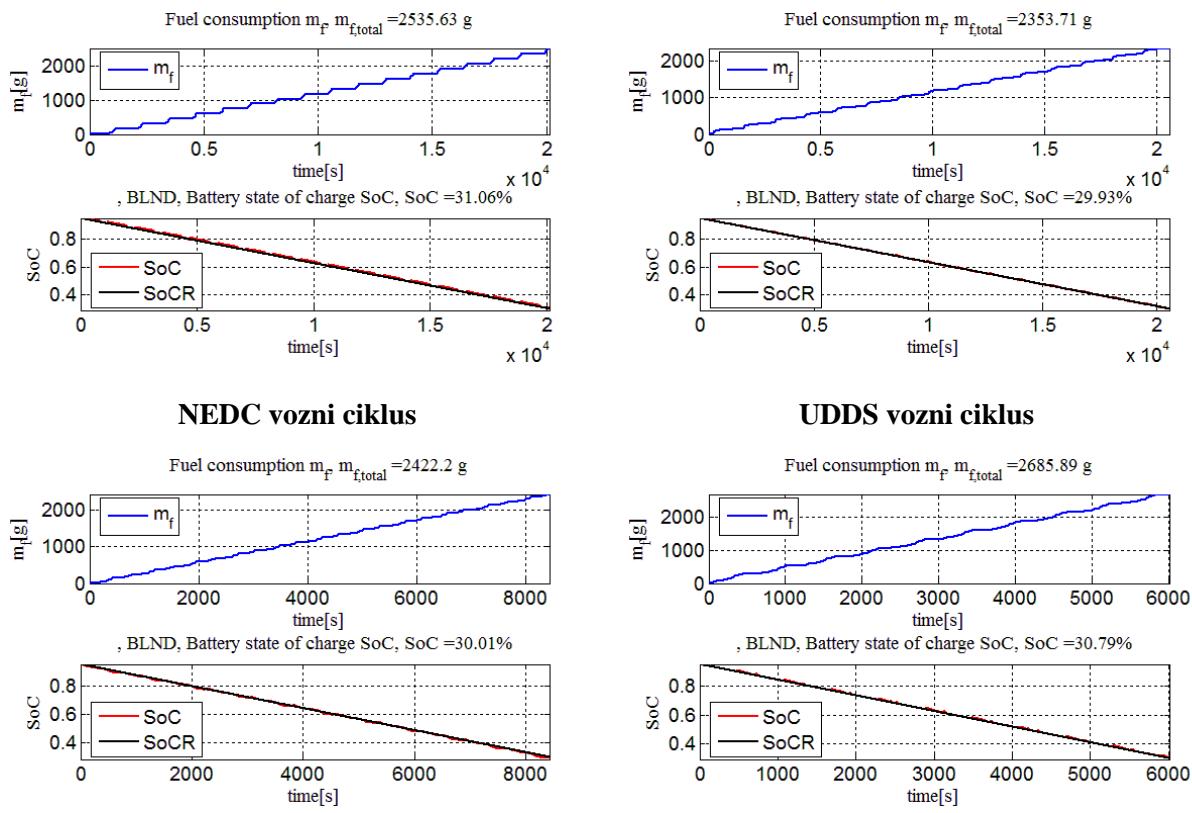
Tablica 10. Usporedbe rezultata simulacija s optimiranim parametrima P regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora za pojedine vozne cikluse.

	Optimirani parametri		Neoptimirani parametri		p ₃ [%]
	SoC _f [%]	m _f [g]	SoC _f [%]	m _f [g]	
NEDCx17	30.01	2442.54	30.01	2754.69	-11.33
UDDRx15	30.22	2296.22	30.22	2455.3	-6.48
HWFETx11	29.99	2422.72	29.99	2801.94	-13.92
US06x10	30.78	2671.65	30.78	2897.4	-7.8
Kombiniranix4	30.52	3876.45	30.52	4254.59	-8.89

Tablica 11. Statistički rezultati simulacije s optimiranim parametrima P regulatora za pojedine vozne cikluse.

BLND statistika	1D-ECMS [%]	2D-ECMS [%]	A _{ek_mean} [g/kWh]	e _{RMS}
NEDCx17	3.9	96.1	240.34	0.0057
UDDRx15	0.18	99.82	247.45	0.0018
HWFETx11	3.28	96.72	239.69	0.0050
US06x10	3.86	96.14	240.05	0.0051
Kombiniranix4	3.2	96.8	239.99	0.0052

Na slici 21 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s parametrima optimiranim za pojedine vozne cikluse.



Slika 21. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s parametrima P regulatora optimiranim za pojedine vozne cikluse.

