Određivanje i praćenje indikatora zdravlja baterijskog članka

Preradović, Patrik

Master's thesis / Diplomski rad

2025

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:168:983886

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-23**

Repository / Repozitorij:

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

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 110

ODREĐIVANJE I PRAĆENJE INDIKATORA ZDRAVLJA BATERIJSKOG ČLANKA

Patrik Preradović

Zagreb, veljača 2025.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 110

ODREĐIVANJE I PRAĆENJE INDIKATORA ZDRAVLJA BATERIJSKOG ČLANKA

Patrik Preradović

Zagreb, veljača 2025.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Zagreb, 30. rujna 2024.

DIPLOMSKI ZADATAK br. 110

Pristupnik:	**Patrik Preradović (0036526926)**
Studij:	Informacijska i komunikacijska tehnologija
Profil:	Automatika i robotika
Mentor:	prof. dr. sc. Mario Vašak

Zadatak: **Određivanje i praćenje indikatora zdravlja baterijskog članka**

Opis zadatka:

Sustavi baterijske pohrane ključni su za proces dekarbonizacije energetskih i transportnih sustava. Pri eksploataciji baterije potrebno je pratiti stanje zdravlja samih baterijskih članaka, od kojih se ona sastoji, u sustavu za gospodarenje baterijom (engl. battery management system, BMS). U naprednom BMS se na temelju određenih parametara zdravlja mogu donositi i preporuke na koji se način baterijski sustav može eksploatirati kako bi se zdravlje baterijskih članaka čim manje degradiralo. Kao indikatori zdravlja često se koriste kapacitet članka i njegov unutarnji otpor. U ovome radu potrebno je, na temelju postojećih laboratorijskih podataka iz dužeg ciklusa eksploatacije baterijskog članka koja odgovara 100.000 km vožnje na konstantnoj temperaturi, odrediti reprezentativne iznose indikatora zdravlja u R2C nelinearnom modelu članka za svakih 10.000 km eksploatacije. Potrebno je razmotriti mogućnost pojednostavnjenja indikatora vezanog uz unutarnji otpor budući da je on u nelinearnom R2C modelu članka ovisan o stanju napunjenosti. Potom je potrebno osmisliti i implementirati algoritam kontinuiranog praćenja pojednostavnjenih indikatora zdravlja R2C nelinearnog modela članka na temelju mjernih podataka. Zadatak je potrebno izvesti u Matlab razvojnom okruženju.

Rok za predaju rada: 14. veljače 2025.

Sadržaj

1. Uvod **1**

2. Model litij-ionskog baterijskog članka **2**

2.1. Građa litij-ionskog članka 2

2.2. Vrste modela baterijskog članka 3

2.3. Model ekvivalentnog kruga 5

3. Optimizacija **8**

3.1. Prikupljeni podaci 8

3.2. Metoda identifikacije parametara 9

3.3. SoC - OCV krivulje 10

3.4. Ograničenja 11

3.5. Pojednostavnjenje otpora 13

3.6. Identifikacija pojednostavnjenih parametara starenja 14

3.7. Kontinuirano praćenje indikatora starenja 15

3.7.1. Moving Horizon optimizacija 15

4. Rezultati **16**

4.1. Rezultati identifikacije parametara 16

4.2. Rezultati pojednostavnjenja otpora 25

4.3. Rezultati identifikacije pojednostavljenih parametara 34

4.4. Rezultati online identifikacije indikatora zdravlja članka 45

5. Zaključak **49**

Literatura **51**

1. Uvod

Litij-ionski baterijski članak je sve zastupljenija punjiva vrsta spremnika energije, pogotovo u automobilskoj industriji zbog svoje velike energetske gustoće i kompaktnosti. Razvijeni su razni sustavi upravljanja baterijom (engl. battery management system, BMS) čijom se primjenom estimira ponašanje članka u različitim uvjetima kako bi se optimirao njegov vijek trajanja, maksimalnu iskoristivost, sigurnost i termalnu kontrolu članka. Postoje različiti modeli interpretacije litij-ionskog članka, svaki sa svojim ograničenjima i primjenama. Cilj je da odredimo i kontinuirano pratimo parametre R2C modela ekvivalentnog strujnog kruga.

U početku rada opisana su sama građa i princip rada litij-ionskog baterije. Nakon toga su opisane vrste modela za simuliranje ponašanja baterije. Poslije je opisan matematički model članka ekvivalentnim strujnim krugom i objašnjena su prikupljena mjerenja. Zatim slijedi opis optimizacijskog problema s postavljenim ograničenjima. Rješavanje nelinearnog optimizacijskog problema napravljeno je uz pomoć Fmincon optimizatora. Korištena je metoda sekvencijalnog kvadratnog programiranja (SQP) kako bi se riješio zadani nelinearni problem.

Zadatak ovog rada je estimirati parametre zdravlja baterijskog članka „offline“ metodom koristeći veliki skup podataka iz mjerenja. Nakon toga se pojednostavnjuje vektor parametara modela kako bi se znalo što su konkretni indikatori zdravlja članka. Zatim se ponovno identificiraju parametri modela, ali ovaj put s reduciranim vektorom parametara. Kasnije, nakon što je model uspješno pojednostavljen i validiran, potrebno je te parametre iskoristiti za „online“ metodu identifikacije modela odnosno kontinuirano praćenje indikatora zdravlja članka. Tada će biti bitno pronaći optimalnu veličinu vremenskog prozora za što bolju lokalizaciju parametara i što manju nesigurnost njihova određivanja. Potom slijedi prikaz i objašnjenje rezultata, a na kraju je napisan zaključak rada.

2. Model litij-ionskog baterijskog članka

2.1. Građa litij-ionskog članka

Litij-ionski baterijski članak sastoji se od 4 glavne komponente što je vidljivo i na slici 2.1:

1. **Elektrode**: Pozitvna elektroda, katoda, obično je izrađena od materijala poput litij-kobalt oksida ($LiCoO_2$), litij-željezo fosfata ($LiFePO_4$) ili nikal-mangan-kobalt oksida (NMC) [1]. Negativna elektroda, anoda, radi se najčešće od grafita.

2. **Elektrolit**: Tekući ili čvrsti medij koji omogućuje prolazak litijevih iona, ali sprječava prolazak elektrona.

3. **Separator**: Fizička barijera koja sprječava kratke spojeve između katode i anode odnosno omogućava prolaz iona i sprječava prolaz elektrona do suprotne elektrode.

4. **Kolektori**: Pozitivni kolektor od aluminija i negativni kolektor od bakra spajaju elektrode s vanjskim električnim krugom.

Tijekom punjenja litijevi ioni se izvlače iz katode i prolaze kroz elektrolit do anode. Elektroni se gibaju kroz vanjski krug do anode, gdje se litijevi ioni kombiniraju s njima i ugrađuju u materijal anode. Proces je obrnut tijekom pražnjenja. Litijevi ioni prelaze iz anode u katodu kroz elektrolit. Elektroni teku natrag kroz vanjski krug kako bi se energija iskoristila za napajanje motora i/ili elektronskih uređaja. Sam proces rada članka prikazan je na slici 2.2.

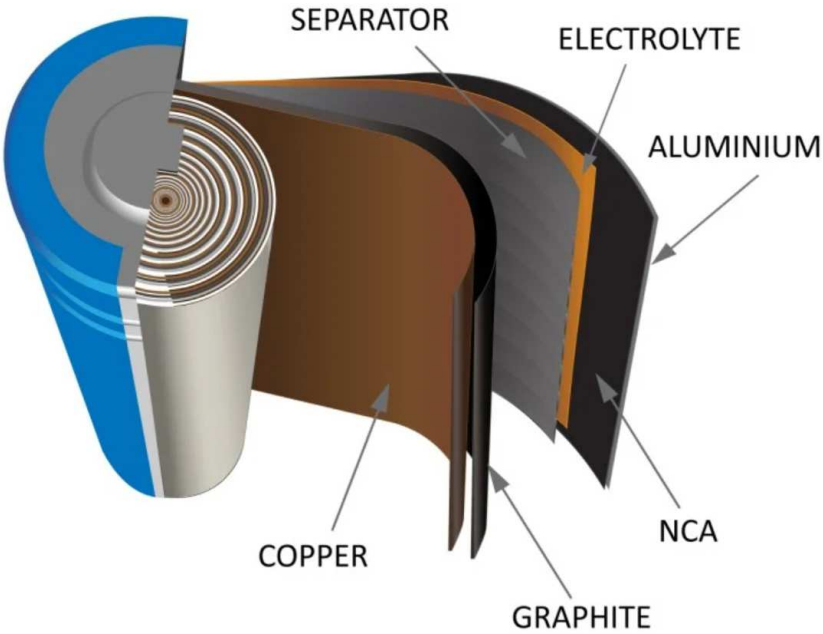

Slika 2.1: Struktura litij-ionskog baterijskog članka [2]

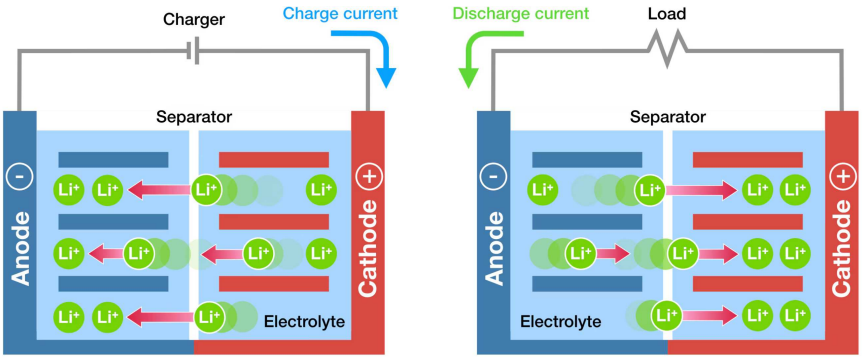

Slika 2.2: Vizualni prikaz principa punjenja i pražnjenja članka [3]

2.2. Vrste modela baterijskog članka

Modeli litij-ionskih baterijskih članaka koriste se kako bi simulirali ponašanje baterije, fokusirajući se na električne i termalne karakteristike te karakteristike starenja članka.

Strujni modeli simuliraju električne veličine na samim terminalima članka kao što su napon, struja i SoC.

Termalni modeli prate distribuciju i ponašanje temperature unutar baterijskog članka. Mogu se modelirati u jednoj, dvije ili tri dimenzije ovisno o nivou

potrebnih detalja.

Modeli starenja članka analiziraju degradaciju baterije tijekom vremena, prateći pad kapaciteta i rast unutarnjeg otpora. Starenje članka može biti prouzrokovano kalendarskim ili cikličkim starenjem. Kalendarsko starenje je rezultat degradacije članka tijekom skladištenja, pri čemu njegova temperatura i stanje napunjenosti utječu na starenje članka. Cikličko starenje se odnosi na degradaciju nakon više broja ciklusa pražnjenja i punjenja članka pod specifičnim uvjetima, ovisno o temperaturi i profilu struje.

Modeli se mogu kombinirati kako bi se dobili točniji i složeniji modeli litij-ionskog članka. Često su temeljeni na matematičkom, fizikalnom pristupu ili pristupu s ekvivalentnim električnim krugom. Za matematički pristup se često koriste pojednostavnjene jednadžbe ili analitičke/stohastičke funkcije za simulaciju vanjskog ponašanja sustava bez uključivanja realnih fizičkih principa sustava članka. Fizički pristup se koristi za modele opisane diferencijalnim algebarskim jednadžbama ili parcijalnim diferencijalnim jednadžbama povezanim s fizikalnim pojavama koje se javljaju u stvarnom sustavu. Strujni model članka opisan ekvivalentnim električnim krugom koristi električne elemente poput otpora i kondenzatora kako bi se opisalo električno ili termalno ponašanje članka. Jednostavniji su od fizičkih modela, a u isto vrijeme predstavljaju srednju točnost stvarnog modela. Jednostavno ih je implementirati za sustave u stvarnom vremenu [4]. Usporedba različitih pristupa modeliranju litij-ionskih članaka opisana je tablicom 2.1. Odabran je strujni model s ekvivalentnim električnim krugom zbog navedenih prednosti.

Model	**Prednosti**	**Nedostaci**
Matematički	Vrlo jednostavan i zahtijeva malo vremena	Niska točnost
Fizički	Visoka točnost	Vrlo složen i vremenski zahtjevan
Strujni	Jednostavan i intuitivan za implementaciju	Srednja točnost

Tablica 2.1: Usporedba različitih pristupa modeliranja baterija [4]

2.3. Model ekvivalentnog kruga

Model ekvivalentnog kruga (ECM) opisuje ponašanje litij-ionske baterije koristeći standardne elemente električnog kruga. Odabran je model ekvivalentnog kruga koji se sastoji od otpornika R_0 spojenog u seriji s dva RC člana kao što je prikazano na slici 2.3.

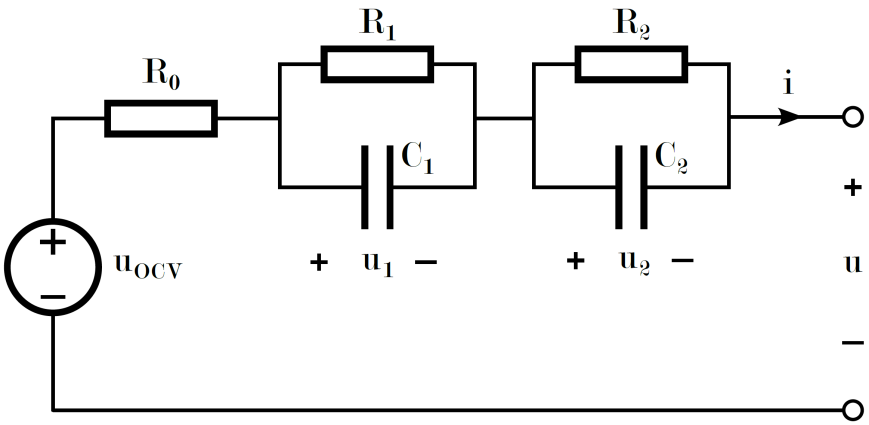

Slika 2.3: Model ekvivalentnog kruga baterijskog članka [5]

Unutarnji otpor R_0 predstavlja unutarnje gubitke baterije zbog otpora elektrolita, unutarnjeg otpora elektroda, strujnih kolektora i žica [6]. Otpor R_0 uzrokuje trenutni pad napona kada protječe struja. Vrijednosti otpora se s vremenom povećavaju zbog više razloga kao što su zadebljanje SEI sloja (sloja krutog elektrolita u međufazi), gubitka aktivnog materijala zbog taloženja litija na elektrodi (na engleskom „Lithium plating"), povećanja otpora kontakta i brojnih drugih razloga [7]. Unutarnji otpor je jedan od glavnih indikatora zdravlja baterije.

Efekti difuzije litijevih iona u materijale elektroda predstavljeni su serijom RC elemenata. Svaki RC član se sastoji od otpornika R spojenog u paralelu s kondenzatorom C. Vremenska konstanta $T = R \cdot C$ definira koliko brzo se napon članka stabilizira nakon promjene strujnog opterećenja. Veće vremenske konstante zbog difuzijskih efekata uzrokuju sporiju stabilizaciju napona.

Spori difuzijski procesi predstavljeni su prvim RC članom gdje su R_1, C_1, T_1 i u_1 relevantne veličine. Povezani su s prijenosom litijevih iona unutar čvrstog materijala elektroda. Ovaj proces je sporiji jer ioni moraju prolaziti kroz kristalnu rešetku aktivnog materijala što ograničava brzinu prijenosa iona [8].

Brzi difuzijski procesi reprezentirani su drugim RC članom, a relevantne veličine su iste. Opisuju prijenos iona u elektrolitu ili blizu površine elektroda. Ovi

procesi su brži zbog veće difuzivnosti u tekućem elektrolitu i kraćih udaljenosti koje ion mora prijeći [8].

Veći broj RC članova poboljšava točnost modela, ali se i povećava računalna složenost identifikacije modela članka.

Napon otvorenog kruga u_{ocv} predstavlja nivo napona baterije kada nije pod opterećenjem. Vrijednost u_{ocv}-a je indikator stanja napunjenosti (SoC) tijekom mirovanja baterije te su završile sve prijelazne pojave. Baterija će imati viši napon kada je više napunjena, a niži napon kada je praznija. Ovaj napon može varirati ovisno o materijalu elektroda, temperaturi i drugim uvjetima. Ako napon otvorenog kruga ne odgovara očekivanoj vrijednosti za određeno stanje napunjenosti, to može ukazivati na problem s baterijom (primjerice oštećenje ćelija, degradacija ili loše performanse).

Pozitivne vrijednosti struje predstavljaju pražnjenje baterije, a negativne punjenje. Mjerene vrijednosti su struja i i napon u na stezaljkama što su ujedno i izlazne i ulazne varijable. Izrazi za varijable stanja u_1 i u_2 definirani su na sljedeći način u kontinuiranom obliku:

$$\frac{d}{dt}u_1 = -\frac{1}{R_1C_1}u_1 + \frac{1}{C_1}i \tag{2.1}$$

$$\frac{d}{dt}u_2 = -\frac{1}{R_2C_2}u_2 + \frac{1}{C_2}i \tag{2.2}$$

Diskretiziranjem prethodnih izraza zero-order hold (ZOH) metodom slijedi:

$$u_1(k+1) = e^{-\frac{1}{T_1}T_s}u_1(k) + R_1\left(1 - e^{-\frac{1}{T_1}T_s}\right)i(k) \tag{2.3}$$

$$u_2(k+1) = e^{-\frac{1}{T_2}T_s}u_2(k) + R_2\left(1 - e^{-\frac{1}{T_2}T_s}\right)i(k) \tag{2.4}$$

gdje su vremenske konstante $T_1 = R_1C_1$ i $T_2 = R_2C_2$, a T_s predstavlja vrijeme uzorkovanja odnosno vremensku razliku između dva uzastopna mjerenja. Razlika ne mora uvijek biti konstantna što omogućava identifikaciju parametara s varirajućim vremenom uzorkovanja $T_s = T_s(k)$. Pretpostavka je da su vrijednosti struje i napona konstantne u intervalu $[kT_s, (k+1)T_s)$. Napon na stezaljkama baterijske ćelije definiran je izrazom:

$$u(k) = u_{ocv} - u_1(k) - u_2(k) - R_0 i(k) \tag{2.5}$$

Svi parametri ovise o stanju napunjenosti baterije SoC i smjeru struje i kao što je opisano jednadžbom 2.6. Pozitivne vrijednosti struje predstavljaju pražnjenje članka, a negativne vrijednosti punjenje:

$$p = f(SoC, sgn(i)), \forall p \in \left\{R_0, R_1, R_2, T_1, T_2\right\} \tag{2.6}$$

Stoga, postoje dva skupa parametara za svaku definiranu točku $SoC-a$, jedan set za punjenje i jedan za pražnjenje. $SoC \in [0, 1]$ se estimira metodom brojanja kulona:

$$SoC(k+1) = SoC(k) - \frac{T_s}{C} i(k) \tag{2.7}$$

gdje C označava kapacitet baterijskog članka. Kapacitet baterije se isto estimira s obzirom da degradira tijekom vremena.

3. Optimizacija

3.1. Prikupljeni podaci

Mjerenja sadrže preko 20 milijuna vremenskih uzoraka struje, napona i vremena tijekom emuliranih 100 tisuća kilometara vožnje automobilom uz konstantnu temperaturu članka. Prosječno vrijeme uzorkovanja podataka iznosi 10 ms. Svaka optimizacija modela se vrši na skupu mjerenja od 10 tisuća kilometara na kojima se identificiraju parametri modela ekvivalentnog kruga članka. Graf ulaznih i izlaznih podataka za skup mjerenja od 10 do 20 tisuća kilometara prikazan je na slici 3.1.

Za svakih 10 tisuća kilometara korišten je samo dio podataka bez pogrešnih mjerenja. U podacima postoji problem s mjerenjima jer na nekim dijelovima nedostaju podaci i vrijednosti vremena uzorkovanja T_s su ponekad jako velike što stvara probleme za optimizaciju modela. Uglavnom, T_s maksimalno traje 60 s, a nekad ta vrijednost zna biti veća i nekoliko redova veličine kao što je vidljivo na zadnjem grafu na slici 3.1. Iz tog razloga odabrano je samo 3 milijuna podataka za svaku optimizaciju osim za skup mjerenja od 50 do 60 tisuća kilometara kada čistih podataka ima gotovo četiri puta manje.

Vrijednosti fiksnih dijelova parametara p_{fix} s njihovim mjernim jedinicama i predefiniranim vrijednostima opisane su u tablici 3.1.