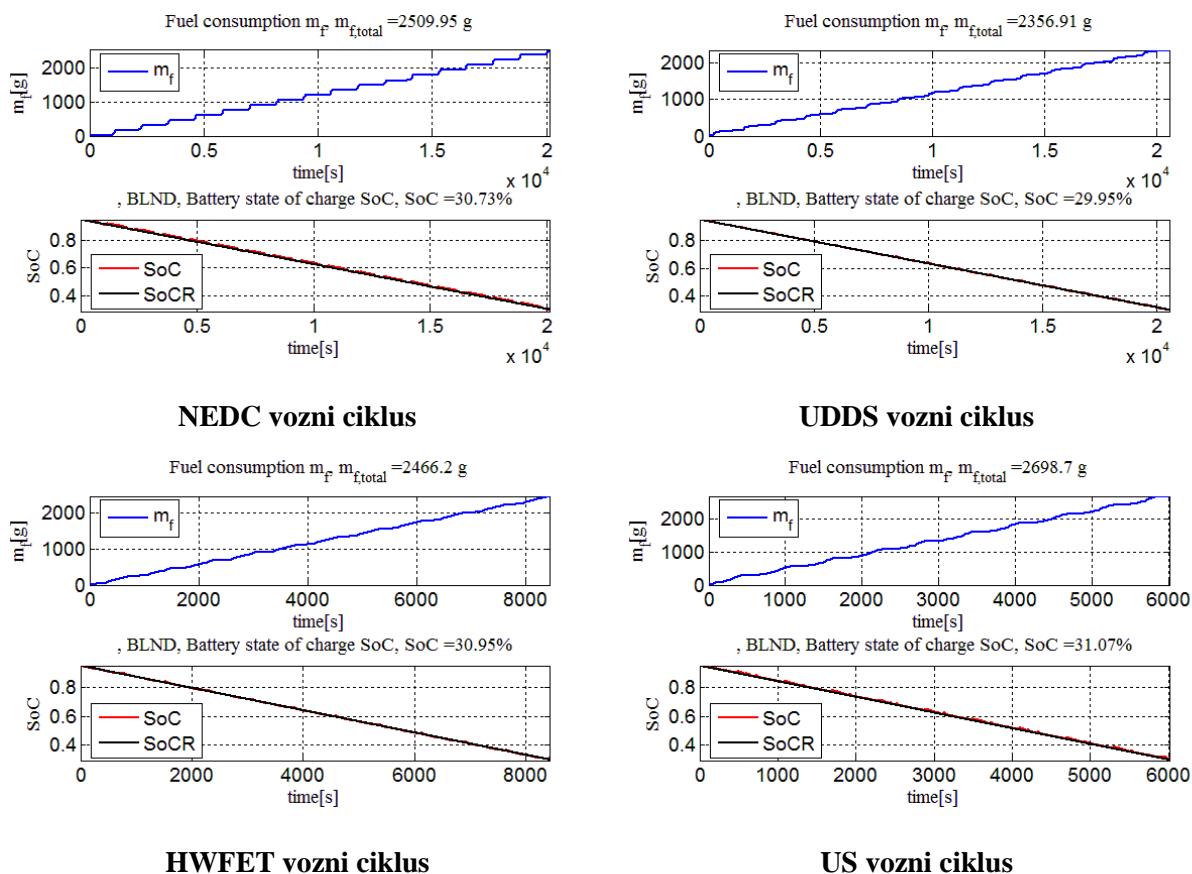
Tablica 12. Usporedbe rezultata simulacija s robusno optimiranim parametrima P regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora.

	Optimirani parametri		Neoptimirani parametri		p_3 [%]
	SoC_f [%]	m_f [g]	SoC_f [%]	m_f [g]	
NEDCx17	30.68	2490.1	30.68	2784.51	-10.57
UDDRx15	30.28	2367.08	30.28	2457.63	-3.68
HWFETx11	31.03	2464.46	31.03	2862.57	-13.90
US06x10	31.11	2712.48	31.11	2909.99	-6.78

Tablica 13. Statistički rezultati simulacije s robusno optimiranim parametrima P regulatora.

BLND rezultati	1D-ECMS [%]	2D-ECMS7 [%]	Aek_mean [g/kWh]	e_{RMS}
NEDCx17	8.1	91.9	239.60	0.0075
UDDSx15	0.58	99.42	235.24	0.0030
HWFETx11	1.17	98.83	239.14	0.0034
US06x10	9.71	90.29	240.07	0.0075

Na slici 22 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima.

**Slika 22. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima P regulatora.**

5.2. Rezultati simulacija EREV vozila sa optimalnim parametrima PI regulatora i pravovima uključivanja/isključivanja benzinskog motora

Parametri za PI regulator stanja napunjenoosti baterije dobiveni numeričkim i analitičkim načinom navedeni se u 4. poglavlju zajedno sa pravovima uključivanja/isključivanja motora. U ovom potpoglavlju nalaze se simulacijski rezultati za složeni hibridni i CS režime rada. Za usporedbu izvedbe regulatora s optimiranim parametrima koriste se rezultati simulacija dobiveni primjenom P regulatora stanja napunjenoosti sa ne optimiranim parametrima.