Tablica 3.1: Parametri

Parametri	Mjerna jedinica	Vrijednosti
C_{nom}	As	$4.8 \cdot 3600$
R_0	Ω	$20 \cdot 10^{-3}$
R_1	Ω	$10 \cdot 10^{-3}$
R_2	Ω	$10 \cdot 10^{-3}$
T_1	s	150
T_2	s	100

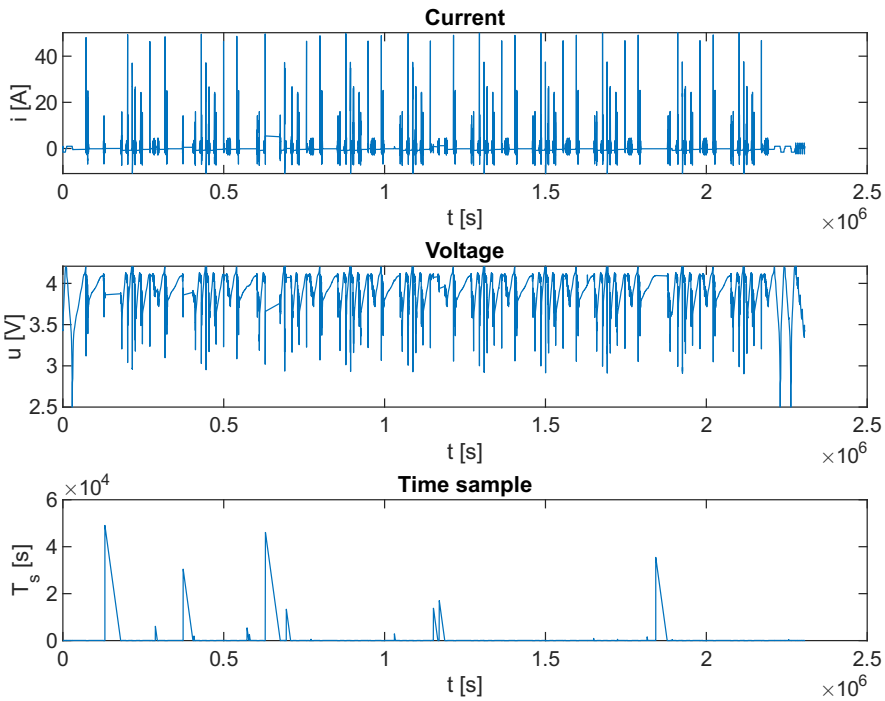

Slika 3.1: Prikaz mjerenog napona, struje i vremena uzorkovanja

3.2. Metoda identifikacije parametara

Parametri litij-ionskog baterijskog članka opisani su konveksnom krivuljom zbog same elektrokemijske prirode punjenja i pražnjenja baterije kao što je opisano u ranijim radovima. Iz tog razloga, odabrana je „fmincon" funkcija u MATLAB-u za identifikaciju parametara zdravlja baterijskog članka. Fmincon je funkcija koja omogućuje postavljanje ograničenja za definirani matematički model baterijskog

članka. Cilj optimizacije je minimiziranje funkcije cilja. U ovom slučaju parametri modela članka opisani su konveksnim funkcijama što olakšava pronalazak globalnog minimuma.

Za nelinearnu optimizaciju odabran je „SQP" (Sekvencijalno kvadratno programiranje) algoritam optimizacije. Takav postupak temelji se na rješavanju niza kvadratnih potproblema dok se ne zadovolje Karush-Kuhn-Tuckerovi uvjeti konvergencije [9]. Algoritam se pokazao najpouzdanijim zbog vremenski kraće optimizacije i točnosti dobivenih rješenja problema.

3.3. SoC - OCV krivulje

Krivulja SoC-OCV dana je od proizvođača te sadrži 402 vrijednosti OCV-a što je vidljivo na slici 3.2. Vrijednosti napona otvorenog kruga kada je članak u potpunosti napunjen iznosi 4.2 V. Kada je članak skroz ispražnjen, minimalna vrijednost OCV-a iznosi 2.5 V. Broj vrijednosti SoC-a je smanjen kako bi računalna složenost optimizacije bila manja. Aproksimirane vrijednosti SoC-a odabiru se minimizacijom pogreške između stvarnih i aproksimiranih vrijednosti napona otvorenog kruga [5]:

$$error = ||u_{OCV}^{dch} - \hat{u}_{OCV}^{dch}||_2 + ||u_{OCV}^{ch} - \hat{u}_{OCV}^{ch}||_2 \tag{3.1}$$

Vrijednosti u_{OCV}-a odgovaraju SoC-OCV krivulji od proizvođača, a $\hat{u}_{OCV}$ je aproksimirana vrijednost napona otvorenog kruga. Eksponenti dch i ch označavaju pražnjenje i punjenje baterije.

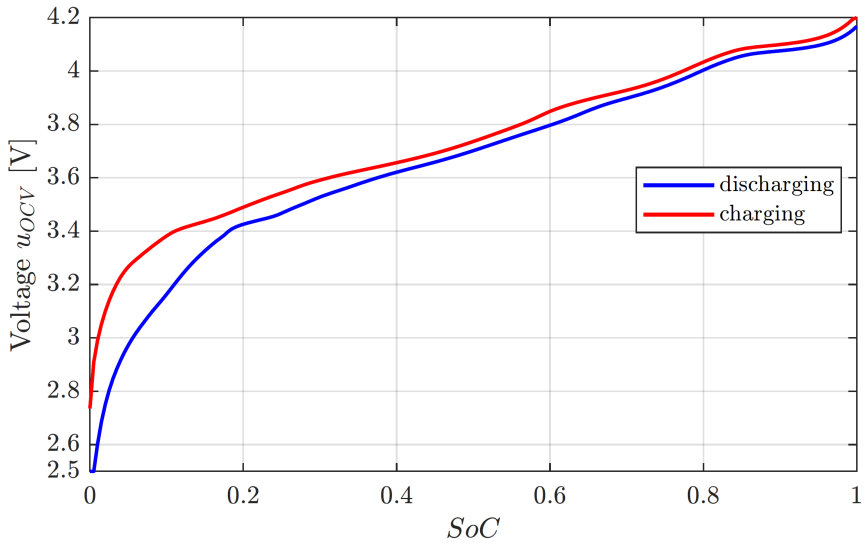

Slika 3.2: SoC-OCV krivulja baterije na 25°C ([5])

Odabrano je 15 točaka SoC-a $\{SoC_1^{DP}, \ldots, SoC_{15}^{DP}\}$ za identifikaciju parametara jer se pogreška aproksimacije ne smanjuje drastično povećanjem broja točaka SOC-a što je vidljivo na slici 3.3:

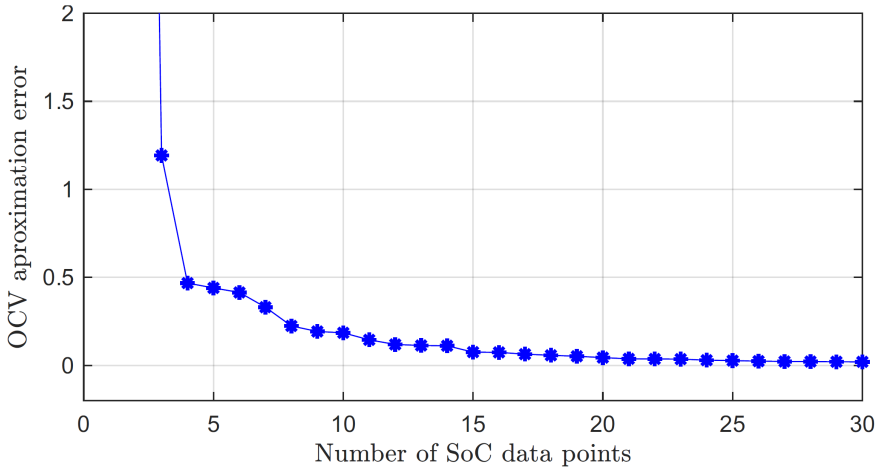

Slika 3.3: Greška aproksimacije SoC-OCV krivulje ovisno o broju točaka SoC-a [5]

3.4. Ograničenja

Identifikacija parametara modela računa se minimiziranjem funkcije:

$$J = \Sigma_{k=0}^{N-1}(u(k) - \hat{u}(k))^2 \tag{3.2}$$

pri čemu $u(k)$ predstavlja k-to mjerenje napona, a $\hat{u}(k)$ aproksimiranu vrijednost

napona koju se dobije iz prethodnih jednadžbi 2.3, 2.4 i 2.5. Parametri R_0, R_1, R_2, T_1 i T_2, u_{OCV} dobiju se linearnom interpolacijom između dvije susjedne točke SoC-a. Optimizacijski problem opisan je u nastavku:

$$\begin{aligned} argmin(J(x)) \\ A_{ineq} \cdot x \leq b_{ineq} \\ x_{min} \leq x \leq x_{max} \end{aligned} \tag{3.3}$$

Vektor x dimenzija (1×154) je sastavljen od:

1. ECM parametara za pražnjenje i punjenje p^{dch}, p^{ch}, $\forall p \in \left\{R_0, R_1, R_2, T_1, T_2\right\}$
2. Kapaciteta baterijskog članka C
3. Početnih uvjeta $SoC(0)$, $u_1(0)$ i $u_2(0)$

Svi parametri su ovisni o stanju napunjenosti $SoC \in [0, 1]$. Postavljena su ograničenja na sam model kako bi se što preciznije simuliralo realno ponašanje litij-ionskog baterijskog članka [5]. Uvjeti opisani formulama 3.3 su:

1. Treba postojati jasna razlika između sporog i brzog RC kruga odnosno njihovih vremenskih konstanti T_1 i T_2 za punjenje i pražnjenje:

$$2T_2(SoC) \leq T_1(SoC), \forall SoC \in \{SoC_1^{DP}, \ldots, SoC_{15}^{DP}\} \tag{3.4}$$

2. Otpori R_1 i R_2 RC članova trebaju biti manji od unutarnjeg otpora R_0 za punjenje i pražnjenje:

$$\begin{aligned} R_1(SoC) \leq R_0(SoC), R_2(SoC) \leq R_0(SoC), \\ \forall SoC \in \{SoC_1^{DP}, \ldots, SoC_{15}^{DP}\} \end{aligned} \tag{3.5}$$

3. Kapacitet baterije ne smije biti puno veći od nazivnog kapaciteta:

$$C \leq 4.9Ah \tag{3.6}$$

4. Krivulje parametara konveksnog su oblika odnosno druga derivacija parametara $\forall p \in \left\{R_0, R_1, R_2, T_1, T_2\right\}$ mora biti pozitivna ili veća od nula za punjenje i pražnjenje ([5]):

$$\frac{p(SoC_s^{DP}) - p(SoC_{s-1}^{DP})}{SoC_s^{DP} - SoC_{s-1}^{DP}} \leq \frac{p(SoC_{s+1}^{DP}) - p(SoC_s^{DP})}{SoC_{s+1}^{DP} - SoC_s^{DP}}, \tag{3.7}$$
$$\forall s \in \{2, \ldots, 14\}$$

5. Svaka sljedeća optimirana vrijednost kapaciteta C mora biti manja ili jednaka od prijašnje:

$$C(i+1) \leq C(i), \forall i \in \{10k, 20k, \ldots, 100k\}\, km \tag{3.8}$$

6. Svi sljedeći optimirani otpori R_0, R_1 i R_2 moraju imati veću ili jednaku vrijednost od prijašnje:

$$R_0(i+1) \geq R_0(i), R_1(i+1) \geq R_1(i), R_2(i+1) \geq R_2(i), \tag{3.9}$$
$$\forall i \in \{10k, 20k, \ldots, 100k\}\, km$$

7. Vremenske konstante T_1 i T_2 su fiksirane tijekom optimizacije:

$$T_1(i) = T_1(1), T_2(i) = T_2(1), \tag{3.10}$$
$$\forall i \in \{10k, 20k, \ldots, 100k\}\, km$$

Potrebno je i normalizirati parametre $\forall p \in \{R_0, R_1, R_2, T_1, T_2, C\}$ jer su vrijednosti nekih parametara drastično veće od drugih. Svaki parametar definiran je na sljedeći način kako ne bi došlo do numeričke nestabilnosti:

$$p = p_{fix} p_{opt} \tag{3.11}$$

Gdje je p_{fix} unaprijed definirana vrijednost parametra p, a p_{opt} je vektor parametara koji se optimizira. Na taj način, sve varijable će biti unutar prihvatljivih magnituda tijekom optimizacije.

3.5. Pojednostavnjenje otpora

Potrebno je odrediti veličine koje opisuju starenje baterijskog članka u vremenu odnosno prijeđenom putu. Za kapacitet članka je jednostavno odrediti veličinu jer je to jedna vrijednost. Međutim, svi ostali parametri ovisni su o stanju napunjenosti. Svaki parametar je vektor koji sadrži 15 elemenata za svaku točku

SoC-a. Optimizacijom parametara modela identificiramo njihove vrijednosti za svih sto tisuća kilometara.

Relevantni parametri za određivanje zdravlja baterije (SoH) su otpori R_0, R_1 i R_2 te kapacitet C. Cilj je prikazati otpore sažetije odnosno reducirati vektor. Potrebno ih je predstaviti s malim brojem parametara μ bez ovisnosti o SoC-u. Ideja je da odaberemo funkciju koja najbolje aproksimira već identificirani model parametara. Primjerice, estimacija unutarnjeg otpora polinomijalnom funkcijom drugog reda definirala bi se na sljedeći način:

$$\begin{gathered}\hat{R}^i(SoC) = f(\mu) = R^{base}(SoC) \cdot \mu_1^i + R^{base}(SoC) \cdot (\mu_2^i)^2, \\ \forall SoC \in \{SoC_1^{DP}, \ldots, SoC_{15}^{DP}\}, \\ i \in \{10k, ..., 100k\}\, km \\ \mu^i \in \{\mu_1, \mu_2\}\end{gathered} \tag{3.12}$$

Bazni otpor R^{base} predstavlja prvu iteraciju identifikacije otpora odnosno R^{10k} koja se optimizirala fmincon funkcijom. Estimacija otpora u ovom slučaju dobije se minimiziranjem razlike referentne i aproksimirane funkcije otpora R koristeći metodu najmanjih kvadrata putem Matlab optimizatora „fminunc" bez ograničenja s njegovim „quasi-newton" solverom:

$$cost = \int_{0.3}^{0.8} (R^i(SoC) - f(\mu^i))^2 \, dSoC \tag{3.13}$$

Potrebna je interpolacija otpora kako bi dobili kontinuiranu krivulju za optimizaciju. Svakom optimizacijom estimiramo μ vektor parametara za svaku iteraciju i emulirane vožnje od 10 tisuća kilometara u rasponu SoC-a od 30% do 80%. Izvan tog po o o odabranoj funkciji. Kasnije će se ispostaviti u dobivenim rezultatima da se dimenzije vektora sva tri otpora mogu značajno smanjiti što će uvelike pojednostaviti problem identifikacije parametara modela članka.

3.6. Identifikacija pojednostavnjenih parametara starenja

Nakon odabira funkcije koja najbolje aproksimira već naučeni model iz poglavlja 3.2., slijedi ponovno identifikacija modela, ali sad s reduciranim vektorom parametara starenja. Parametri su identificirani na istom skupu mjerenja kako bi

se usporedila točnost aproksimacije novih otpora s referentnim iz već naučenog modela. Maknut je uvjet 4 iz ograničenja modela jer se identifikacija izvodila na području SoC-a od 30% do 80% gdje je krivulja otpora uglavnom linearna. Ostali uvjeti su ostali isti i korišten je isti optimizator s istim algoritmom optimizacije minimuma.

3.7. Kontinuirano praćenje indikatora starenja

Zadnji korak je dinamička odnosno „online“ identifikacija parametara zdravlja članka kontinuirano u vremenu. Model se identificira na manjem vremenskom prozoru s manje mjerenja koristeći „Moving Horizon“ metodu estimacije parametara.

3.7.1. Moving Horizon optimizacija

Estimacija s pomičnim vremenskim intervalom (eng. Moving Horizon estimation (MHE)) koristi se za estimaciju stanja sustava na temelju zašumljenih mjerenja. To je algoritam koji radi na principu pomicanja horizonta odnosno vremenskog intervala, što znači da kontinuirano ažurira estimaciju stanja kako nova mjerenja postanu dostupna. Optimizacijski problem rješava se korištenjem optimizacijskog algoritma, kao što je metoda unutarnje točke (eng. Interior-point), u svakom vremenskom koraku kako nova mjerenja postanu dostupna. Rješenje optimizacijskog problema daje estimaciju stanja sustava za trenutni vremenski korak i sljedećih nekoliko vremenskih koraka u horizontu. Zatim se horizont pomiče naprijed za jedan vremenski korak i proces se ponavlja [10]. Parametri se estimiraju na vremenskom horizontu T_{int} iz kojih uzimamo odzive simetrično oko točke u vremenu. Nakon svake estimacije, vremenski interval se pomiče unaprijed za vrijeme T_s.

4. Rezultati

4.1. Rezultati identifikacije parametara

Unutarnji otpor R_0 povećava se s vremenom kao što je prikazano na grafovima 4.1, 4.2 i 4.3. Drugim riječima, što je više automobil prešao kilometara to je veći unutarnji otpor litij-ionskog članka.

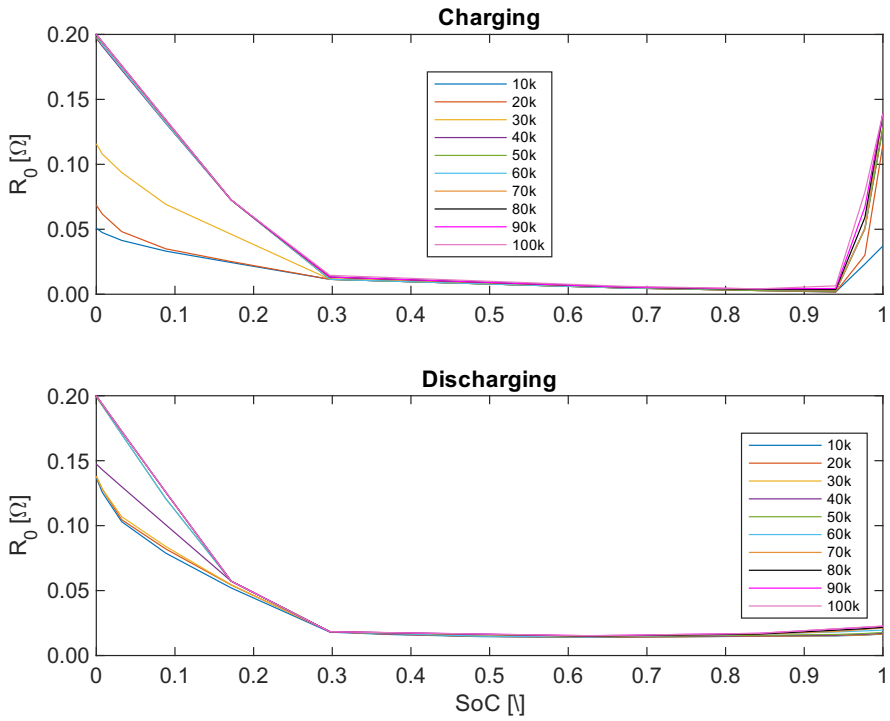

Slika 4.1: Prikaz otpora R_0 u ovisnosti o $SoC - u$

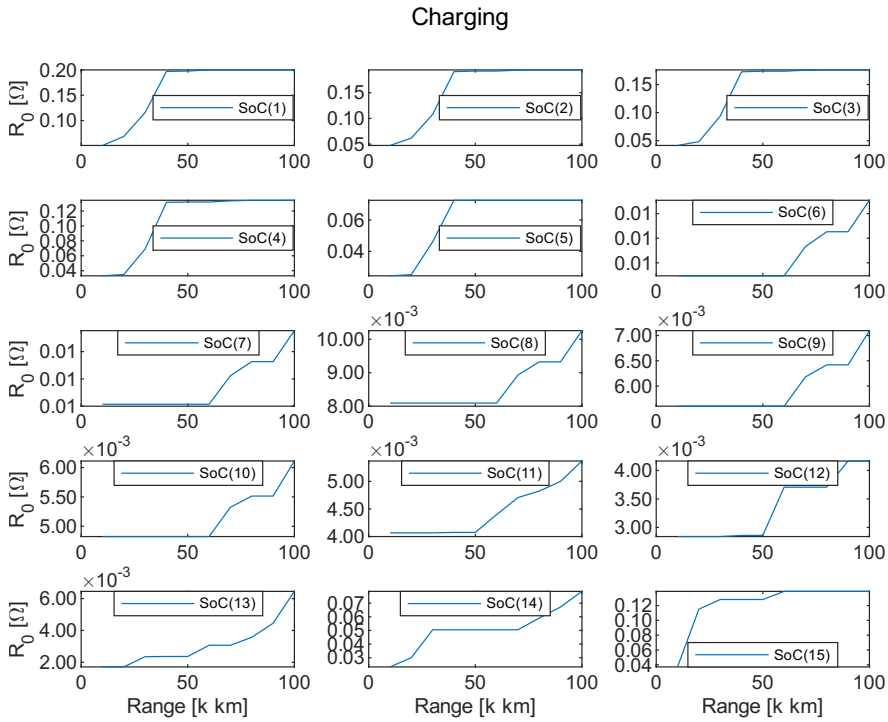

Slika 4.2: Promjena otpora R_0 za sve vrijednosti SoC-a tijekom punjenja

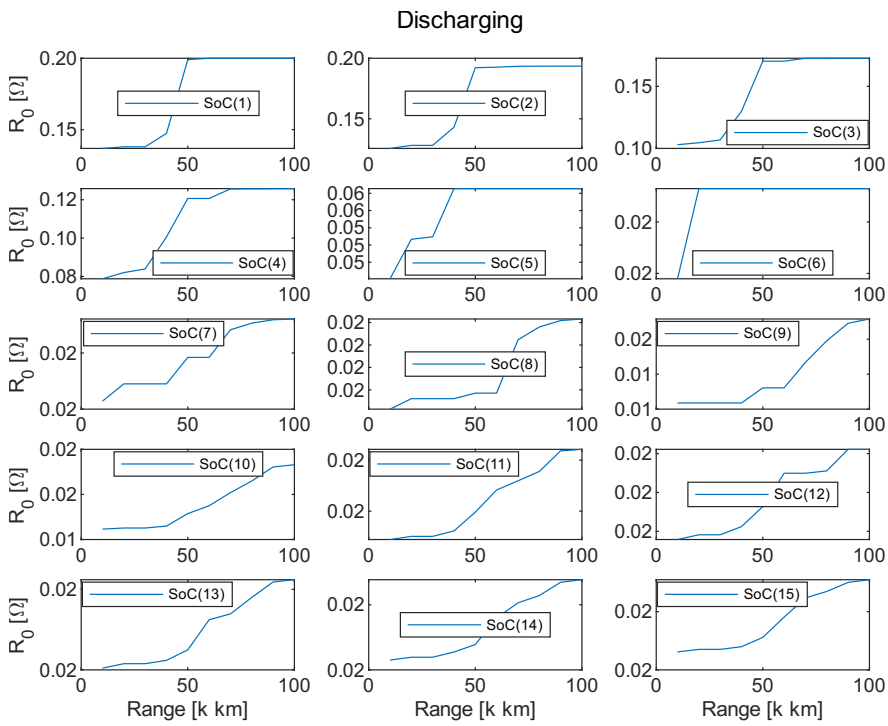

Slika 4.3: Promjena otpora R_0 za sve vrijednosti SoC-a tijekom pražnjenja

Isto vrijedi i za otpore RC članova R_1 i R_2. Ovisnost otpora R_1 o SoC-u za punjenje i pražnjenje nalazi se na slici 4.4. Grafovima 4.5 i 4.6 opisana je promjena

otpora kako se domet povećava za svaku vrijednost SoC-a. Isto vrijedi i za otpor R_2 koji je prikazan slikama 4.7, 4.8 i 4.9. Svi otpori poprimaju konveksan oblik i sve vrijednosti otpora R_1 i R_2 manje su od otpora R_0.