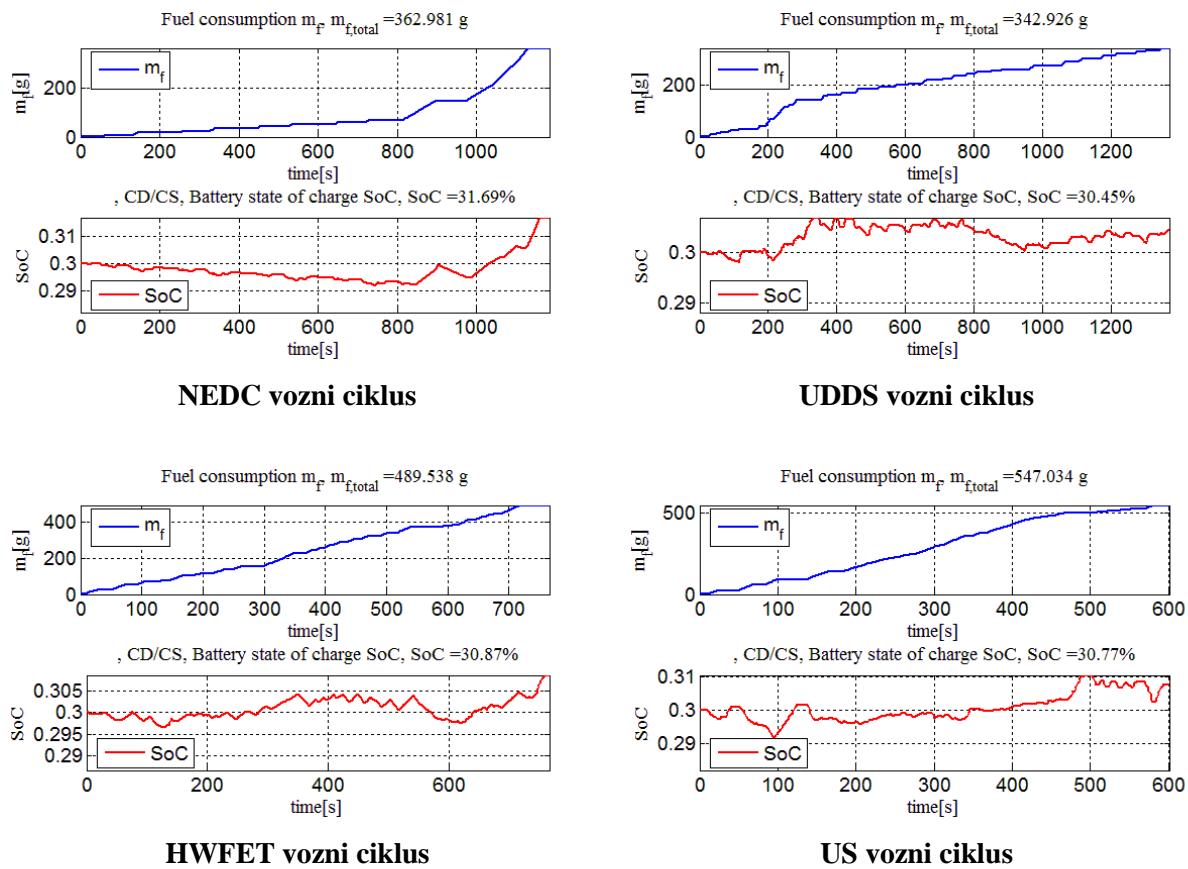
5.2.1. CS režim rada

U prvom stupcu tablice za CS režim rada navedeni su svi vozni ciklusi. U drugom stupcu navedeni su razlike potrošnje goriva simulacije sa ne optimiranim parametrima P regulatora i potrošnje goriva dobivene dinamičkim programiranjem. U četvrtom stupcu navedene su razlike potrošnje goriva simulacije sa optimiranim parametrima PI regulatora i potrošnje goriva dobivene dinamičkim programiranjem. U petom i šestom stupcu pokazani su postotci rada 1D-ECMS-a i 2D-ECMS-a. U sedmom stupcu pokazane su vrijednosti srednje specifične potrošnje goriva, a u osmom stupcu prikazane su srednja odstupanja SoC -a od SoC_R -a (RMS, eng. Root Mean Square). Parametri p_1 i p_2 definirani su prema jednadžbama (38) i (39).

Tablica 14. Rezultati simulacije za CS režim rada sa optimiranim parametrima PI regulatora za pojedine vozne cikluse

CS statistika	p_1 [%]	p_2 [%]	1D- ECMS [%]	2D- ECMS [%]	A_{ek_mean} [g/kWh]	e_{RMS}
NEDC	3.28	0.53	3.96	96.04	247.23	0.0054
UDDS	4.41	1.40	1.26	98.74	246.30	0.0038
HWFET	6.47	0.45	0.47	99.53	241.50	0.0022
US	1.69	-0.03	2.20	97.80	239.90	0.0043
Kombinirani	N/A	N/A	0.50	99.50	246.77	0.0020

Na slici 23 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s optimiranim parametrima za pojedine vozne cikluse.