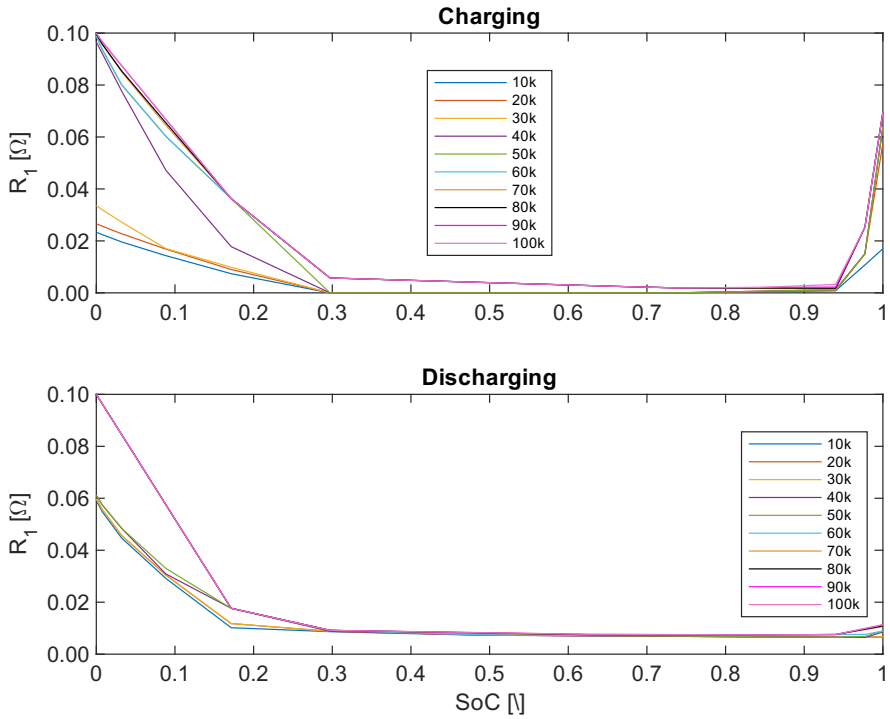

Slika 4.4: Prikaz otpora R_1 u ovisnosti o $SoC - u$

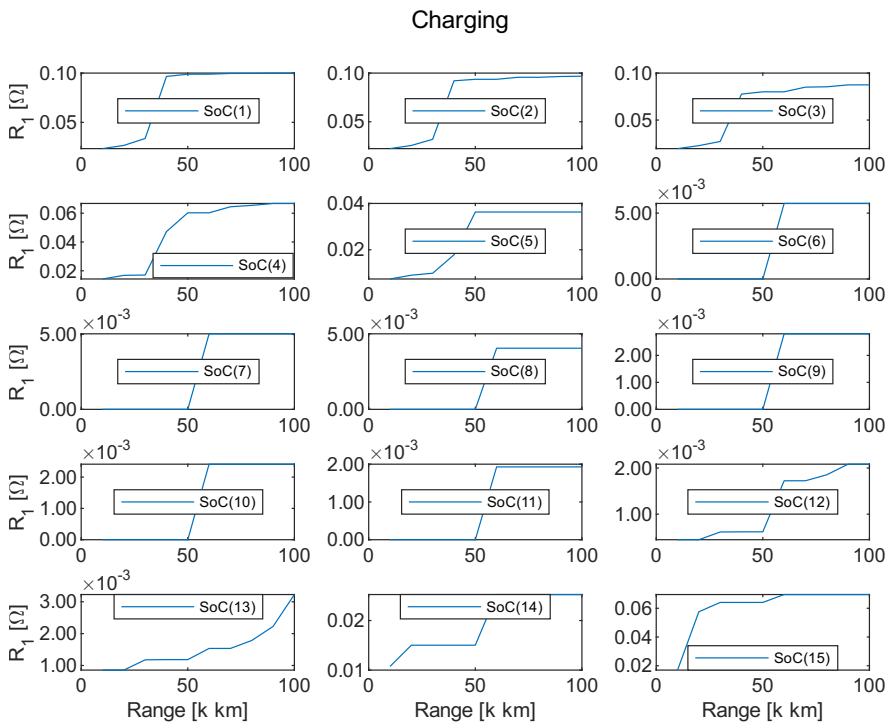

Slika 4.5: Promjena otpora R_1 za sve vrijednosti SoC-a tijekom punjenja

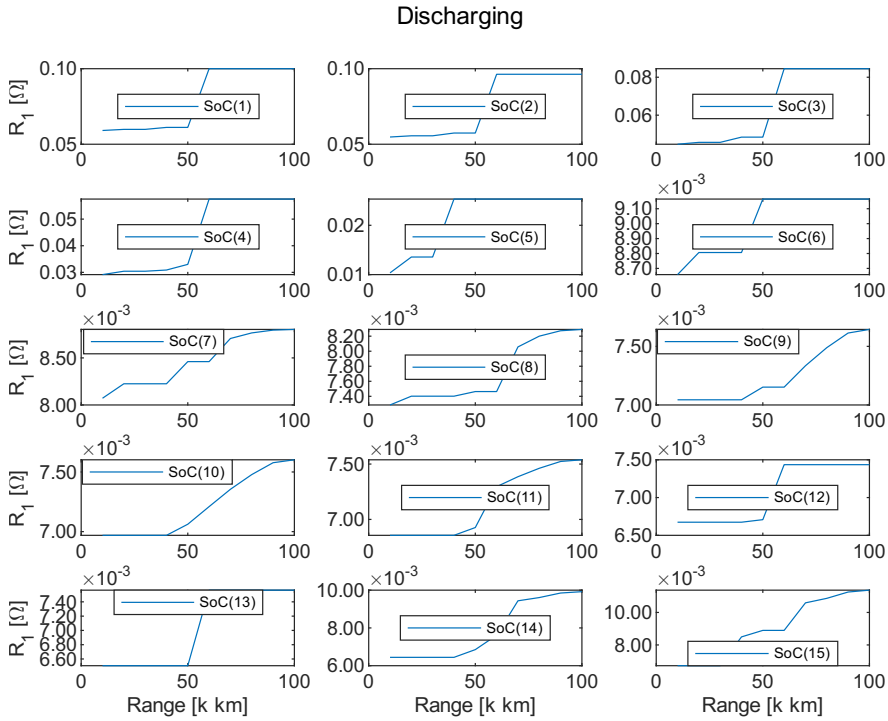

Slika 4.6: Promjena otpora R_1 za sve vrijednosti SoC-a tijekom pražnjenja

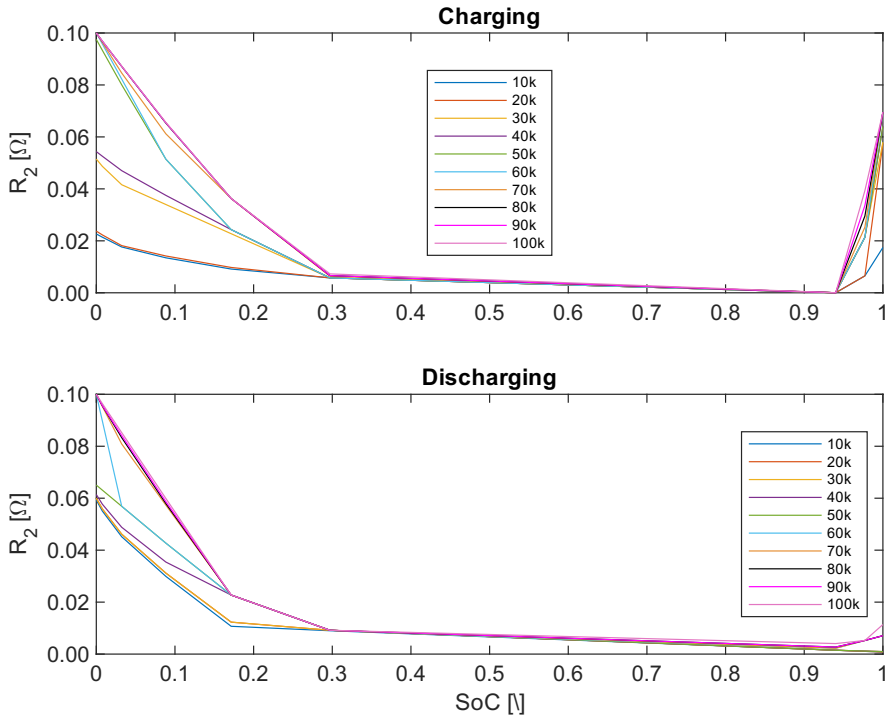

Slika 4.7: Prikaz otpora R_2 u ovisnosti o $SoC - u$

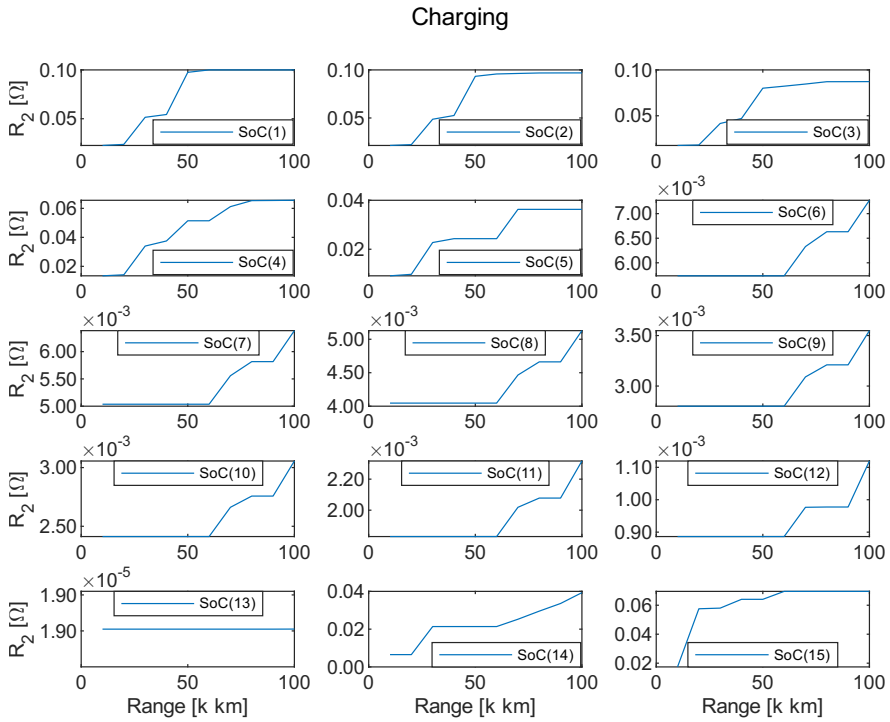

Slika 4.8: Promjena otpora R_2 za sve vrijednosti SoC-a tijekom punjenja

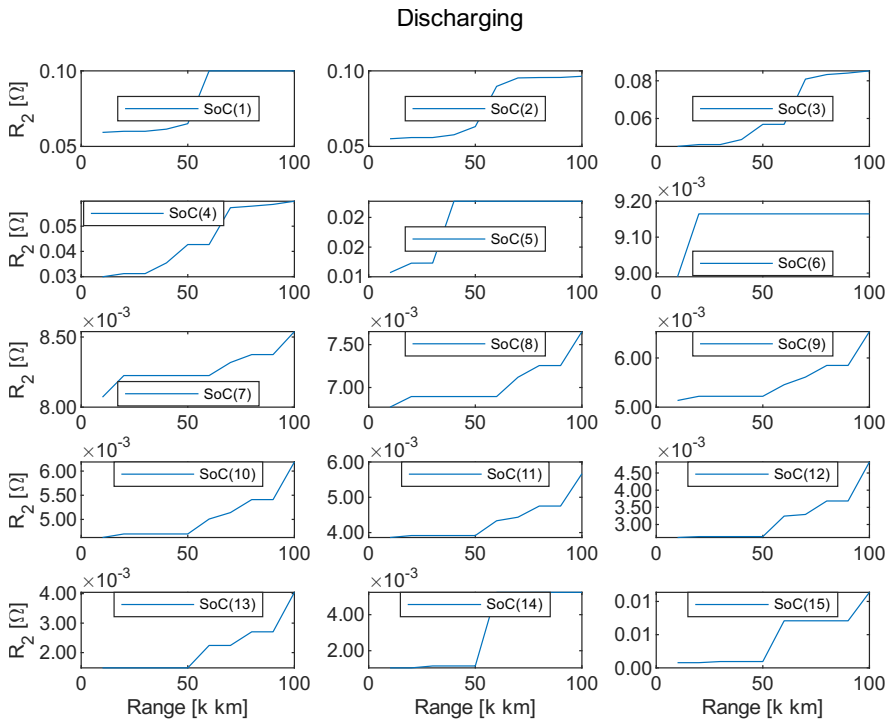

Slika 4.9: Promjena otpora R_2 za sve vrijednosti SoC-a tijekom pražnjenja

Vremenske konstante T_1 i T_2 ne mijenjaju se povećanjem prijeđenih kilometara automobila jer su njihove vrijednosti fiksirane na vrijednosti iz prve optimizacije

što je vidljivo na grafovima 4.10 i 4.11. Također, vremenska konstanta T_1 je dvaput veća od T_2 na svim vrijednostima SoC-a.

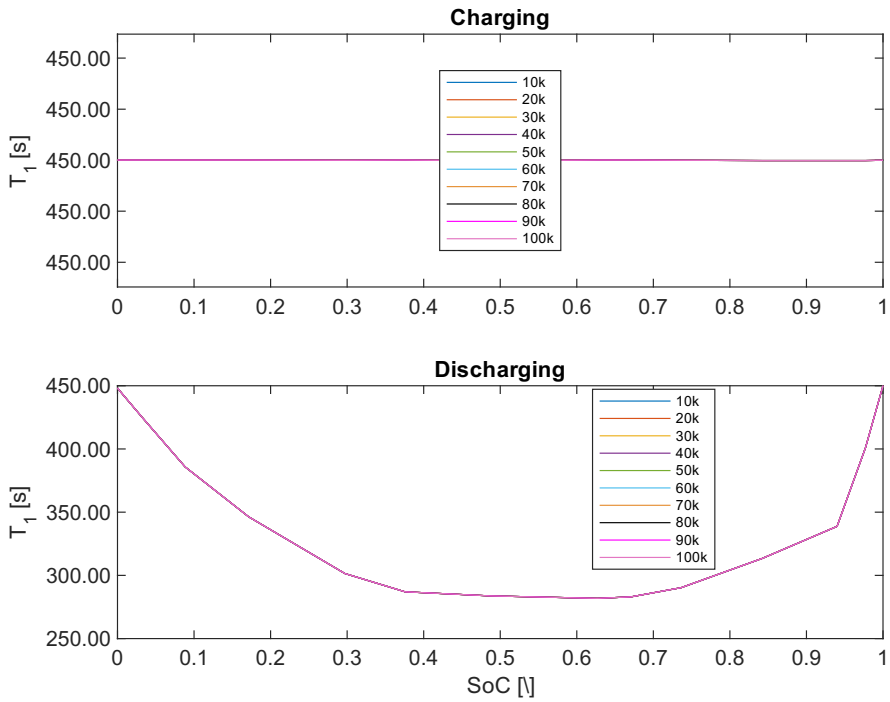

Slika 4.10: Prikaz vremeneske konstante T_1 u ovisnosti o $SoC - u$

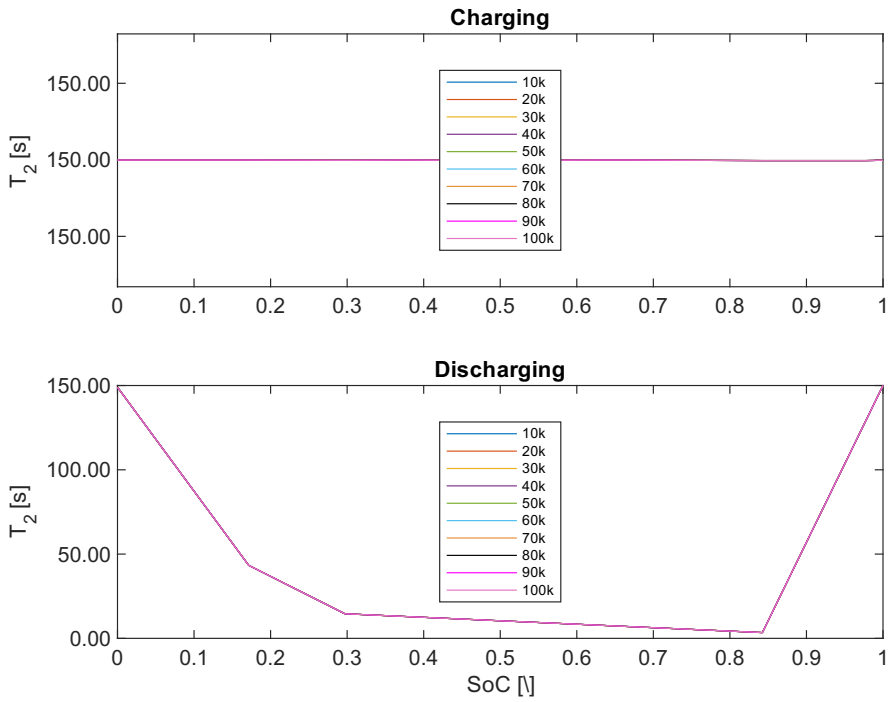

Slika 4.11: Prikaz vremeneske konstante T_2 u ovisnosti o $SoC - u$

Degradacija kapaciteta litij-ionskog članka s vremenom prikazana je grafom 4.12. Vrijednosti u početku, prvih 20 tisuća kilometara, sporije padaju, a kasnije se proces degradacije kapaciteta malo ubrzava. Promjena kapaciteta bi se kasnije trebala krenuti smanjivati, iako od 70 tisuća kilometara kreće stagnirati. Kada se nova baterija prvi put koristi, SEI sloj se formira i stabilizira tijekom vremena. Tijekom ove rane faze može doći do degradacije baterijskog članka. Međutim, nakon što SEI sloj dosegne stabilno stanje, smanjuje se daljnja reakcija između anode i elektrolita, što zauzvrat usporava stopu gubitka kapaciteta [11].

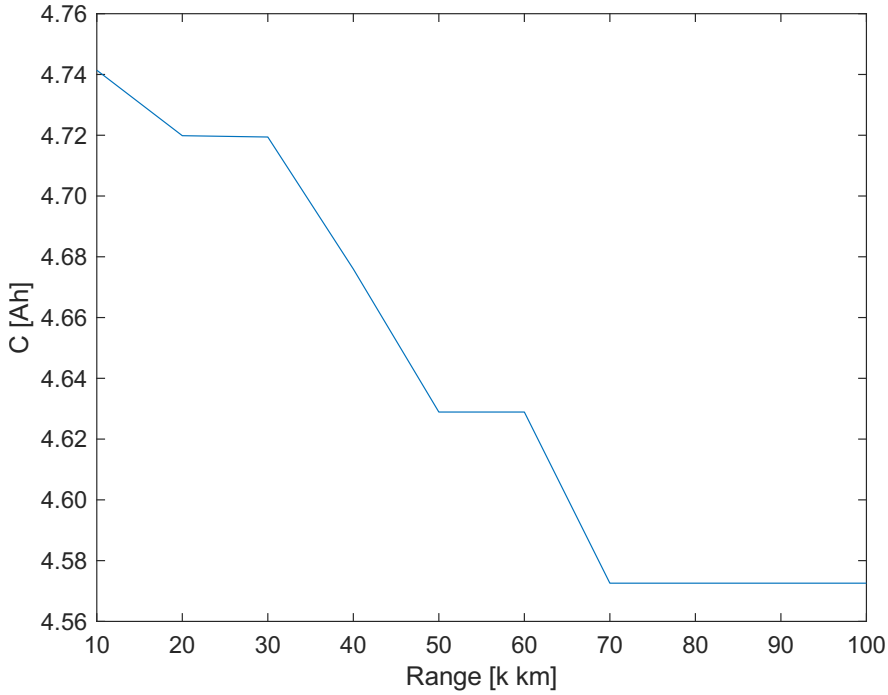

Slika 4.12: Smanjenje kapaciteta baterije

SEI sloj, iako je koristan, može uzrokovati početni gubitak kapaciteta zbog svog procesa formiranja, ali kada se stabilizira, baterija može zadržati svoj kapacitet dulje razdoblje [11].