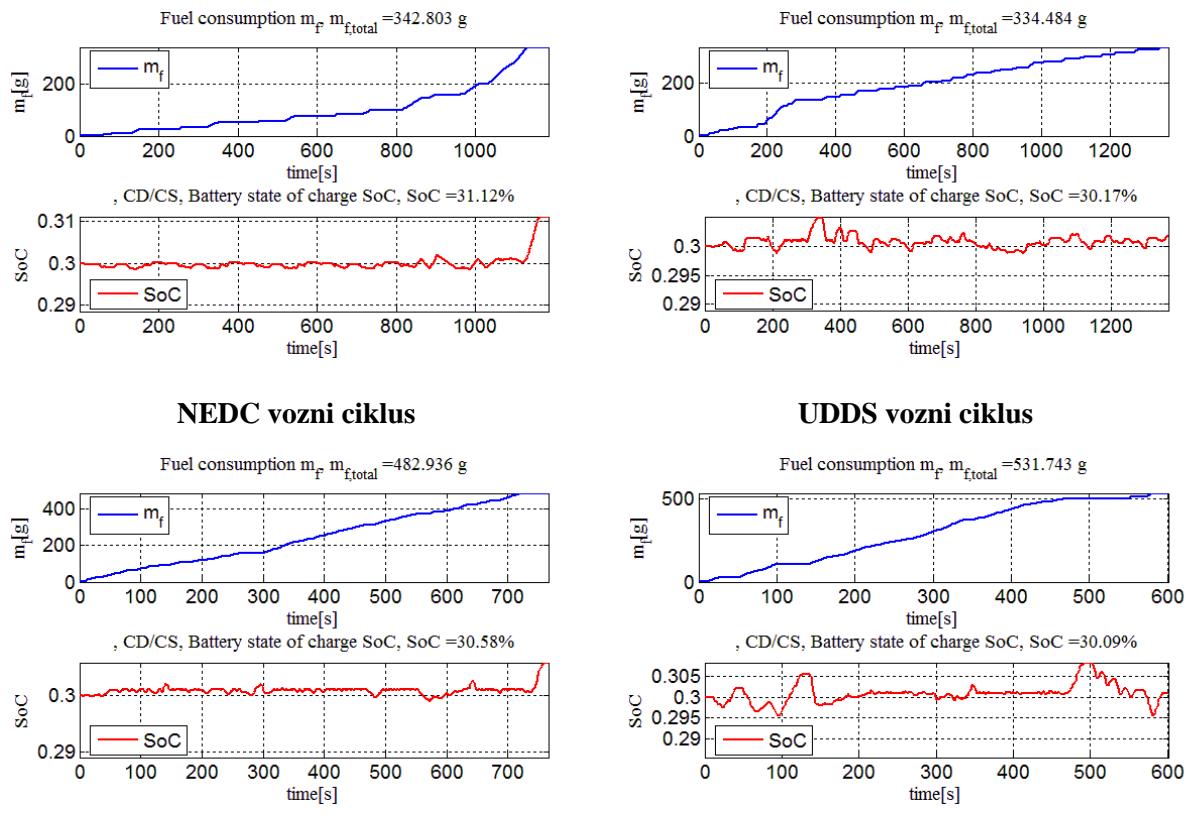


Slika 23. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s optimiranim parametrima PI regulatora za pojedine vozne cikluse.

Tablica 15. Rezultati simulacije za CS režim rada sa robusno optimiranim parametrima PI regulatora za pojedine vozne cikluse.

CS rezultati	p ₁ [%]	p ₂ [%]	1D-ECMS [%]	2D-ECMS [%]	A _{ek_mean} [g/kWh]	e _{RMS}
NEDC	3.28	1.54	0.64	99.36	250.12	0.0021
UDDS	4.41	2.28	0.07	99.93	250.34	0.0013
HWFET	6.47	1.45	0.08	99.92	242.89	0.0012
US06	1.69	2.23	0.55	99.45	245.39	0.0025

Na slici 24 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima za pojedine vozne cikluse.

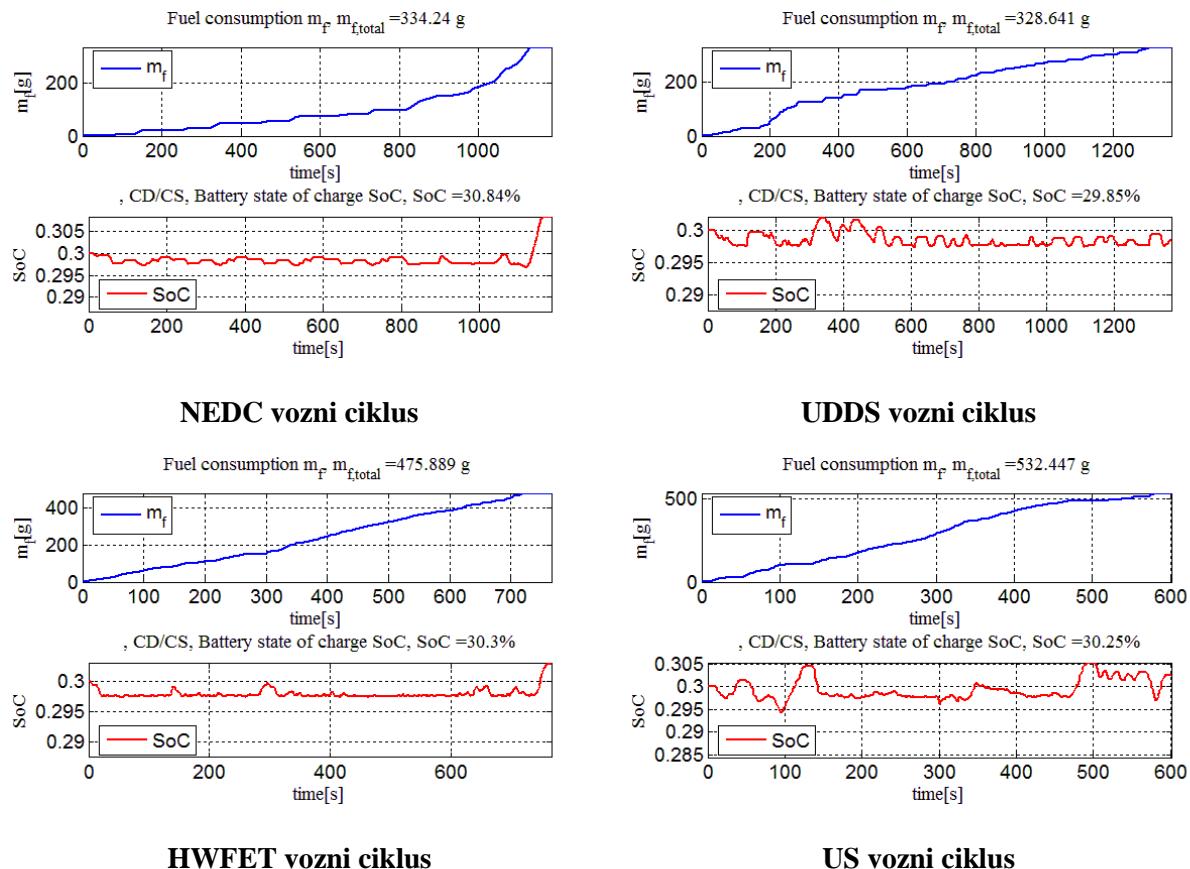


Slika 24. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima PI regulatora za pojedine vozne cikluse.