Estimirana stanja napunjenosti koja se nalaze na slici 4.13 indiciraju da se članak pretežito puni i prazni u području SoC-a od 30% do 80%. Iz toga se može zaključiti da su parametri loše identificirani kada je vrijednost stanja napunjenosti manja od 40% jer ne postoji dovoljno podatka u tom području SoC-a.

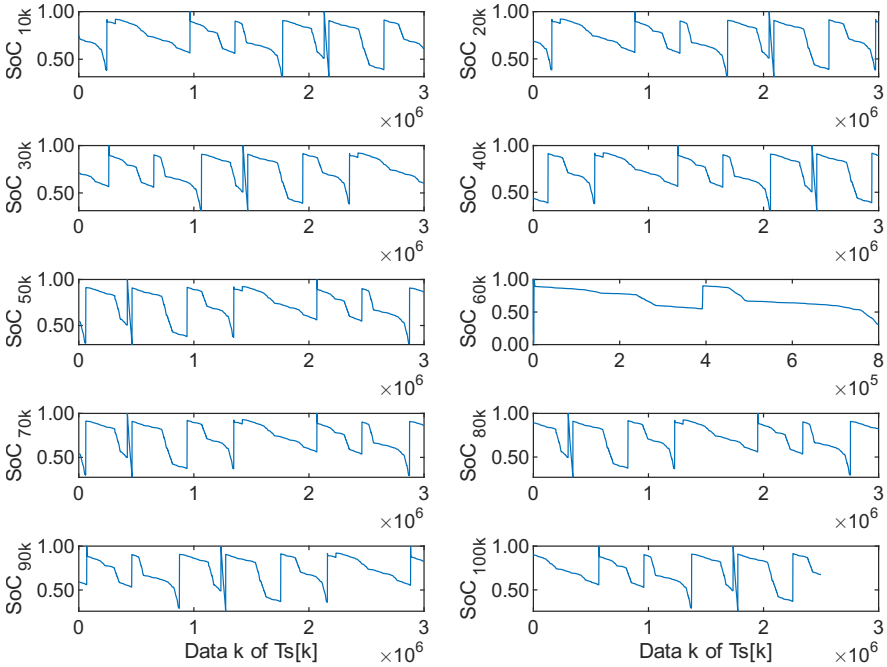

Slika 4.13: Aproksimirana stanja napunjenosti u ovisnosti o dometu

Estimirani naponi članka u ovisnosti o prijeđenim kilometrima prikazani su na slici 4.14. Vidljivo je da je napon lošije identificiran na skupu mjerenja od 50 do 60 tisuća kilometara. Razlog tome je vjerojatno manji broj dostupnih podataka ili/i pogreška tijekom mjerenja napona i struje baterijskog članka. Isto je vidljivo i na slici 4.13 na grafu stanja napunjenosti za 60 tisuća kilometara gdje SoC postepeno pada, odnosno baterija se jako sporo prazni tijekom cijelog vremena.

Na slici 4.15 se nalazi uvećan prikaz optimiranih veličina u, u_1, u_2 i SoC-a. Estimirani napon $u_{estimated}$ dobro prati stvarni napon u. Praćenje je najbolje u područjima stabilnog stanja odnosno gdje nema većih oscilacija stvarnog napona i struje. Pogreška između procijenjenog i stvarnog napona $u - u_{estimated}$ je unutar raspona $\pm 0.02V$. Postoje povremena veća odstupanja, ali su kratkotrajna i brzo se vraćaju na nominalne vrijednosti. Procjena stanja napunjenosti pokazuje kontinuirano opadanje bez skokova u vrijednostima. Vidljivo je kako napon u_1 prikazuje sporije procese difuzije jer je krivulja glatka, a krivulja napona u_2 više oscilatorna što opisuje brže procese difuzije. Napon u_2 se može brže ustabiliti nakon brze promjene vrijednosti struje, dok naponu u_1 treba više vremena da se ustabili jer je vremenska konstanta T_1 veća.

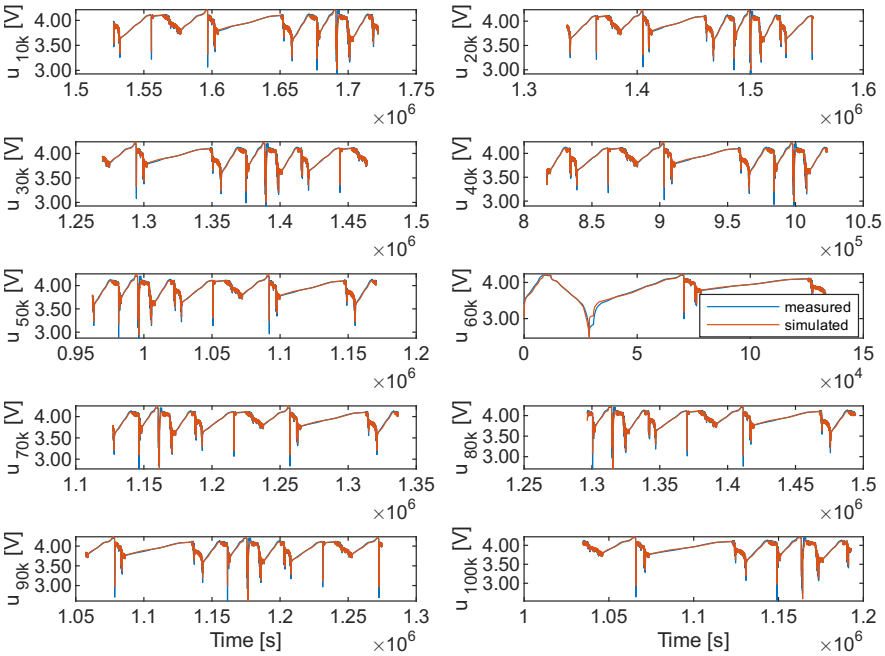

Slika 4.14: Usporedba mjerenog i estimiranog napona

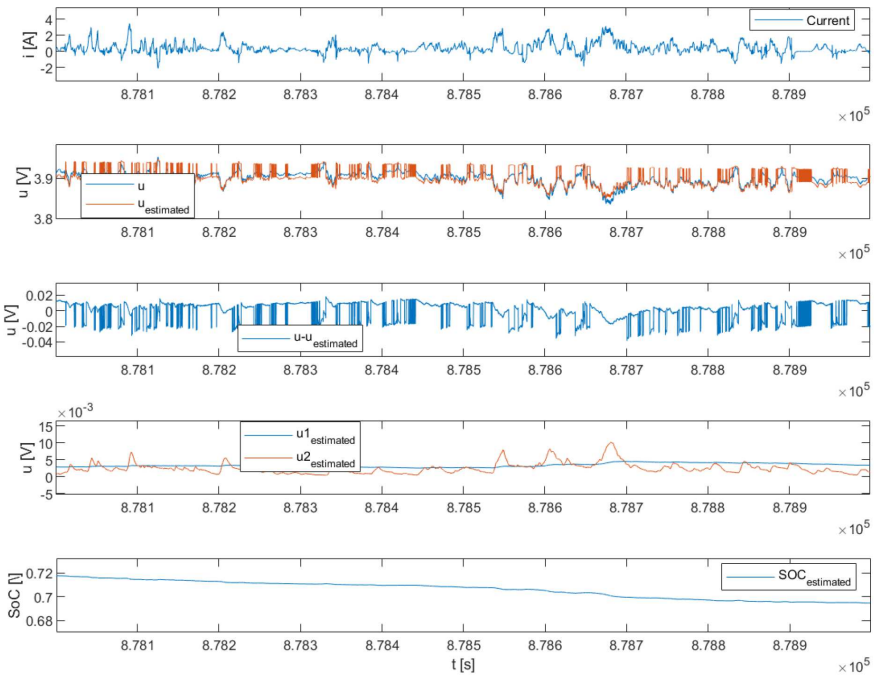

Slika 4.15: Uvećan prikaz optimiziranih veličina

Izračunate su tri različite metrike za evaluaciju pogrešaka identifikacije parametara modela. Na slici 4.15 vidljivo je da nisu velike pogreške identifikacije i da pogreške imaju slabi trend rasta s vremenom.

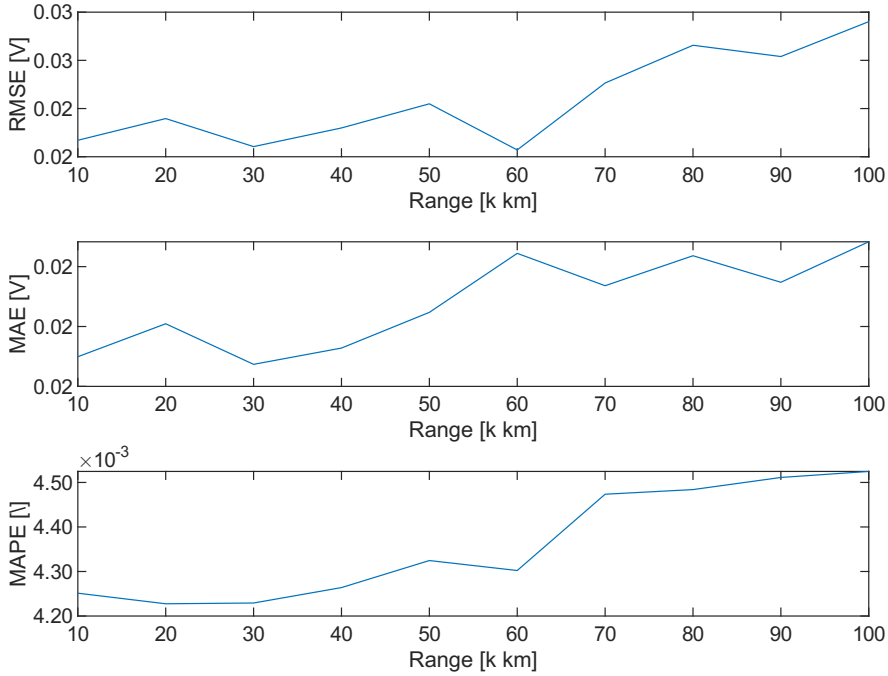

Slika 4.16: Pogreške identifikacije parametara modela

4.2. Rezultati pojednostavnjenja otpora

Odabrane su tri različite funkcije za aproksimaciju otpora $R \in \{R_0, R_1, R_2\}$, zasebno za punjenje i pražnjenje baterijskog članka. Aproksimacija krivulje otpora se dobije estimacijom vektora parametara μ za područje stanja napunjenosti $SoC \in [0.3, 0.8]$ jer izvan tog područja nema puno mjerenja:

1. $\hat{R} = R_{base} \cdot \mu_1$
2. $\hat{R} = R_{base} \cdot \mu_1 + R_{base}^2 \cdot \mu_2$
3. $\hat{R} = R_{base} \cdot \mu_1 + R_{base}^2 \cdot \mu_2 + R_{base}^3 \cdot \mu_3$

Srednje vrijednosti pogrešaka aproksimacije otpora R_0, R_1, R_2 ovisno o korištenoj funkciji se nalaze u tablicama 4.1, 4.2 i 4.3. S obzirom na broj parametara i iznos pogrešaka, najbolji je odabir funkcija polinoma prvog stupnja odnosno prva po redu funkcija. Estimacija krivulje polinomom prvog stupnja i njihove pogreške za sve otpore nalaze se na slikama 4.17 - 4.31. Pod pretpostavkom da vremenske konstante T_1 i T_2 fiksiramo jer se ne mijenjaju puno kroz vrijeme, slijedi da se starenje litij-ionskog članka može opisati sa sveukupno 7 parametara: promjenom kapaciteta C i tri parametra po otporima R_0, R_1 i R_2, odvojeno za punjenje i pražnjenje. Metodom najmanjih kvadrata, dobiveno je 144 parametara manje od

prvotno identificiranih parametara ECM članka.

Tablica 4.1: Pogreške aproksimacije unutarnjeg otpora R_0

f	charging			discharging		
	RMSE_{avg}	MAE_{avg}	MAPE_{avg}	RMSE_{avg}	MAE_{avg}	MAPE_{avg}
1.	7.50E-05	2.83E-05	1.00E-02	2.59E-04	9.80E-05	6.60E-03
2.	8.42E-05	3.18E-05	1.12E-02	2.68E-04	1.01E-04	6.80E-03
3.	8.42E-05	3.18E-05	1.12E-02	2.68E-04	1.01E-04	6.80E-03

Tablica 4.2: Pogreške aproksimacije otpora R_1

f	charging			discharging		
	RMSE_{avg}	MAE_{avg}	MAPE_{avg}	RMSE_{avg}	MAE_{avg}	MAPE_{avg}
1.	8.44E-04	3.19E-04	7.16E-01	1.16E-04	4.40E-05	6.60E-03
2.	8.46E-04	3.20E-04	7.17E-01	1.16E-04	4.40E-05	6.60E-03
3.	8.35E-04	3.16E-04	7.08E-01	1.16E-04	4.39E-05	6.60E-03

Tablica 4.3: Pogreške aproksimacije otpora R_2

f	charging			discharging		
	RMSE_{avg}	MAE_{avg}	MAPE_{avg}	RMSE_{avg}	MAE_{avg}	MAPE_{avg}
1.	2.26E-05	8.55E-06	9.60E-03	4.69E-05	1.77E-05	6.80E-03
2.	2.26E-05	8.56E-06	9.70E-03	1.34E-04	5.07E-05	1.93E-02
3.	2.26E-05	8.56E-06	9.70E-03	1.34E-04	5.07E-05	1.93E-02

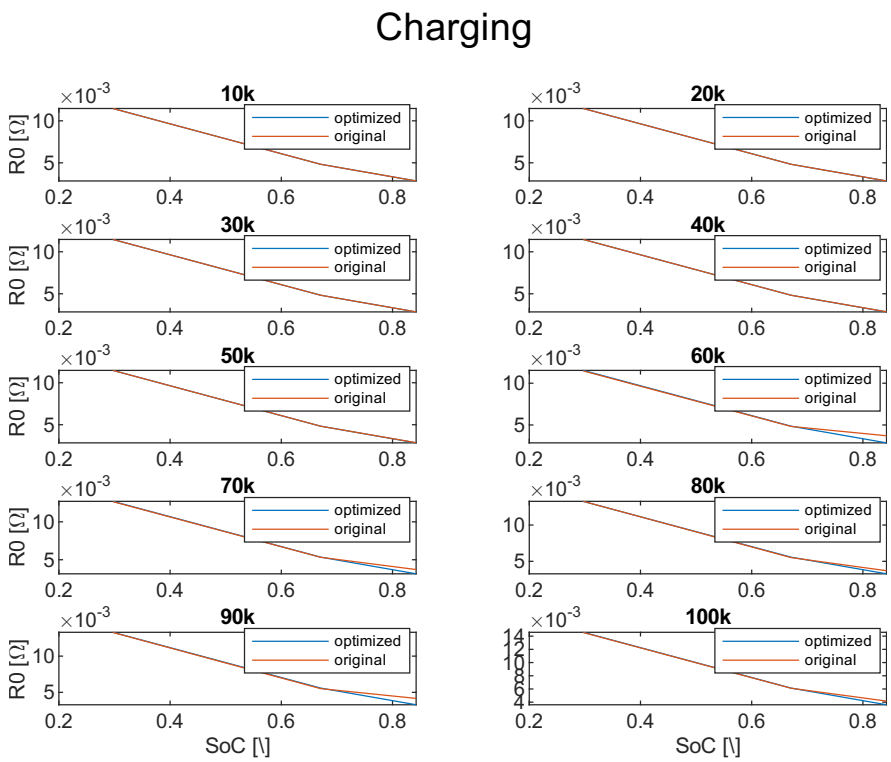

Slika 4.17: Aproksimacija krivulje unutarnjeg otpora za punjenje

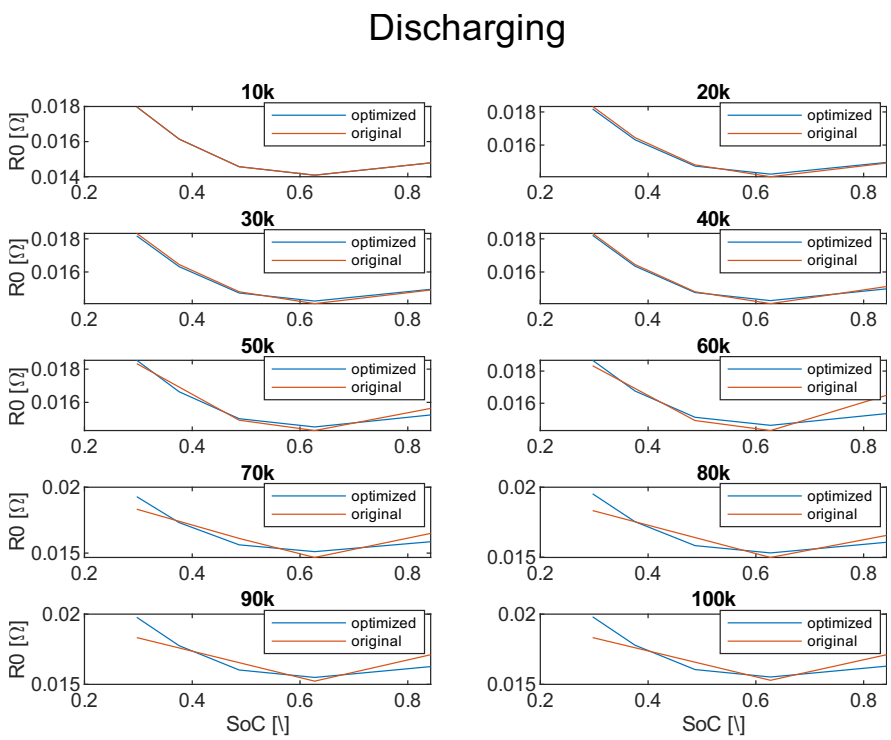

Slika 4.18: Aproksimacija krivulje unutarnjeg otpora za pražnjenje

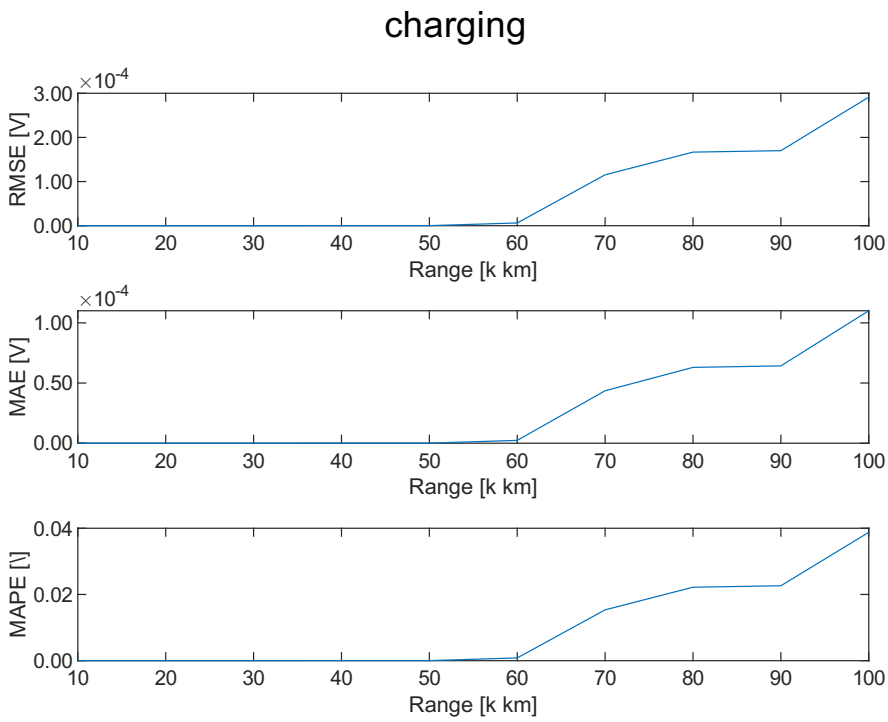

Slika 4.19: Pogreška aproksimacije krivulje otpora R_0 za punjenje

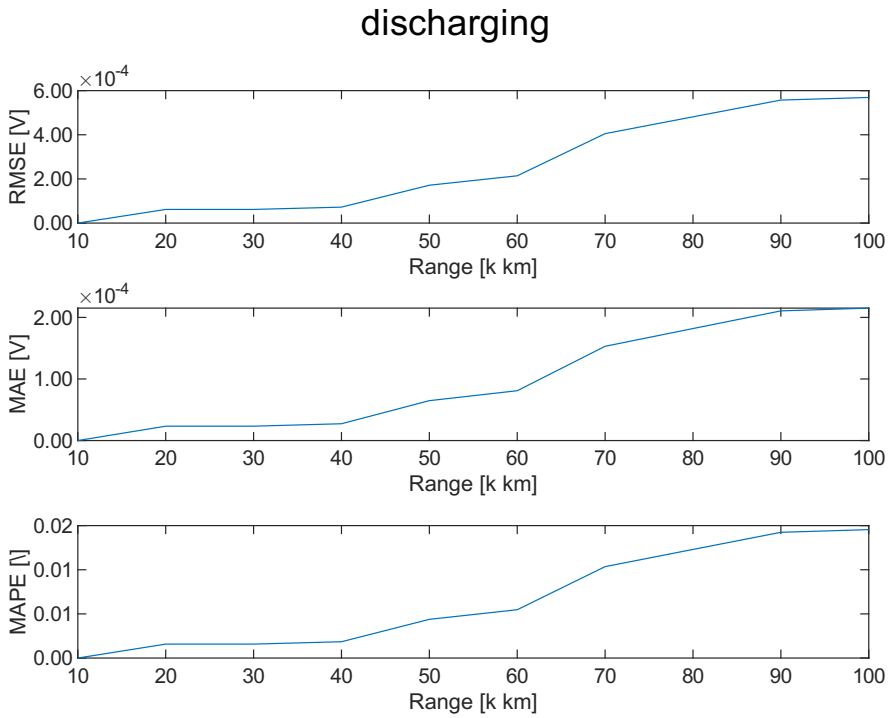

Slika 4.20: Pogreška aproksimacije krivulje otpora R_0 za pražnjenje

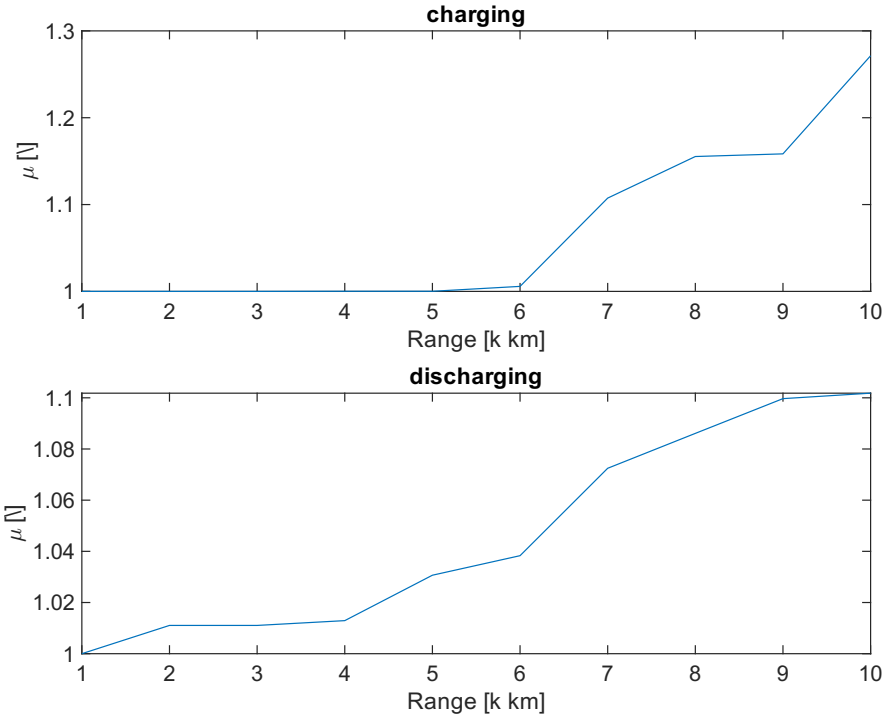

Slika 4.21: Vrijednosti parametra μ za otpor R_0

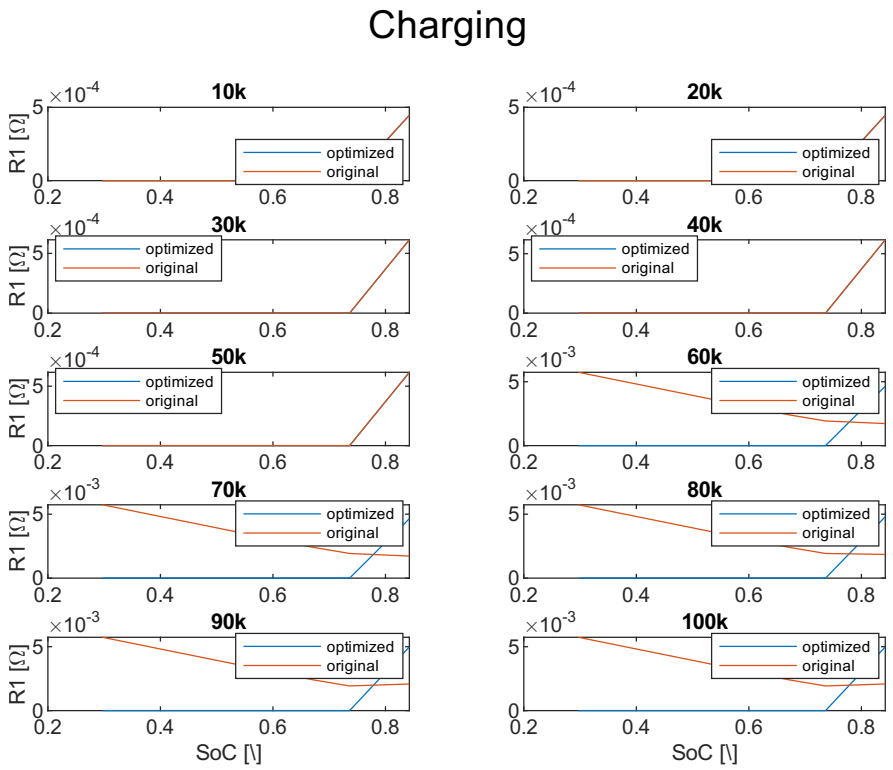

Slika 4.22: Aproksimacija krivulje otpora R_1 za punjenje

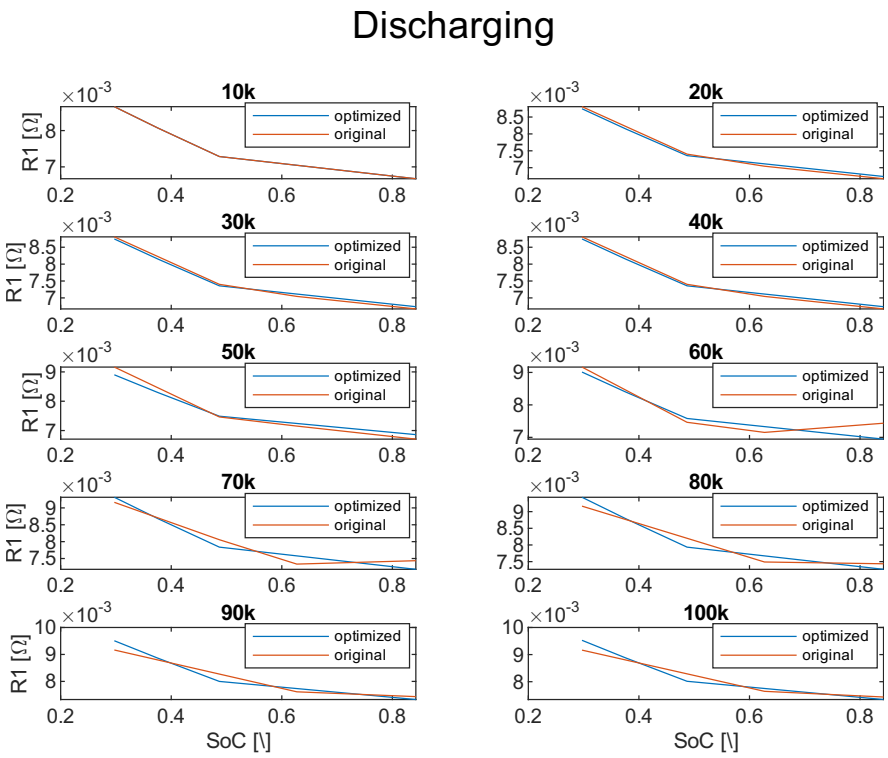

Slika 4.23: Aproksimacija krivulje otpora R_1 za pražnjenje

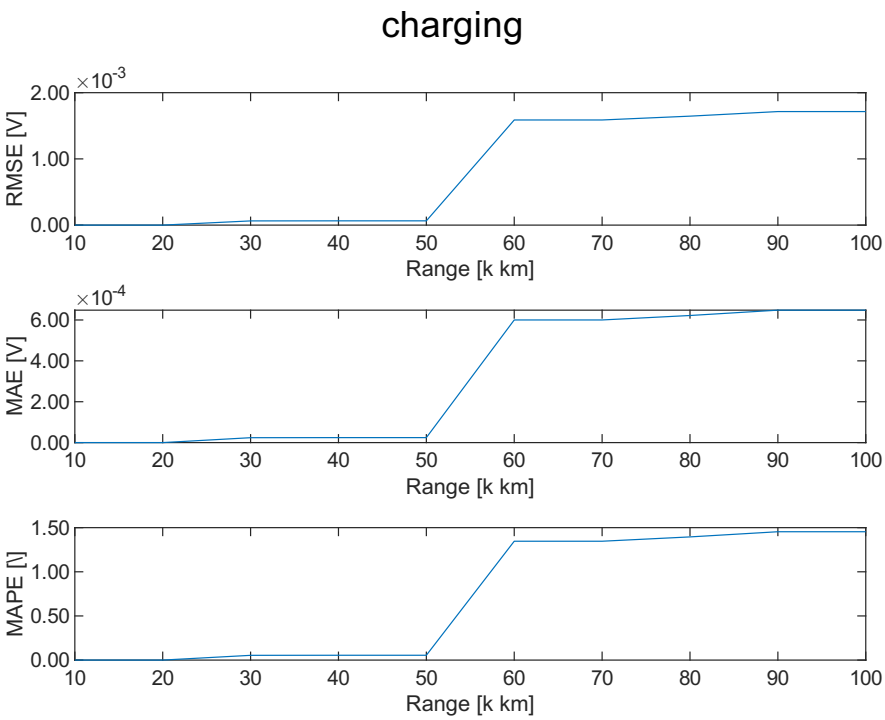

Slika 4.24: Pogreška aproksimacije krivulje otpora R_1 za punjenje

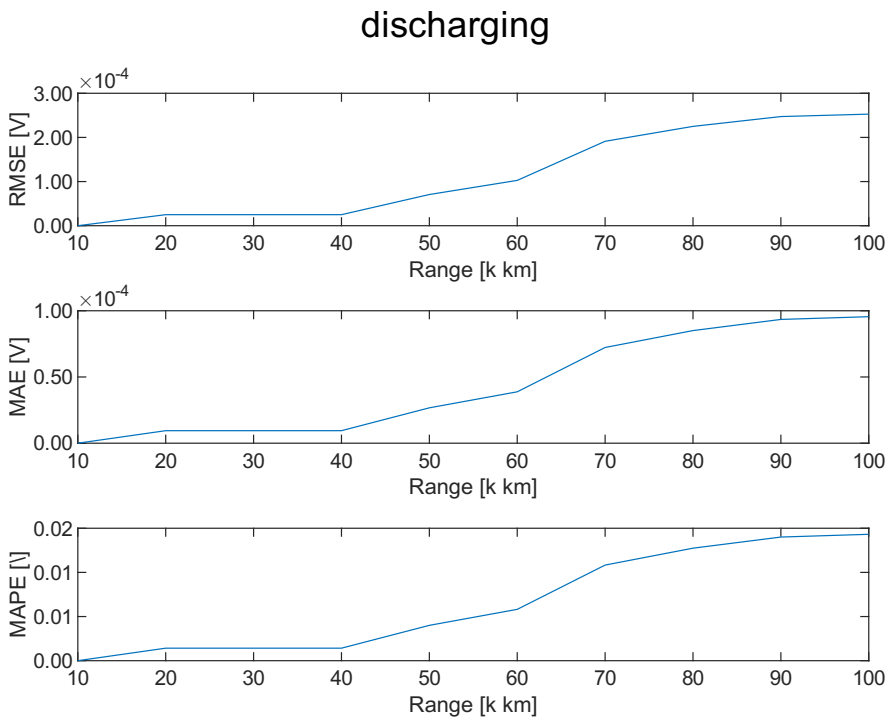

Slika 4.25: Pogreška aproksimacije krivulje otpora R_1 za pražnjenje

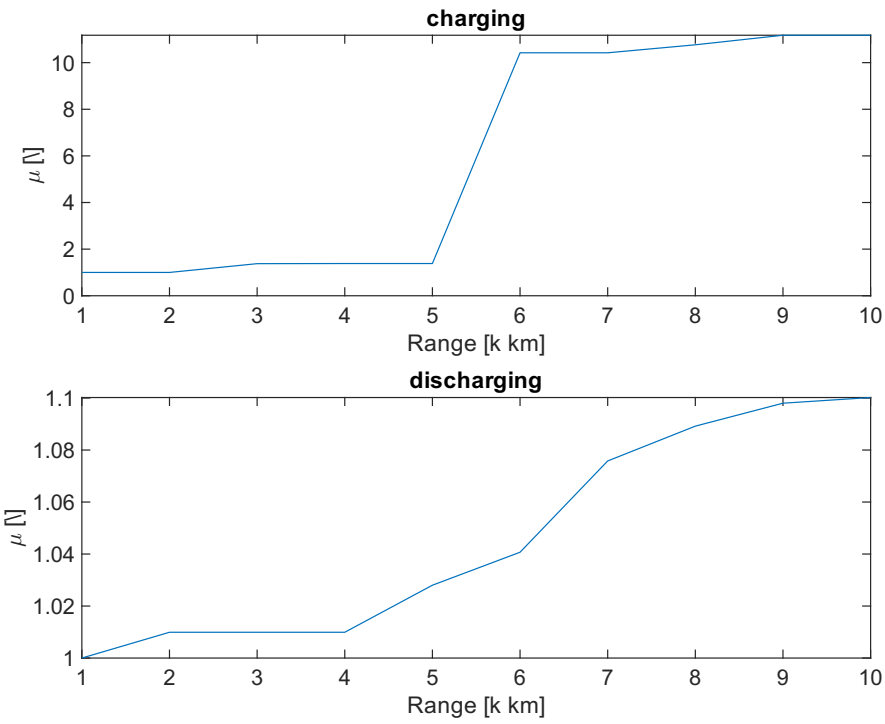

Slika 4.26: Vrijednosti parametra μ za otpor R_1

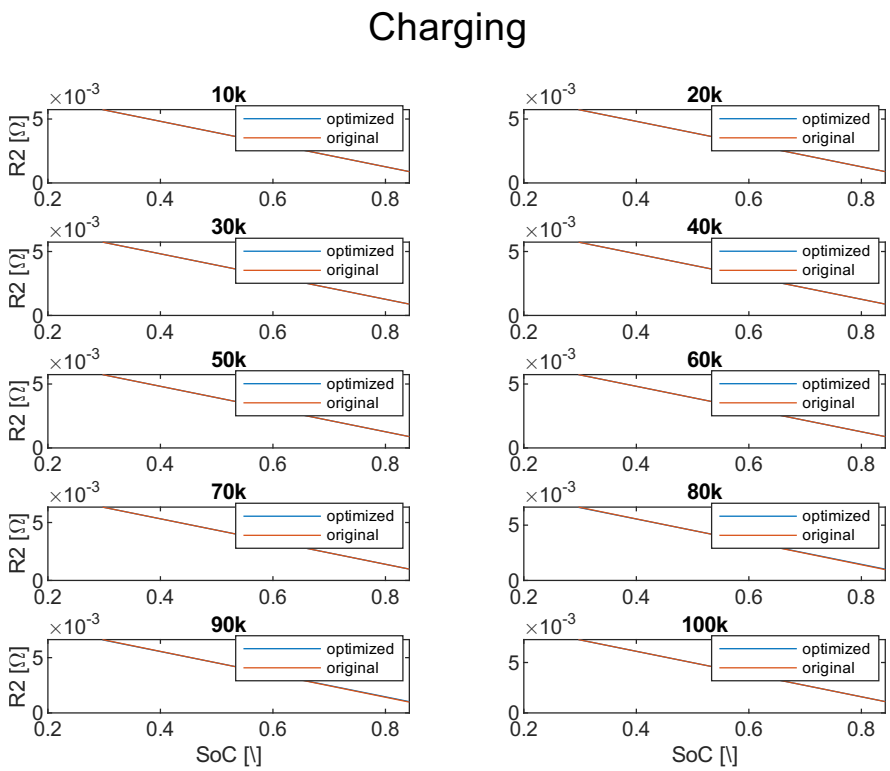

Slika 4.27: Aproksimacija krivulje otpora R_2 za punjenje

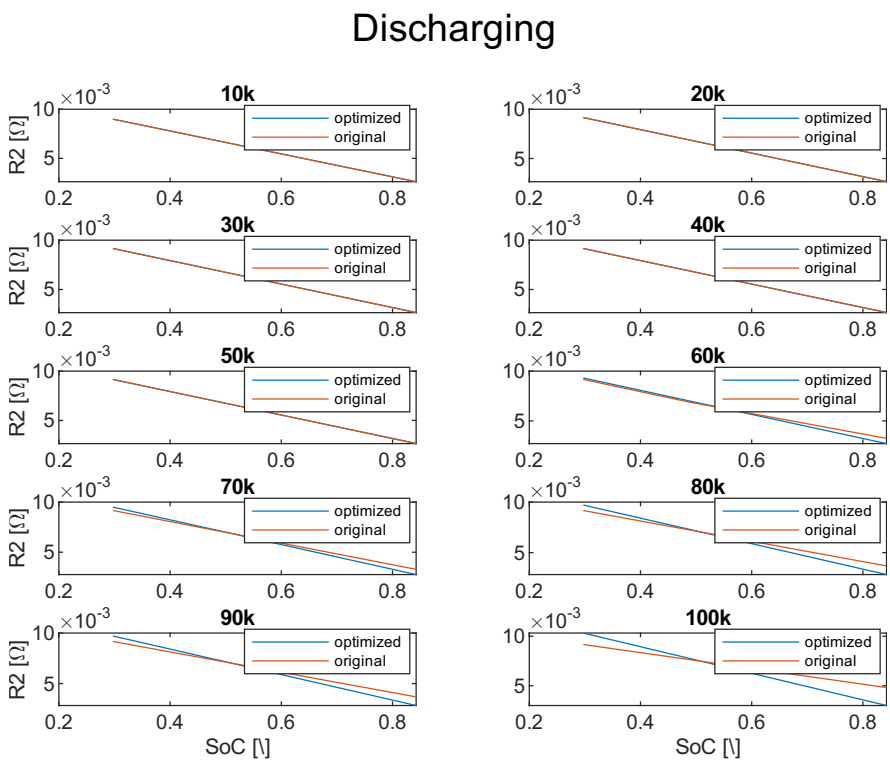

Slika 4.28: Aproksimacija krivulje otpora R_2 za pražnjenje

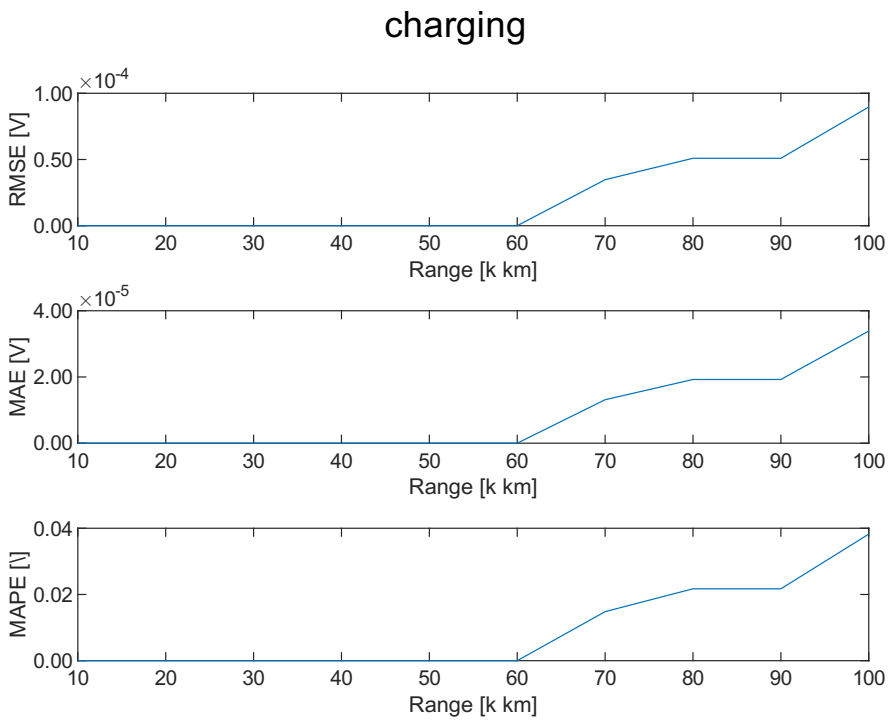

Slika 4.29: Pogreška aproksimacije krivulje otpora R_2 za punjenje

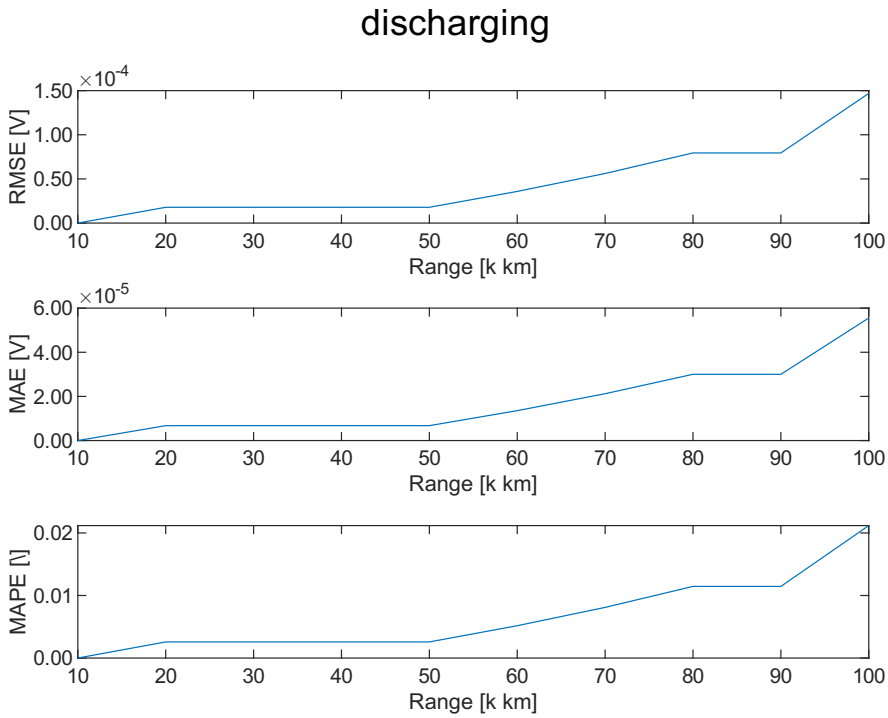

Slika 4.30: Pogreška aproksimacije krivulje otpora R_2 za pražnjenje

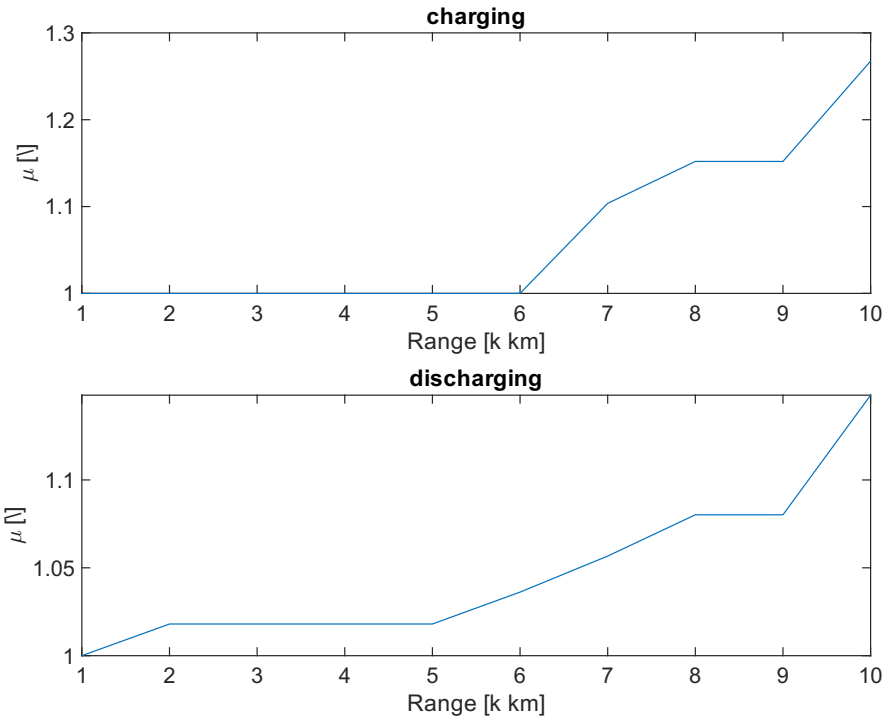

Slika 4.31: Vrijednosti parametra μ za otpor R_2

4.3. Rezultati identifikacije pojednostavljenih parametara

Nakon što je određena optimalna funkcija za aproksimaciju otpora, ponovno se identificira model s reduciranim vektorom parametara starenja. Optimizacija je izvršena na istom skupu mjerenja kao u poglavlju 4.1. Maknut je uvjet konveksnosti, a ostala ograničenja modela su ostala ista. Parametri starenja, otpori R_0, R_1, R_2 za punjenje i pražnjenje i kapacitet C, identificirani su na području SoC-a od 30% do 80%.