Tablica 16. Rezultati simulacije za CS režim rada sa analitički optimiranim parametrima PI regulatora.

CS rezultati	p_1 [%]	p_2 [%]	1D-ECMS [%]	2D-ECMS [%]	A_{ek_mean} [g/kWh]	e_{RMS}
NEDC	3.28	1.46	0.86	99.14	248.55	0.0034
UDDS	4.41	2.27	0.21	99.79	247.15	0.0022
HWFET	6.47	0.9	0.22	99.78	241.15	0.0023
US06	1.69	-0.05	0.61	99.39	239.40	0.0029

Na slici 25 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s analitički optimiranim parametrima za pojedine vozne cikluse.



Slika 25. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s analitički optimiranim parametrima za pojedine vozne cikluse.

5.2.2. Složeni hibridni režim rada

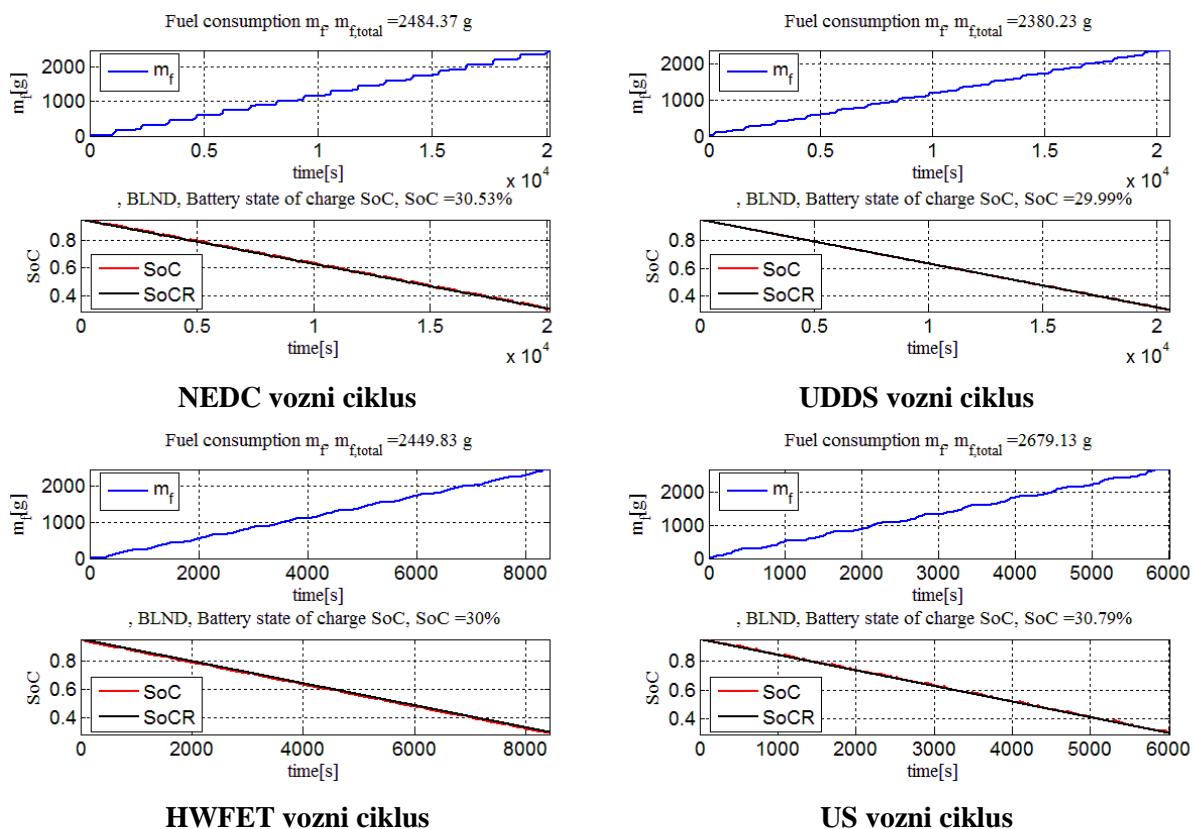
Tablica 17. Usporedbe rezultata simulacija s optimiranim parametrima PI regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora za pojedine vozne cikluse.

	Optimirani parametri		Neoptimirani parametri		p_3 [%]
	SoC_f [%]	m_f [g]	SoC_f [%]	m_f [g]	
NEDCx17	31.05	2524.95	31.06	2802.02	-9.89
UDDRx15	30.16	2284.35	30.16	2453.01	-6.87
HWFETx11	30.25	2431.96	30.22	2807.57	-13.37
USx10	30.76	2675.91	30.76	2896.7	-7.62
Kombiniranix4	30.37	3870.66	30.38	4249.24	-8.9

Tablica 18. Statistički rezultati simulacije s optimiranim parametrima P regulatora za pojedine vozne cikluse.

BLND statistika	1D-ECMS [%]	2D-ECMS [%]	A _{ek_mean} [g/kWh]	e _{RMS}
NEDCx17	16.19	83.81	241.19	0.6462
UDDSx15	0.26	99.74	248.89	0.6343
HWFETx11	4.59	95.41	237.91	0.6137
USx10	3.78	96.22	240.83	0.6082
Kombiniranix4	2.34	97.66	241.42	0.6291

Na slici 26 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s parametrima optimiranim za pojedine vozne cikluse.



Slika 26. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s parametrima PI regulatora optimiranim za pojedine vozne cikluse.

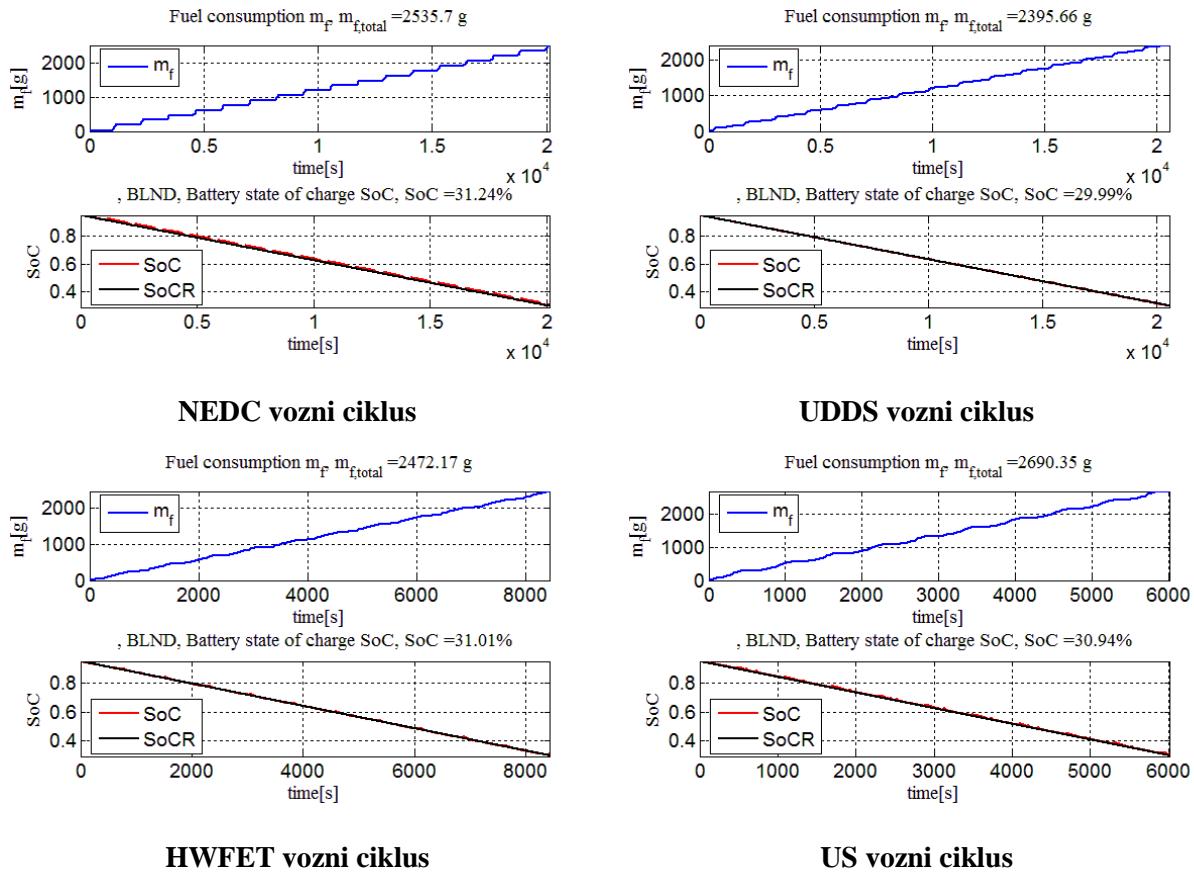
Tablica 19. Usporedbe rezultata simulacija s robusno optimiranim parametrima PI regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora.

	Optimirani parametri		Neoptimirani parametri		p_3 [%]
	SoC _f [%]	m _f [g]	SoC _f [%]	m _f [g]	
NEDCx17	31.09	2526.87	31.09	2805.02	-9.91
UDDSx15	30.07	2354.74	30.08	2449.73	-3.88
HWFETx11	31.01	2469.93	31.07	2862.91	-13.72
US06x10	30.95	2710.27	30.95	2904.07	-6.67

Tablica 20. Statistički rezultati simulacije s robusno optimiranim parametrima PI regulatora.

BLND rezultati	1D-ECMS [%]	2D-ECMS [%]	A _{ek_mean} [g/kWh]	e _{RMS}
NEDCx17	13.67	86.33	240.57	0.0089
UDDSx15	0.11	99.89	239.72	0.0016
HWFETx11	0.85	99.15	239.72	0.0029
US06x10	5.94	94.06	240.41	0.0061

Na slici 27 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima.



Slika 27. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima PI regulatora.