Vidljivo je da su parametri dobro aproksimirani. Doduše, rezultati nisu toliko slični u odnosu na prošlo poglavlje kad smo koristili metodu najmanjih kvadrata za aproksimaciju otpora. Krivulje otpora i kapaciteta te njihove greške aproksimacije nalaze se na grafovima od 4.32 do 4.47. Na grafu 4.37 vidljivo je da se krivulja referentnog otpora promijenila nakon 60 tisuća kilometara što je povećalo pogrešku estimacije parametra. Optimizirani otpori imaju isti oblik kao krivulje otpora iz detaljno naučenog modela za prvih 10 tisuća kilometara i zato nije moguće jednako dobro estimirati otpore nakon što se promijeni njena krivulja. Aproksimirana stanja napunjenosti, naponi, pogreške identifikacije i uvećan

prikaz indikatora zdravlja modela su prikazani na slikama od 4.48 do 4.51. Vidljivo je da su vrijednosti pogrešaka identifikacije modela slične onima iz detaljno naučenog modela s nereduciranim vektorom parametara.

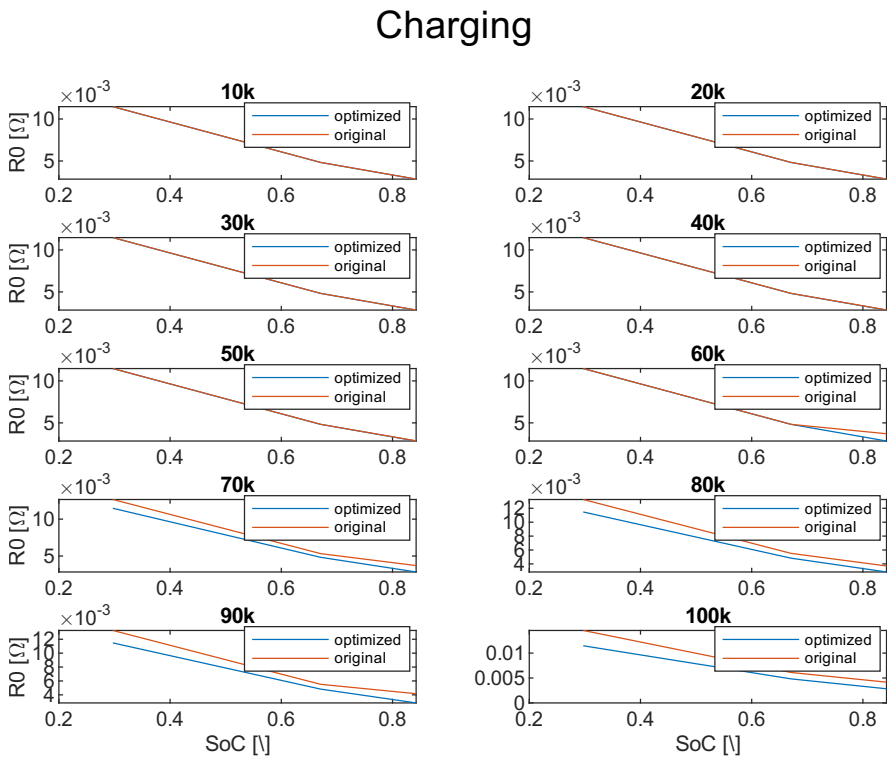

Slika 4.32: Aproksimirani otpor R_0 tijekom punjenja

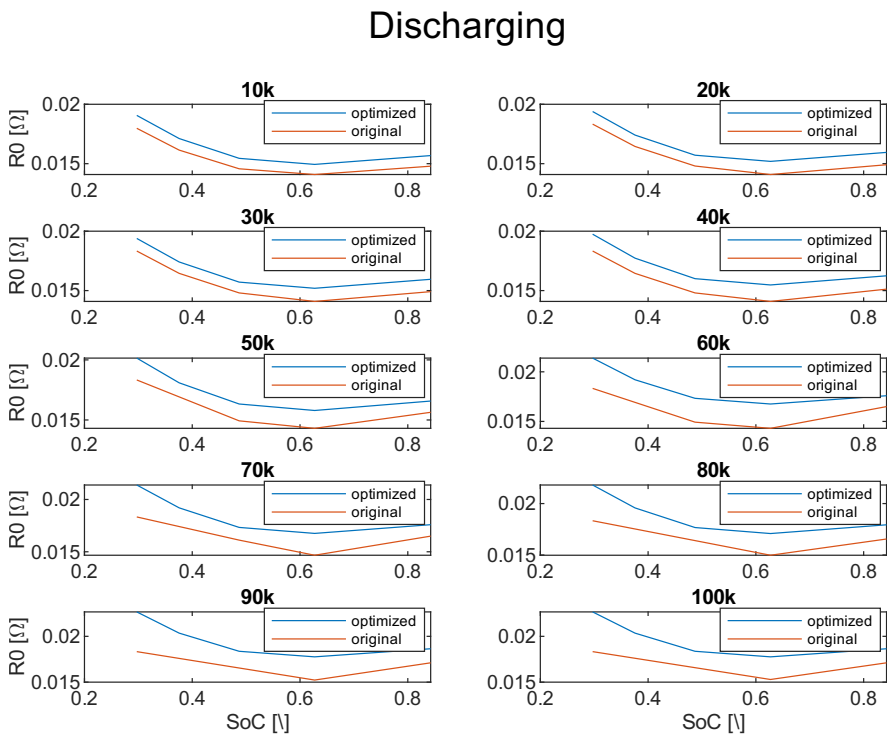

Slika 4.33: Aproksimirani otpor R_0 tijekom pražnjenja

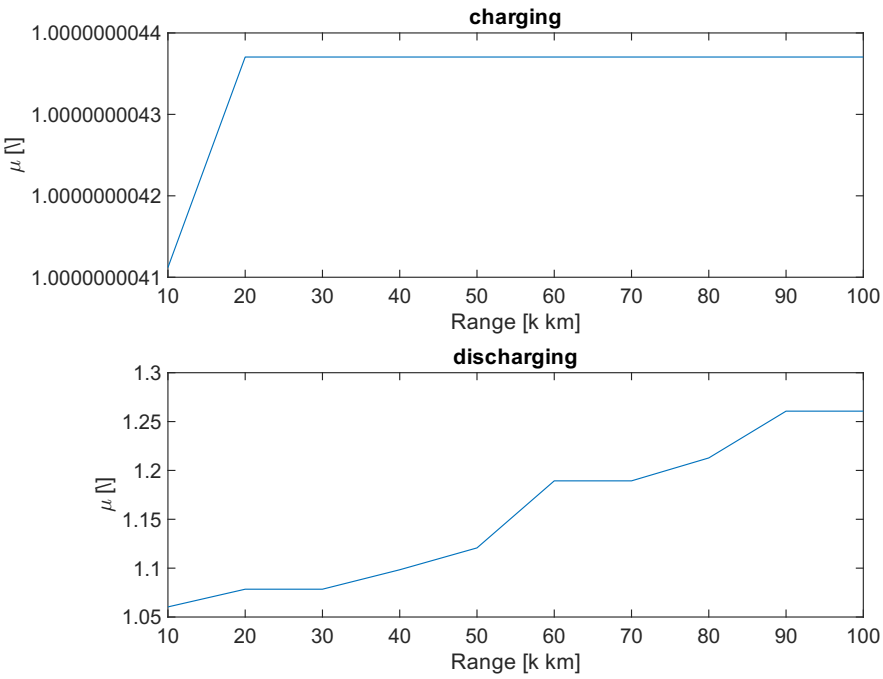

Slika 4.34: Vrijednosti parametara μ za otpor R_0

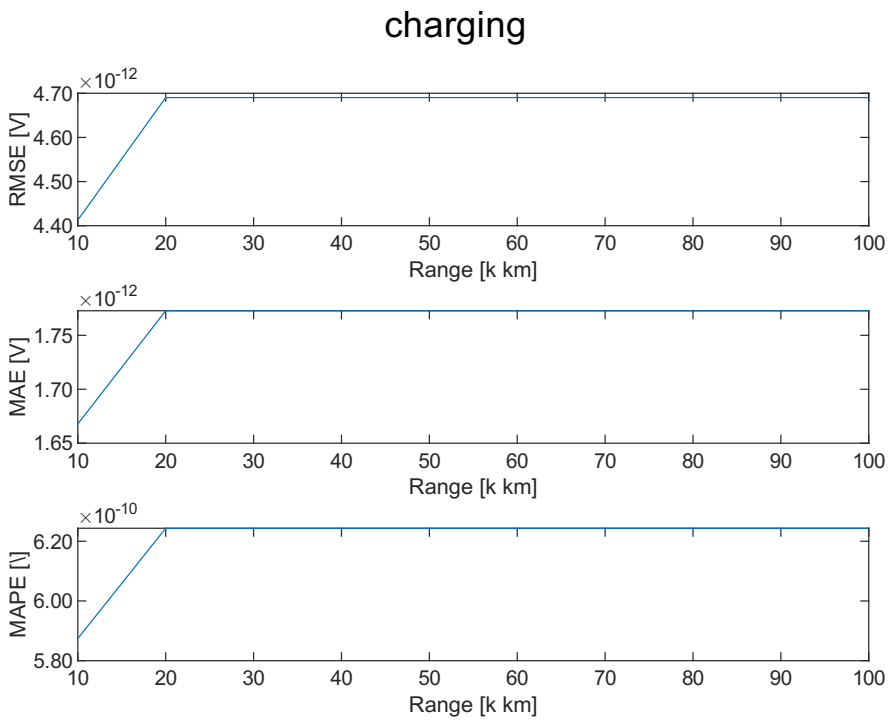

Slika 4.35: Pogreške aproksimacije otpora R_0 tijekom punjenja

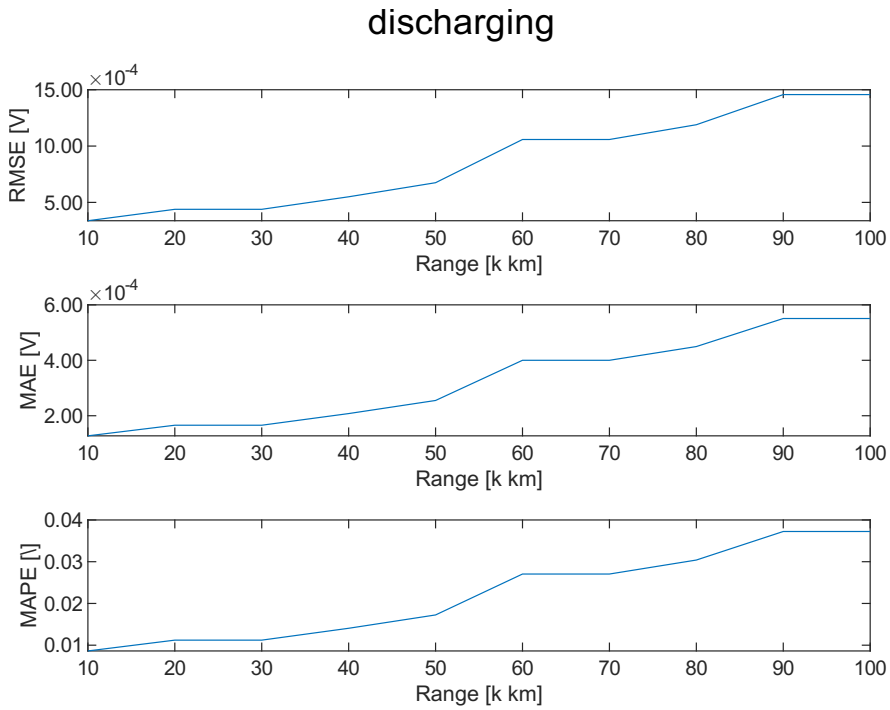

Slika 4.36: Pogreške aproksimacije otpora R_0 tijekom pražnjenja

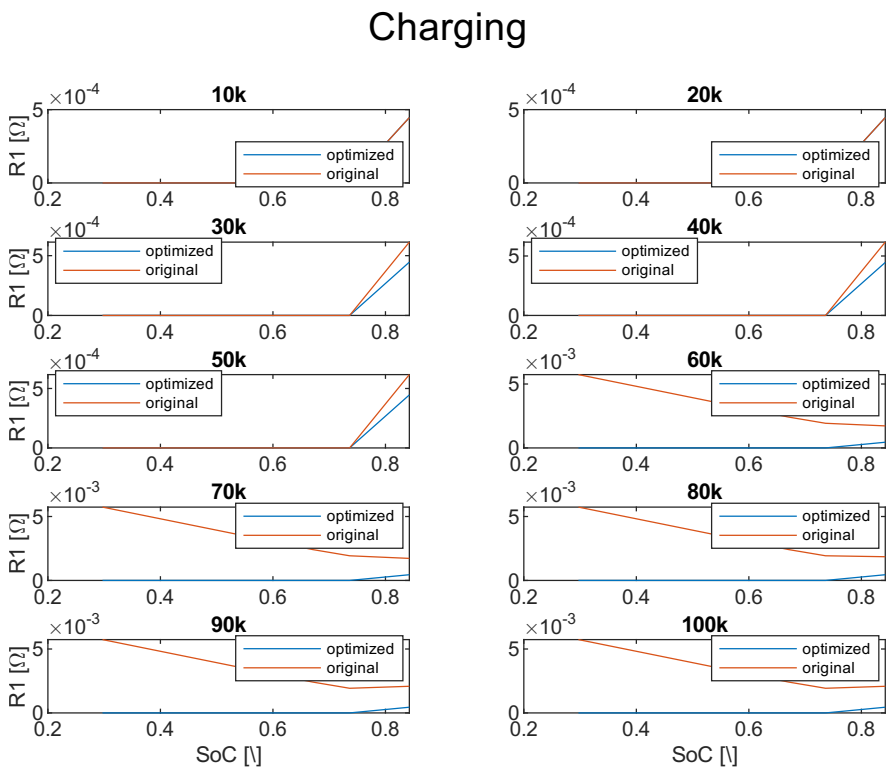

Slika 4.37: Aproksimirani otpor R_1 tijekom punjenja

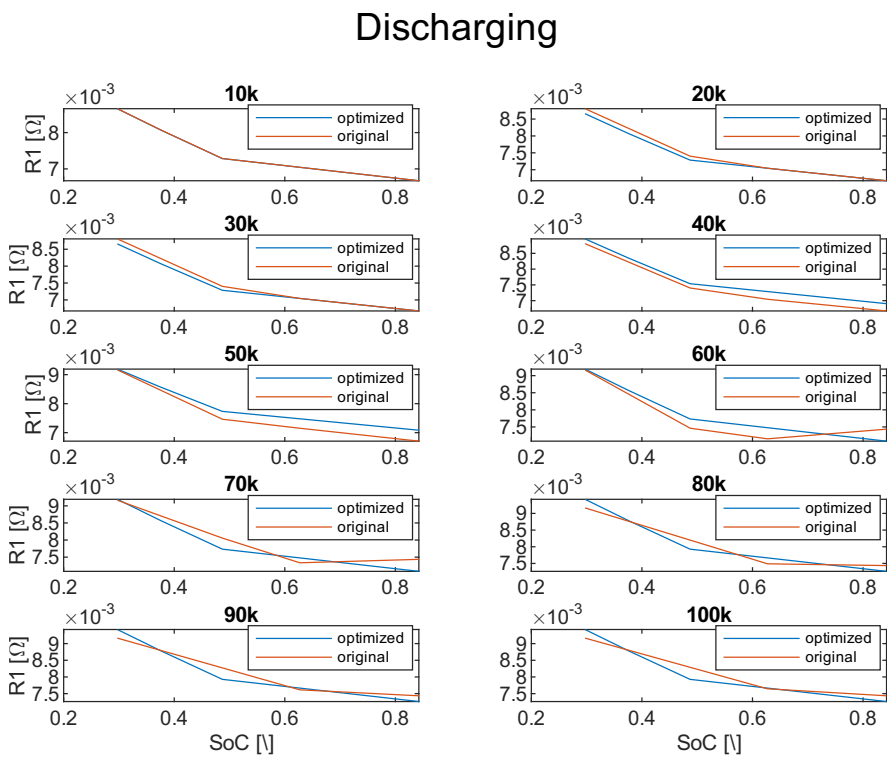

Slika 4.38: Aproksimirani otpor R_1 tijekom pražnjenja

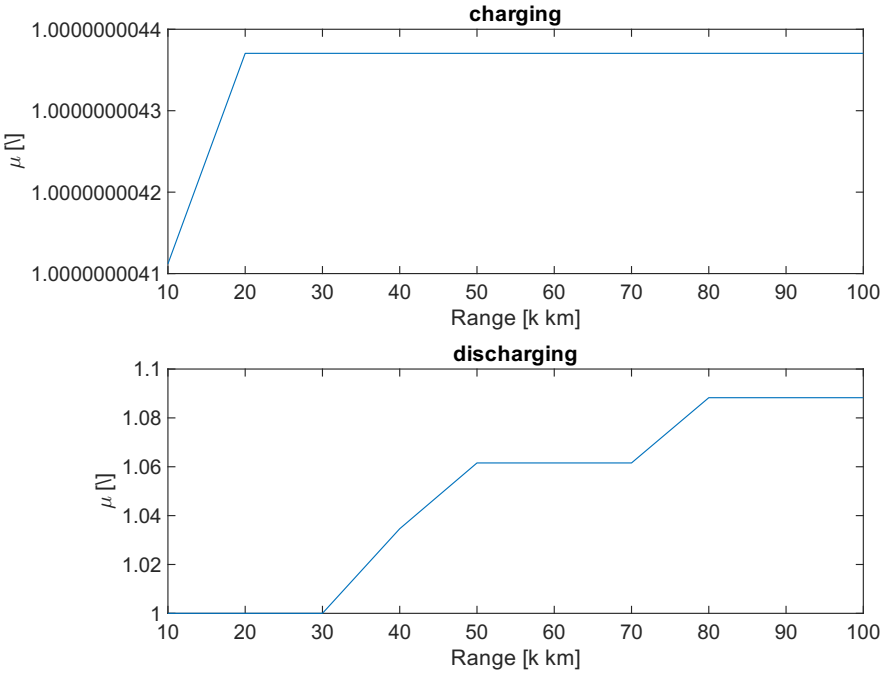

Slika 4.39: Vrijednosti parametara μ za otpor R_1

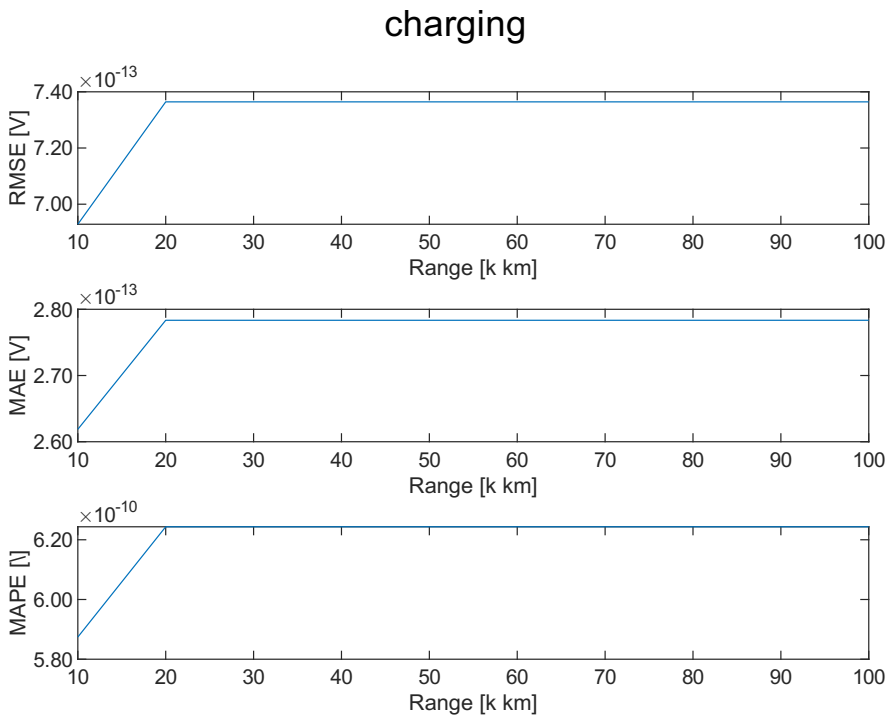

Slika 4.40: Pogreške aproksimacije otpora R_1 tijekom punjenja

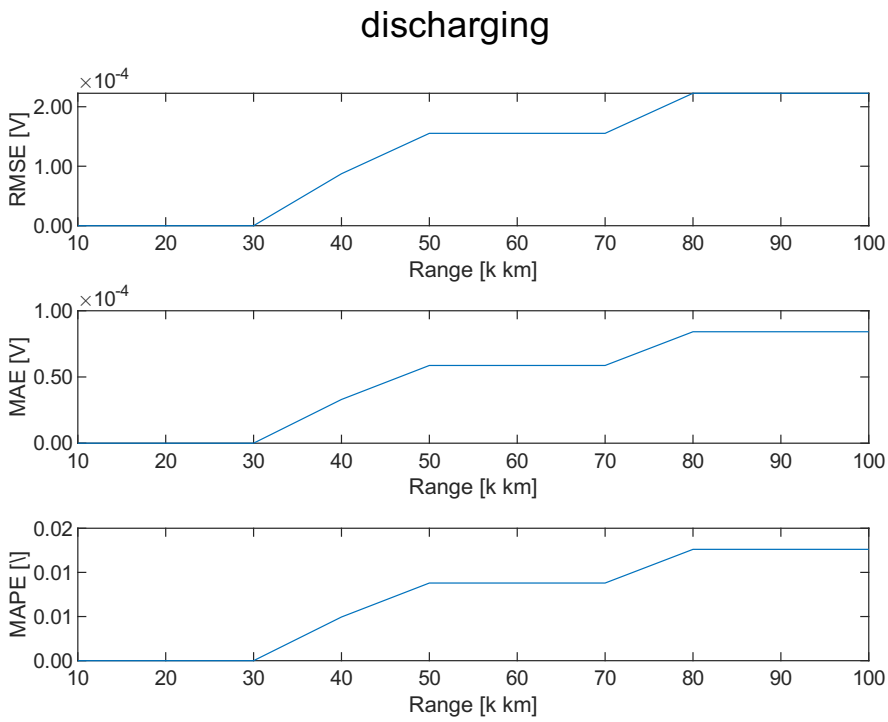

Slika 4.41: Pogreške aproksimacije otpora R_1 tijekom pražnjenja

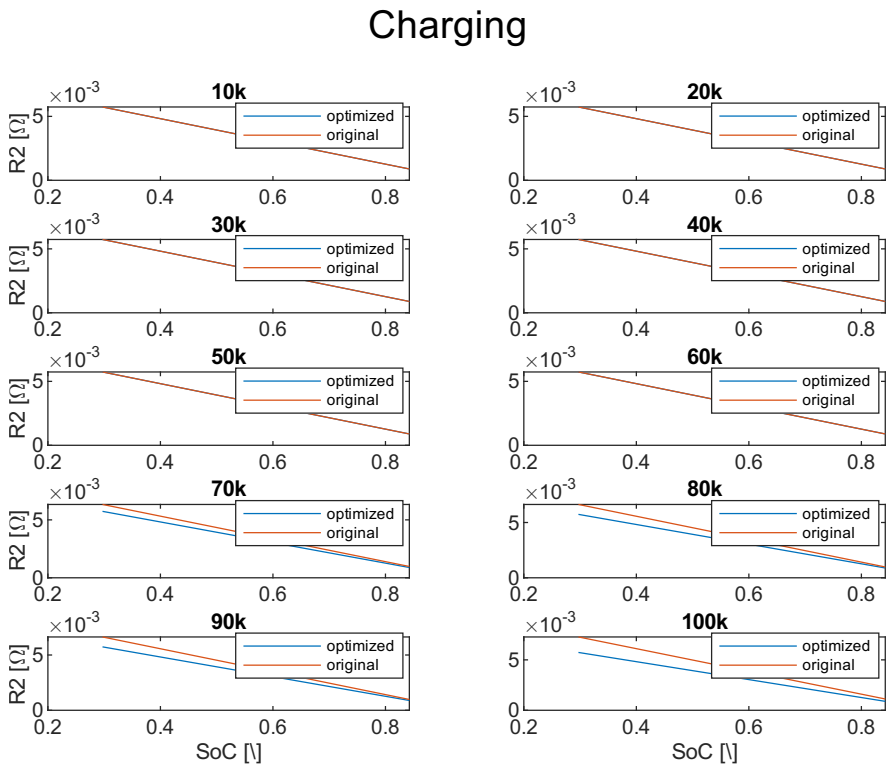

Slika 4.42: Aproksimirani otpor R_2 tijekom punjenja

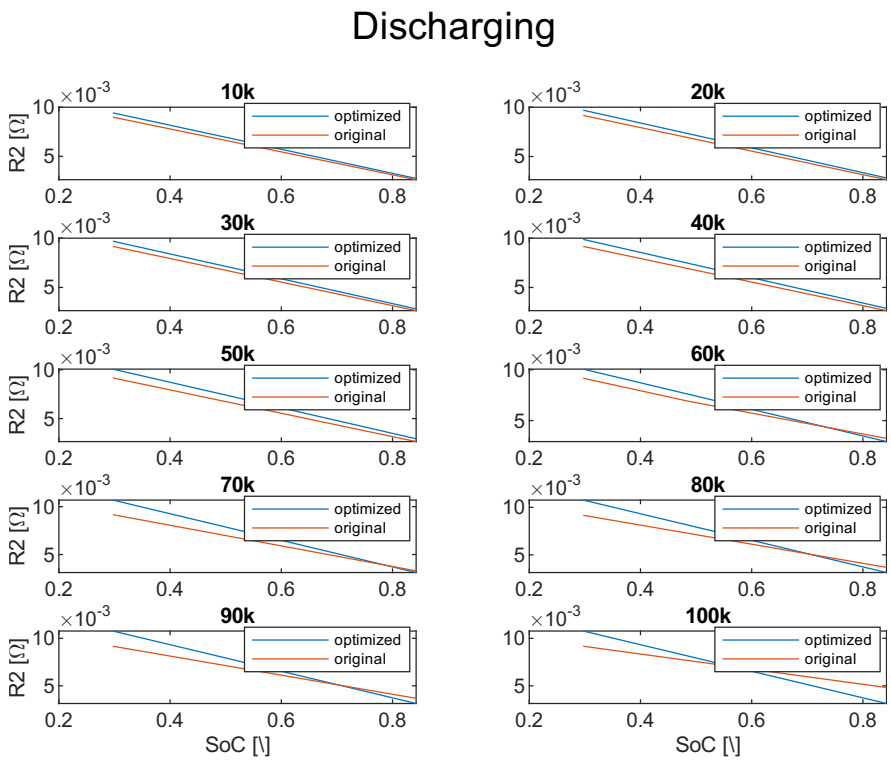

Slika 4.43: Aproksimirani otpor R_2 tijekom pražnjenja

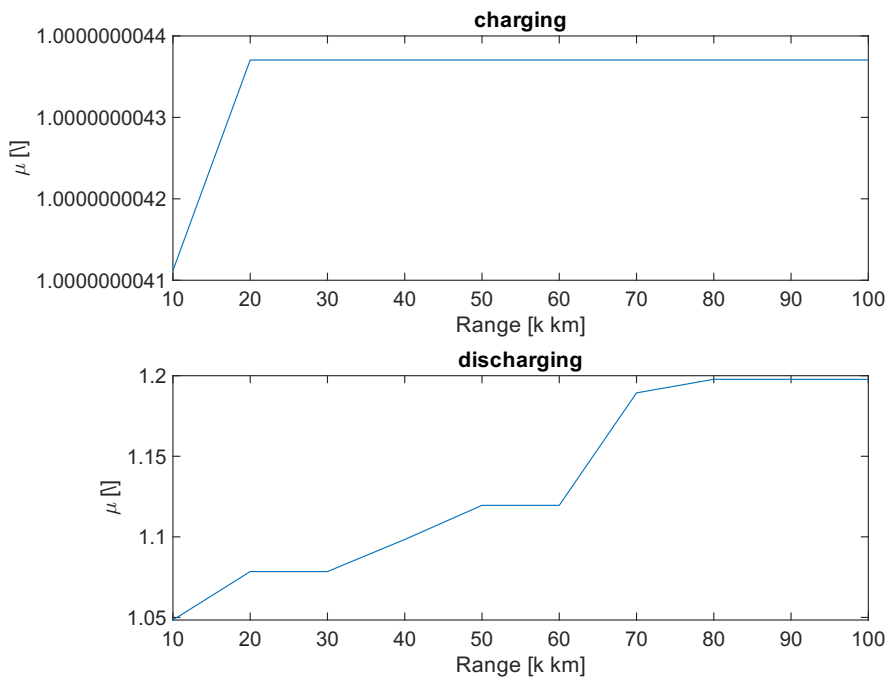

Slika 4.44: Vrijednosti parametara μ za otpor R_2

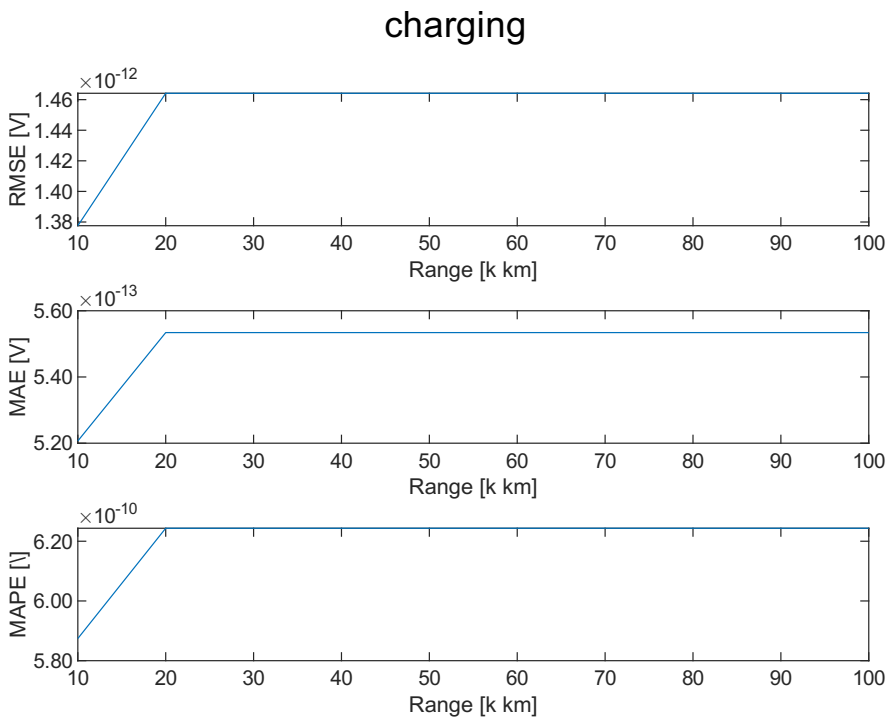

Slika 4.45: Pogreške aproksimacije otpora R_2 tijekom punjenja

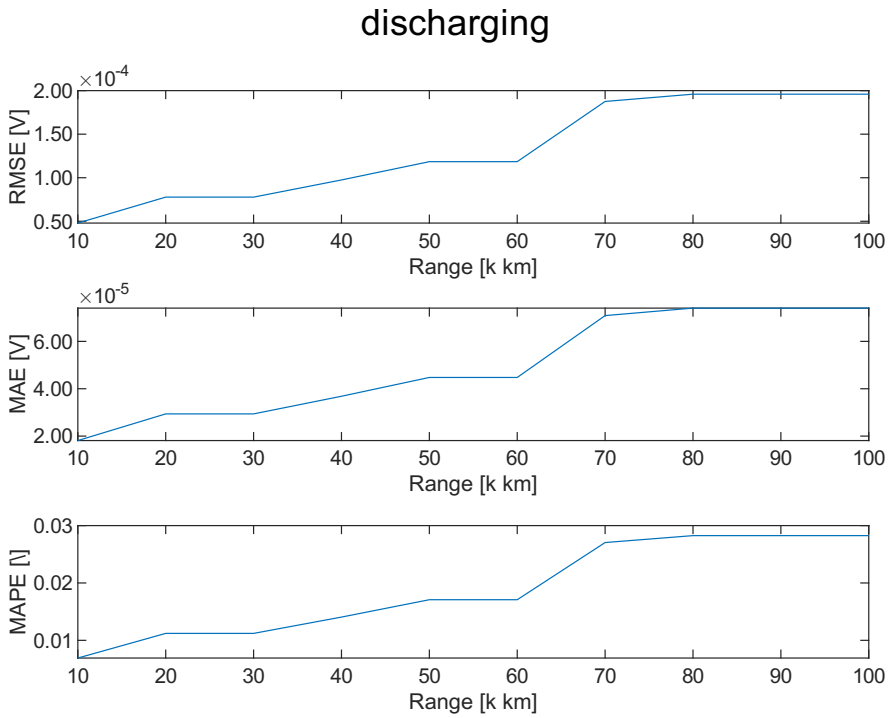

Slika 4.46: Pogreške aproksimacije otpora R_2 tijekom pražnjenja

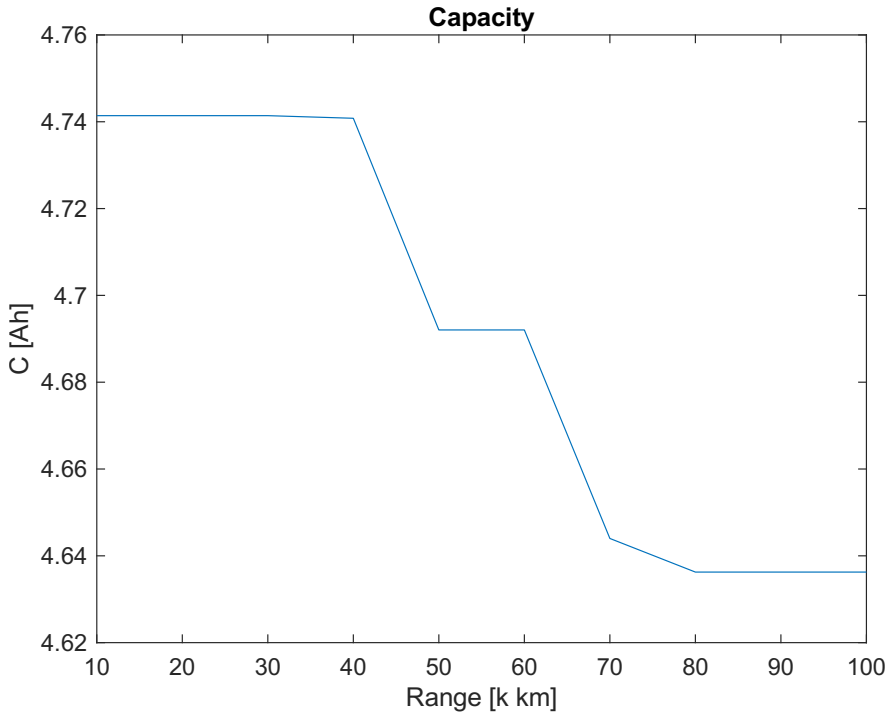

Slika 4.47: Smanjenje kapacita u ovisnosti o prijeđenom putu

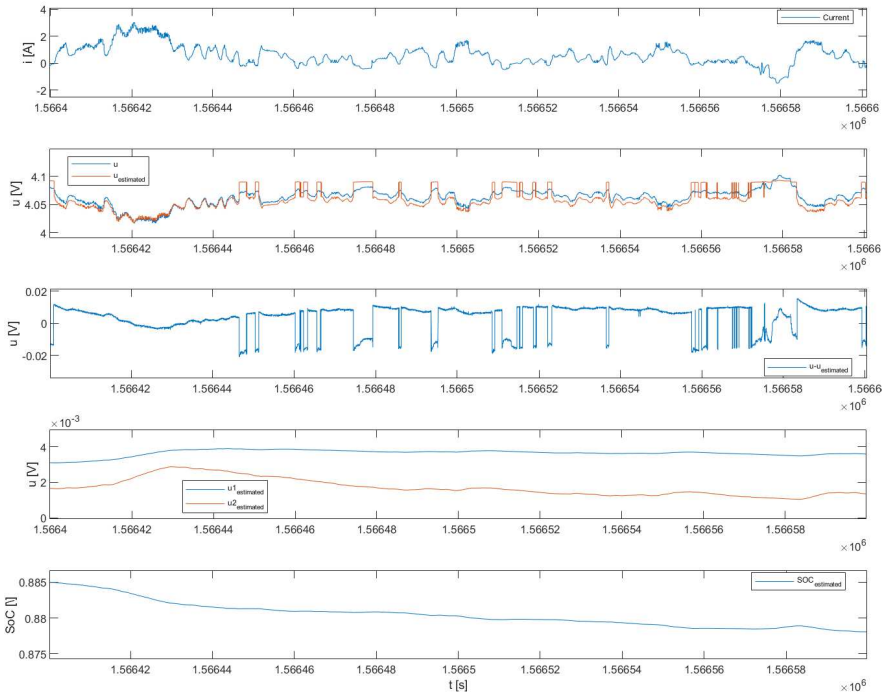

Slika 4.48: Uvećan prikaz optimiziranih veličina

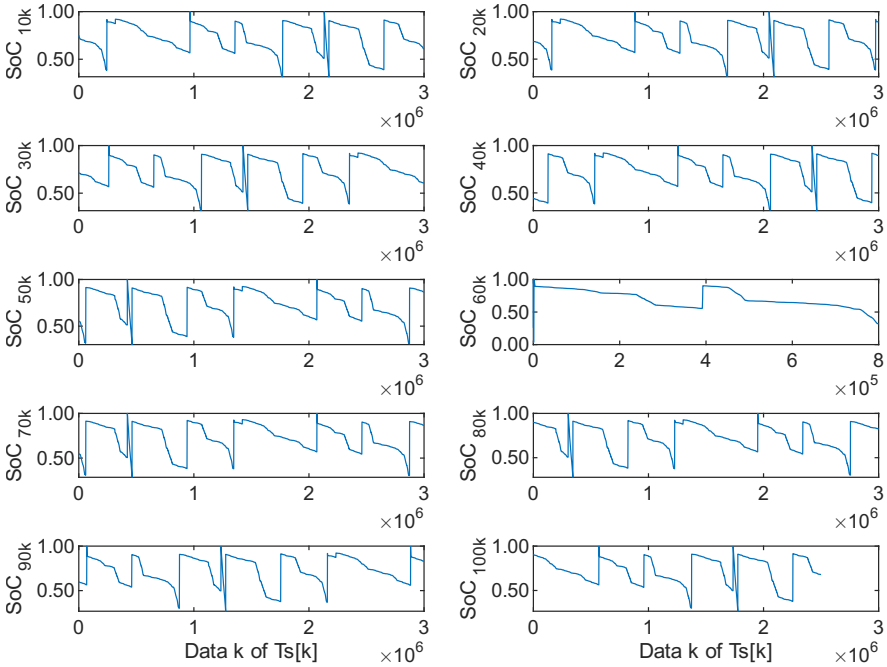

Slika 4.49: Aproksimirana stanja napunjenosti u ovisnosti o dometu

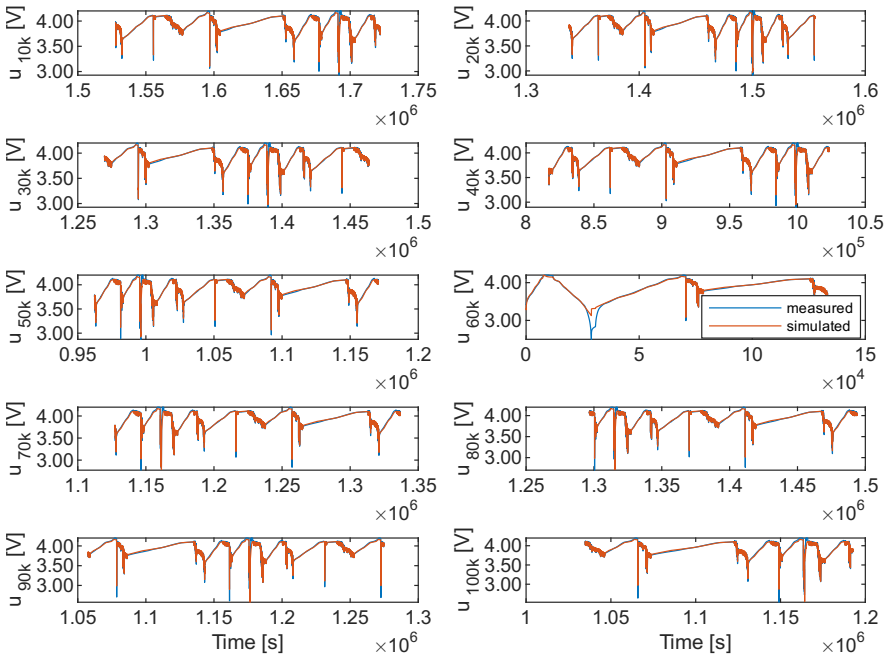

Slika 4.50: Usporedba mjerenog i estimiranog napona

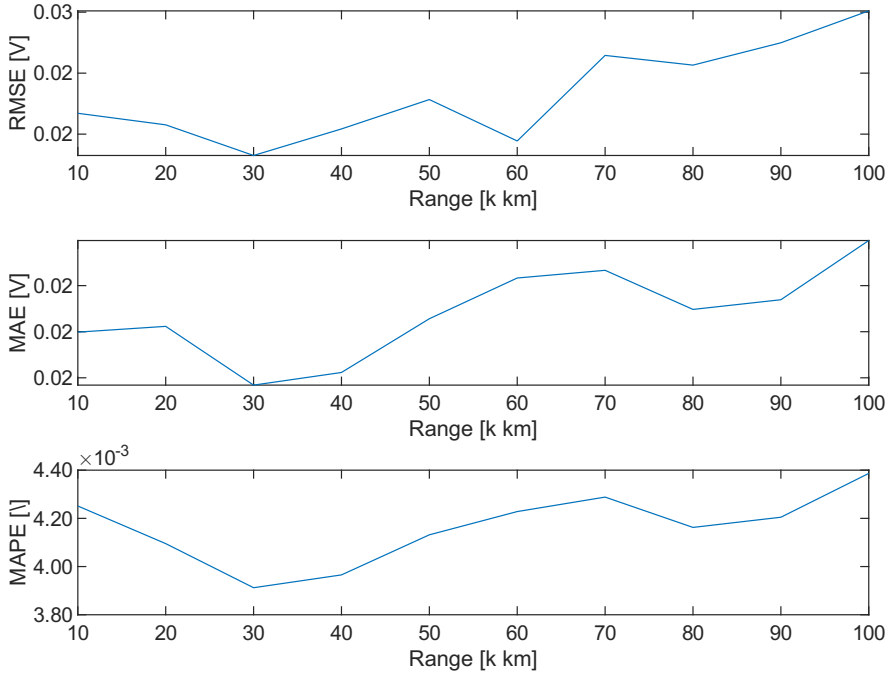

Slika 4.51: Pogreške identifikacije parametara modela

4.4. Rezultati online identifikacije indikatora zdravlja članka

Pojednostavljeni vektor parametara je identificiran metodom pomičnog horizonta (MHE) s vremenskim intervalom/prozorom od $T_{int} = 50h$ i vremenom uzorkovanja algoritma $T_s = 12h$. Korištena je fmincon funkcija za optimizaciju s interior-point algoritmom esimacije minimuma. S obzirom na postojeće greške u mjerenjima, nelinearan model je optimiziran isključivo na ispravnim podacima, za svih sto tisuća kilometara od prikupljenih mjerenja, kako bi dobili što bolja rješenja.

Tijekom pražnjenja baterije, krivulje otpora R_0, R_1 i R_2 vidljivo pokazuju porast njihovih vrijednosti s vremenom ako zanemarimo stršeće vrijednosti. Krivulje otpora tijekom punjenja nisu reprezentativni indikatori degradacije članka zbog premalih magnituda struje tijekom punjenja [12]. Na slikama od 4.52 do 4.54 su prikazani parametri otpora tijekom punjenja i pražnjenja. Gornji grafovi prikazuju estimirane parametre dobivene MHE optimizacijom, a donji parametre iz detaljno naučenog modela iz prošlog poglavlja 4.3. Na donjem grafu, svaka iteracija predstavlja optimizaciju parametara modela nakon prijeđenih 10 tisuća kilometara. Obje krivulje parametara otpora za pražnjenje imaju slične vrijed-

nosti i trend porasta otpora. Isto vrijedi i za estimirani kapacitet na slici 4.55.

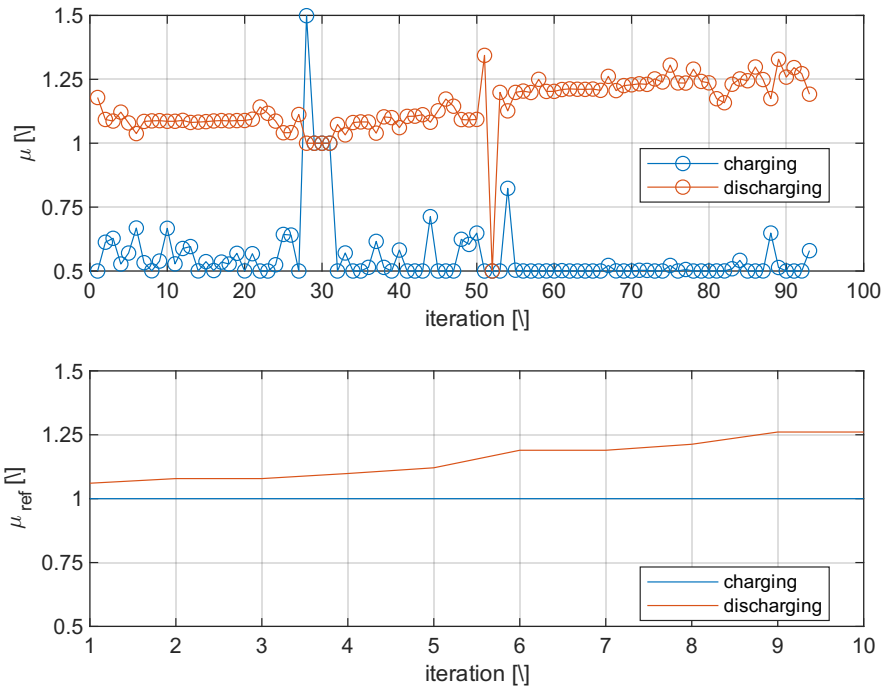

Slika 4.52: Dinamička estimacija otpora R0 za punjenje i pražnjenje

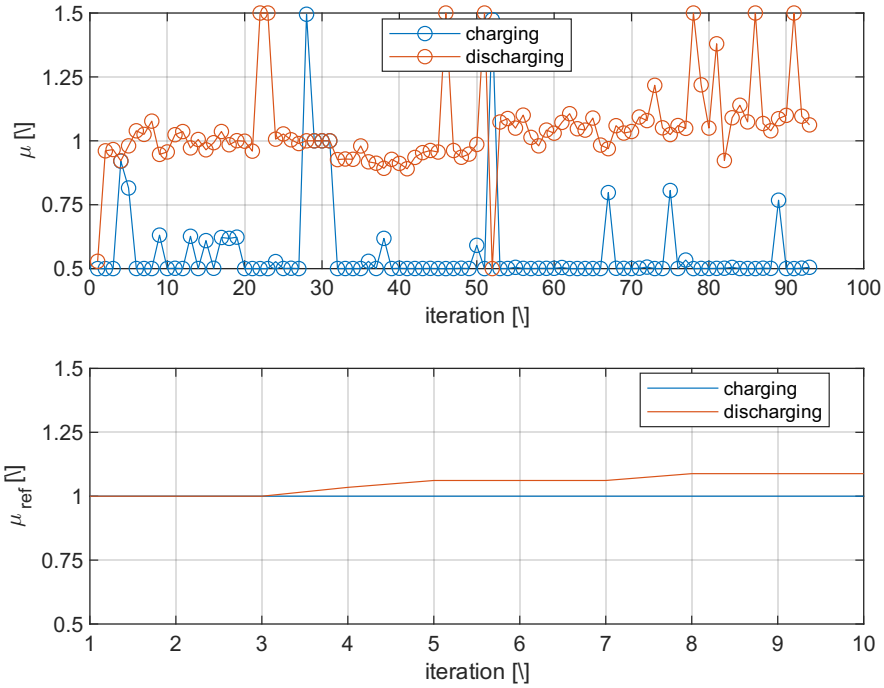

Slika 4.53: Dinamička estimacija otpora R1 za punjenje i pražnjenje

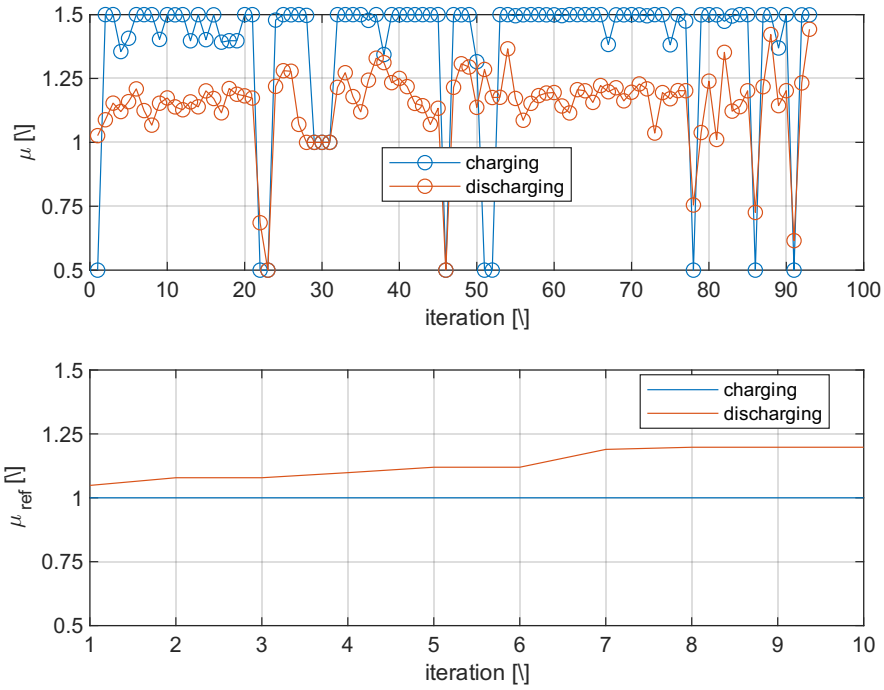

Slika 4.54: Dinamička estimacija otpora R2 za punjenje i pražnjenje

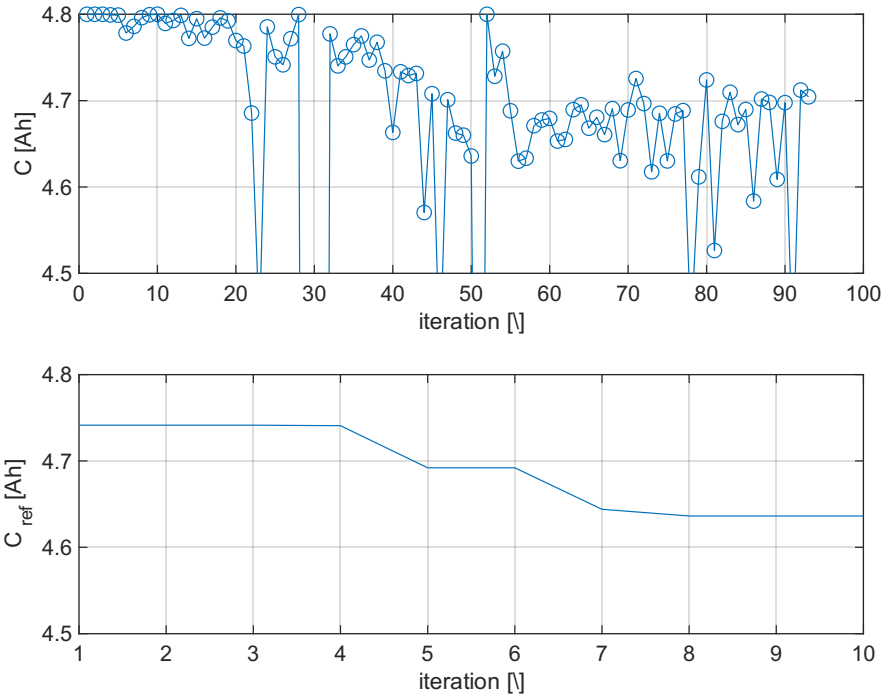

Slika 4.55: Dinamička estimacija kapaciteta

Pogreške estimacije parametara modela nisu velike što je vidljivo na gornjem grafu na slici 4.56. Na donjem grafu su prikazani počeci vremenskog horizonta za svaku iteraciju. Nakon svakih deset tisuća kilometara vrijeme se resetira zbog

načina na koji se prikupljaju mjerenja.

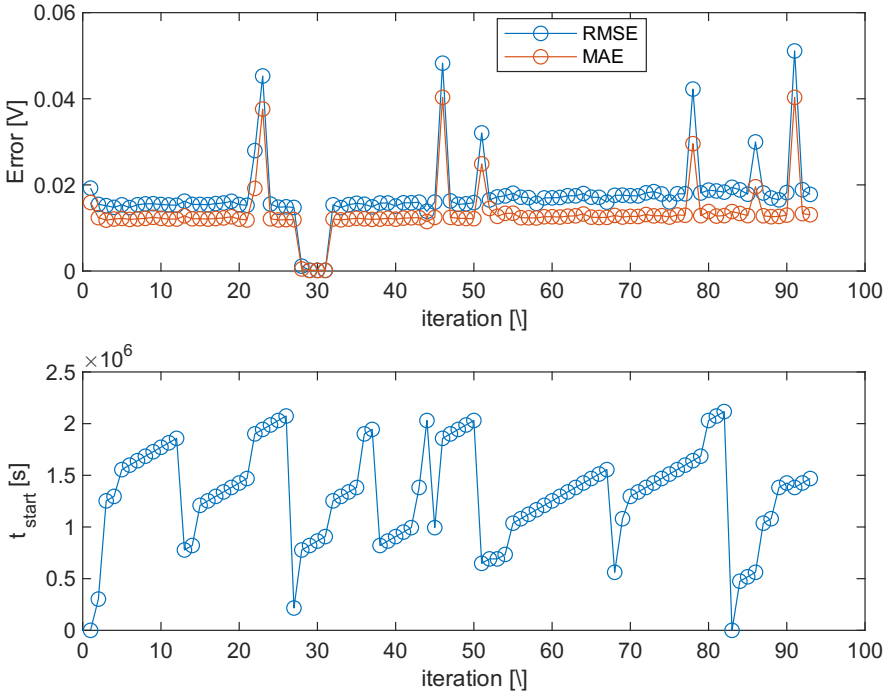

Slika 4.56: Pogreške estimacije parametara i počeci vremenskih intervala

5. Zaključak

Identifikacija parametara napravljena je prvo offline metodom koristeći fmincon funkciju s SQP algoritmom optimizacije minimuma cost funkcije. Rezultati optimizacije su zadovoljavajući, ali je potrebno postaviti puno ograničenja na nelinearan model kako bi se dobili željeni rezultati. Problem su prikupljena mjerenja jer uzorkovanje podataka nije konzistentno i nije dobro napravljeno testiranje litij-ionskog baterijskog članka. Baterija se nije uvijek ciklički punila i praznila do kraja tijekom testiranja što je rezultiralo manjim magnitudama struja i napona članka. Posljedično, otpori su dobro estimirani samo u području stanja napunjenosti od 30% do 80% jer se baterija najviše punila i praznila u tome području SoC-a. R2C model je optimiziran na manjem skupu mjerenja zbog pojavljivanja neispravno uzorkovanih podataka. Postoji dosta mjerenja s prevelikim vremenom uzorkovanja podataka što bi narušilo identifikaciju parametara modela.

Krivulje otpora su uspješno aproksimirane metodom najmanjih kvadrata koristeći funkciju polinoma prvog stupnja. Vektor parametara je smanjen s 154 elementa na deset elemenata odnosno omogućeno je da starenje litij-ionskog članka opišemo sa samo sedam parametara. Potom je ponovno optimiziran model, ali sa smanjenim vektorom parametara na istom skupu mjerenja. Identificirani otpori se dobro poklapaju s krivuljama referentih otpora iz detaljno naučenog modela.

Kontinuirano praćenje indikatora zdravlja članka izvedeno je estimacijom s pomičnim vremenskim intervalom (eng. Moving Horizon Estimation (MHE)) na istom optimizacijskom modelu kao i za prethodne slučajeve. Isprobane su različite duljine vremenskih intervala i vremena uzorkovanja procesa. Manji vremenski prozor bolje u vremenu lokalizira parametre, ali je veća nesigurnost njihova određivanja. Krivulje parametara otpora tijekom pražnjenja prikazuju trend porasta otpora dok vrijednosti parametara tijekom punjenja nisu baš reprezentativni indikatori zdravlja zbog manjih magnituda struja tijekom punjenja članka. Parametri otpora za pražnjenje i kapacitet imaju slične vrijednosti i trend porasta/pada kao i kod parametara iz detaljno naučenog modela s offline metodom.

Literatura

[1] Dragonfly energy. *A Guide To The 6 Main Types Of Lithium Batteries*. URL: https://dragonflyenergy.com/types-of-lithium-batteries-guide/.

[2] S. Laurén. *Force tensiometer to study the wettability of the battery electrodes*. URL: https://www.biolinscientific.com/blog/force-tensiometer-to-study-the-wettability-of-the-battery electrodes.

[3] Matsushima Measure Tech. *Lithium-Ion Battery (Secondary battery) definition, structure, features, raw material reserves and loss reduction*. URL: https://sensing.matsushima-m-tech.com/en/knowledge/24.