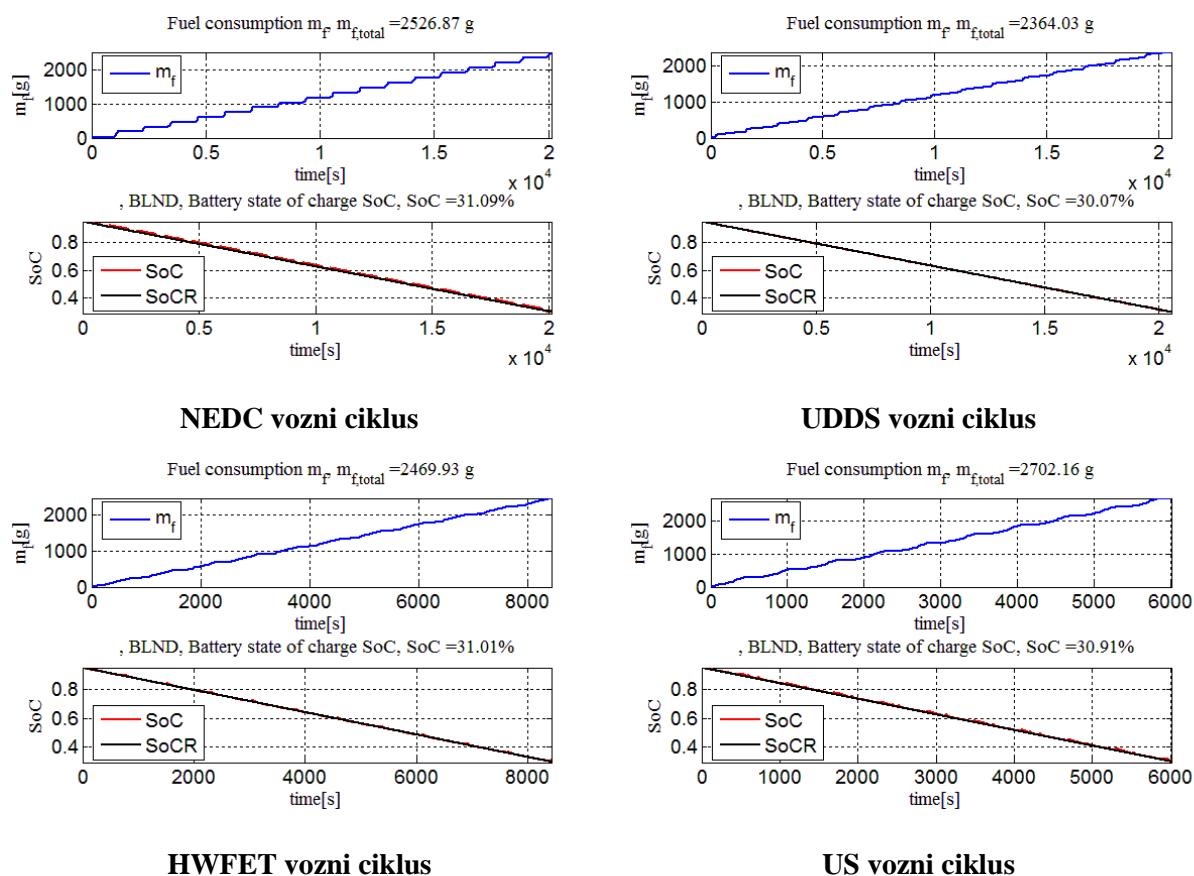
Tablica 21. Usporedba rezultata simulacija s analitički optimiranim parametrima PI regulatora u odnosu na simulacije s ne optimiranim parametrima P regulatora.

	Optimirani parametri		Neoptimirani parametri		p_3 [%]
	SoC_f [%]	m_f [g]	SoC_f [%]	m_f [g]	
NEDCx17	31.05	2517.37	31.09	2805.65	-9.93
UDDRx15	30.07	2364.03	30.08	2449.73	-3.5
HWFETx11	31.01	2469.93	31.01	2862.91	-13.72
US06x10	30.91	2702.16	30.91	2908.07	-7.08

Tablica 22. Statistički rezultati simulacije s analitički optimiranim parametrima PI regulatora.

BLND statistika	1D-ECMS [%]	2D-ECMS [%]	A_{ek_mean} [g/kWh]	e_{RMS}
NEDCx17	13.67	86.33	240.57	0.0090
UDDSx15	0.11	99.89	239.60	0.0016
HWFETx11	0.85	99.15	239.72	0.0029
US06x10	5.84	94.16	239.95	0.0060

Na slici 28 prikazani su dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima.

**Slika 28. Dijagrami SoC -a i potrošnje goriva m_f u ovisnosti o vremenu za simulacije s robusno optimiranim parametrima.**

5.3. Usporedni rezultati

Radi bolje preglednosti u ovom pod-poglavlju su navedeni i uspoređeni svi prethodno navedeni rezultati i uspoređeni sa rezultatima simulacija sa P regulatorom i ne optimiranim parametrima. Za različite slučajeve SoC regulatora i parametre regulatora uvedene su oznake :

1. DP – rezultati dobiveni dinamičkim programiranjem,
2. RB+ECMS0 – P regulator s ne optimiranim parametrima,
3. RB+ECMS1 – P regulator s parametrima optimiranim za pojedine vozne cikluse,
4. RB+ECMS2 – P regulator s robusno optimiranim parametrima,
5. RB+ECMS3 – PI regulator s parametrima optimiranim za pojedine vozne cikluse,
6. RB+ECMS4 - PI regulator s robusno optimiranim parametrima,
7. RB+ECMS5 – PI regulator s analitički optimiranim parametrima.

Tablica 23. Usporedbe rezultata simulacija za razne slučajeve u odnosu prema rezultatima simulacije s P regulatorom s ne optimiranim parametrima za složeni hibridni režim i različite vozne cikluse.

17xNEDC	RB+ECMS1	RB+ECMS2	RB+ECMS3	RB+ECMS4	RB+ECMS5
RB+ECMS0	-11.33%	-10.57%	-9.92%	-9.89%	-9.93%
15xUDDS	RB+ECMS1	RB+ECMS2	RB+ECMS3	RB+ECMS4	RB+ECMS5
RB+ECMS0	-6.48%	-3.68%	-6.87%	-3.88%	-3.5%
11xHWFET	RB+ECMS1	RB+ECMS2	RB+ECMS3	RB+ECMS4	RB+ECMS5
RB+ECMS0	-13.92%	-13.9%	-13.72%	-13.27%	-13.27%
10xUS06	RB+ECMS1	RB+ECMS2	RB+ECMS3	RB+ECMS4	RB+ECMS5
RB+ECMS0	-7.8%	-6.78%	-7.62%	-6.67%	-7.08%

Tablica 24. Usporedbe rezultata simulacija za razne slučajeve u odnosu prema rezultatima simulacije s P regulatorom s ne optimiranim parametrima za CS režim i različite vozne cikluse.