[4] Simone Barcellona i Luigi Piegari. "Lithium Ion Battery Models and Parameter Identification Techniques". *Energies* 10.12 (2017.). ISSN: 1996-1073.

[5] Filip Rukavina, Dorijan Leko, Matija Matijaić, Ivan Bralić, Juan M. Ugalde i Mario Vaak. "Identification of Equivalent Circuit Model Parameters for a Li-ion Battery Cell". *2023 IEEE 11th International Conference on Systems and Control (ICSC)* (2023.), str. 671–676.

[6] Z. Povijač. "Usporedba kombinacije Ni-Mn-Co oksida i litijevog ferofosfata kao katodnih materijala za litij ionske galvanske članke". Mag. rad. Fakultet kemijskog inženjerstva i tehnologije, 2024.

[7] D. Kim, K. Koo, J. J. Jeong, T. Goh i S. W. Kim. "Second-Order Discrete-Time Sliding Mode Observer for State of Charge Determination Based on a Dynamic Resistance Li-Ion Battery Model". *Energies* 6.10 (2013.), str. 5538–5551. ISSN: 1996-1073.

[8] U. Krewer, F. Röder, E. Harinath, R. D. Braatz, B. Bedürftig i R. Findeisen. "Review—Dynamic Models of Li-Ion Batteries for Diagnosis and Operation: A Review and Perspective". *Journal of The Electrochemical Society* 165.16 (2018.), A3656.

[9] L. Prlenda. “Energetski učinkovito upravljanje raspodjelom pogonskog momenta”. Mag. rad. Fakultet elektrotehnike i računarstva, 2024.

[10] Eric L. Haseltine i James B. Rawlings. “Critical Evaluation of Extended Kalman Filtering and Moving-Horizon Estimation”. *Industrial & Engineering Chemistry Research* 44.8 (2005.), str. 2451–2460. DOI: 10.1021/ie0343081.

[11] Jelena Popovic. “10 - Nanostructured alkali and alkaline earth metal interfaces for high-energy batteries”. *Nanomaterials for Electrochemical Energy Storage*. Ur. Rinaldo Raccichini i Ulderico Ulissi. Sv. 19. Frontiers of Nanoscience. Elsevier, 2021., str. 327–359.

[12] Xinfan Lin i Anna G. Stefanopoulou. “Analytic Bound on Accuracy of Battery State and Parameter Estimation”. *Journal of The Electrochemical Society* 162.9 (srpanj 2015.), A1879. DOI: 10.1149/2.0791509jes.

Sažetak

Litij-ionski baterijski članak opisan je R2C modelom ekvivalentnog strujnog kruga (ECM). Objašnjen je princip optimizacije nelinearnog modela članka uz postavljena ograničenja. Korištena je Fmincon funkcija i metoda sekvencijalnog kvadratnog programiranja (SQP) kako bi se riješio zadani nelinearni problem. Parametri modela prvo su identificirani offline metodom. Nakon toga je pojednostavljen vektor parametara kako bi se dobili konkretni indikatori zdravlja članka. Odzivi modela s novim parametrima validirani su naspram odziva iz detaljno naučenog modela. Zatim je provedena online identifikacija modela s reduciranim vektorom parametara. Potom slijedi prikaz i objašnjenje rezultata, a na kraju je napisan zaključak rada.

Ključne riječi: litij-ionski članak, ECM, Fmincon funkcija, SQP algoritam, parametri, indikatori zdravlja, metode identifikacije

Determining and monitoring of battery cell health indicators

Abstract

The lithium-ion battery cell is described by the R2C model of the equivalent circuit (ECM), explaining the principle of optimizing the nonlinear model with set constraints. The Fmincon function and the sequential quadratic programming (SQP) method were used to solve the given nonlinear problem. First, the model parameters were identified offline. After that, the parameter vector was simplified to obtain specific health indicators of the cell. The model responses with the new parameters were validated against the responses from the detailed learned model. Then, online identification of the model with the reduced parameter vector was performed. Followed by the presentation and explanation of the results, and finally, a conclusion of the thesis.

Keywords: lithium-ion cell, ECM, Fmincon function, SQP algorithm, parameters, health indicators, identification methods