NEDC	RB+ECMS1	RB+ECMS2	RB+ECMS3	RB+ECMS4	RB+ECMS5
DP , CS	0.53%	2.01%	0.53%	1.54%	1.46%
UDDS	RB+ECMS1	RB+ECMS2	RB+ECMS3	RB+ECMS4	RB+ECMS5
DP , CS	1.53%	4.12%	1.40%	2.28%	2.27%
HWFET	RB+ECMS1	RB+ECMS2	RB+ECMS3	RB+ECMS4	RB+ECMS5
DP , CS	0.47%	1.41%	0.45%	1.45%	0.49%
US06	RB+ECMS1	RB+ECMS2	RB+ECMS3	RB+ECMS4	RB+ECMS5
DP , CS	-0.04%	1.84%	-0.03%	2.23%	-0.05%

6. Zaključak

Iz priloženih rezultata može se zaključiti da se optimiranjem parametara proporcionalnog regulatora s mrtvom zonom i pragova uključivanja/isključivanja motora s unutarnjim izgaranjem mogu postići značajnije uštede goriva. Valja naglasiti da su ovi parametri optimirani samo za zadane standardizirane vozne cikluse što ne znači će se njihovim korištenjem postići uštede goriva u drugim voznim ciklusima ili u realnoj vožnji. Korištenjem robusno optimiranih parametara ne postižu se jednake uštede goriva kao kod korištenja parametara optimiranih za pojedine vozne cikluse no zbog njihove robusnosti mogu se koristiti za različite vozne cikluse i postići zadovoljavajuće uštede goriva. Proporcionalna pojačanja i mrtva zone regulatora naštimana su tako da SoC regulator zahtjeva preciznije iznose snage P_{batt} od motora s unutarnjim izgaranjem kako bi održao SoC što bliže referenci. Pragovi uključivanja/isključivanja motora P_{on} i P_{off} naštimani su tako da motor radi samo u područjima najveće korisnosti.

Proporcionalno integralni PI regulator stanja napunjenosti baterije s optimiranim parametrima ne ostvaruje jednake uštede goriva pri voznim ciklusima u složeni hibridnom režimu rada kao P regulator s optimiranim parametrima. Zbog svoje prirode PI regulator pokušava svesti regulacijsko odstupanje e_{SoC} na nulu te time postići veću preciznost slijedenja reference. Zbog težnje smanjivanju regulacijskog odstupanja PI regulator će češće zahtijevati punjenje odnosno pražnjenje baterije mijenjanjem zahtjeva snage P_{batt} . Iz slike 17 vidljivo je da PI regulator češće traži pražnjenje baterije (negativni iznos P_{batt}) kako bi pratilo padajuću referencu SoC_R i sveo e_{SoC} na nulu. No u slučaju većeg zahtjeva snage od strane vozača P_d u trenutku kada je e_{SoC} jednak nuli, stvarni SoC će početi padati i udaljavati se od reference. Tada će se opet aktivirati PI regulator i zahtijevati snagu od motora kako bi napunio bateriju do SoC_R u danom vremenu uzorkovanja, no takav način regulacije rezultira nižom korisnošću od one koja se dobije primjenom P regulatora. U slučaju kada ne bi bilo vozača, to jest kada bi snaga P_d bila jednaka nuli cijelo vrijeme, PI regulator bi imao veoma visoku korisnost pri održavanju SoC -a oko njegove reference no vozačev zahtjev snage P_d uvelike utječe na izvedbu PI regulatora. Kod agresivnijih voznih ciklusa koji zahtijevaju veće i češće promjene snage P_d (npr. UDDS) korisnost je manja jer SoC regulator mora korigirati sada češće padove

SoC-a koji se događaju prilikom velikih zahtjeva snage P_d što rezultira većom potrošnjom goriva i manjom korisnošću. Iako ne ostvaruje uštedu goriva koju ostvaruje P regulator za standardizirane vozne cikluse, PI regulator bolje prati referencu regulirane veličine iz čega se može zaključiti da je PI regulator robusniji i da bi vjernije držao *SoC* na referentnoj vrijednosti u slučaju nestandardiziranih realnih voznih ciklusa.

Za daljnju optimizaciju upravljačke strategije i smanjenje potrošnje goriva tokom voznih ciklusa moguće je optimirati težinsku funkciju $W(e_{soc})$ premazivanja između 1D-ECMS i 2D-ECMS optimizacijskih algoritama, kako bi se našao optimalan odnos količine rada između ova dva načina. Podešavanjem što većeg broja parametara upravljačkog sustava u ovako kompleksom sustavu da odgovaraju standardiziranim voznim ciklusima može rezultirati manjom potrošnjom goriva.

7. Literatura

- [1] B. Škugor, J.Deur: Instanteneous Optimization-based Energy Management Control Strategy for Extended Range Electric Vehicle, SAE International Congress, 2013.
- [2] B. Škugor : Control Variables Optimization and Feedback Control Strateg Design for the Blended Operating Mode of an Extended Range Electric Vehile, SAE International Congress, 2014.
- [3] Z. Vukić, LJ. Kuljača: Automatsko upravljanje , Kigen, Zagreb, 2005.