

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/308472361>

Ocenjevanje stanja napolnjenosti baterije inteligentnega avtodoma Estimating the state of battery charge in an intelligent mobile home

Conference Paper · September 2016

CITATIONS

0

READS

6

4 authors:



[Matej Senozetnik](#)

Jožef Stefan Institute

1 PUBLICATION 0 CITATIONS

[SEE PROFILE](#)



[Luka Bradeško](#)

Jožef Stefan Institute

17 PUBLICATIONS 41 CITATIONS

[SEE PROFILE](#)



[Luka Stopar](#)

Jožef Stefan Institute

4 PUBLICATIONS 2 CITATIONS

[SEE PROFILE](#)



[Dunja Mladenić](#)

Jožef Stefan Institute

226 PUBLICATIONS 3,253 CITATIONS

[SEE PROFILE](#)

Some of the authors of this publication are also working on these related projects:



OPTIMUM [View project](#)



OPTIMUM [View project](#)

Ocenjevanje stanja napolnjenosti baterije inteligentnega avtodoma

Matej Senočetnik^{1,2}, Luka Bradeško^{1,2}, Luka Stopar^{1,2}, Dunja Mladenič^{1,2}

¹ Institut Jožef Stefan, Jamova 39, 1000 Ljubljana

² Mednarodna podiplomska šola Jožefa Stefana, Jamova cesta 39, 1000 Ljubljana

E-pošta: matej.senozetnik@ijs.si

Estimating the state of battery charge in an intelligent mobile home

The paper investigates the use of machine learning methods for estimating state of charge (SOC) of Li-Ion batteries. Machine learning methods are evaluated in a real-world setting of an intelligent mobile home. The state of charge depends on the batteries capacity, electrical current that flew in/out of the battery and its temperature. We first acquired historical measurements of the current, voltage and temperature under regular operating conditions. Then we applied support vector machine method to estimate the state of battery charge and obtain accurate predictions outperforming the existing voltage method.

1 Uvod

Z razvojem inteligentnih avtodomov se je pojavila potreba po čim natančnejšem ocenjevanju stanja raznih virov, kot na primer ocenjevanje stanja čiste in odpadne vode ter ocenjevanje stanja baterije. Stanja napolnjenosti baterije ne moremo direktno meriti, zato ga je potrebno oceniti z merjenjem toka, napetosti, temperature in drugih razpoložljivih podatkov. Pri delu se osredotočimo na baterijo, ki temelji na tehnologiji polnilnih baterij Li-ion z anodnim materialom $LiFePO_4$. Li-ion tehnologija je vedno bolj zanimiva za uporabo v aplikacijah, v katere se tradicionalno vgrajuje manj zahtevne in bolj preizkušene vrste baterij [4].

V literaturi [2, 9] za ocenjevanje stanja napolnjenosti zasledimo naslednje delitev metod in sicer:

- **neposredne metode**, ki se nanašajo na fizikalne lastnosti baterije;
- **metode integriranja**, ki uporabljajo tok praznjenja ali polnjenja kot vhodni podatek;
- **adaptivni sistemi**, ki prilagajajo sistem glede na podatke, ki prihajajo vanj in z njimi ocenimo SOC;
- **hibridne metode**, ki so kombinacija neposrednih metod, metod integriranja in adaptivnih sistemov.

V tem delu smo preizkusili iz vsake skupine vsaj eno izmed metod. Implementirali smo najbolj smiselne, glede na podatke, ki smo jih pridobili in opremo, ki smo jo imeli na voljo. V skupini neposrednih meritev smo implementirali metodo napetostnih meritev. Izmed metod

integriranja smo implementirali metodo štetja naboja in smo jo uporabili tudi kot referenčno vrednost. Pri adaptivnih sistemih smo preizkusili metodo podpornih vektorjev. Poskusili smo tudi kombinacijo dveh vrst metod in sicer napetostno meritev in metodo podpornih vektorjev.

2 Pregled metod

Metode za ocenjevanje stanja napolnjenosti smo razdelili v skupine in izpostavili nekaj predstavnikov iz vsake skupine.

2.1 Neposredne metode

Neposredne metode uporabljajo fizikalne lastnosti baterije, kot so napetost, tok, temperatura in impedanca [9].

Eden izmed predstavnikov neposrednih metod je test praznjenja, ki ga proizvajalci uporabljajo z namenom, da določijo maksimalno kapaciteto baterije.

S pomočjo impedance se lahko določi SOC. Pri merjenju elektrokemijske impedance se baterijo vzbuja z izmeničnim tokovnim ali napetostnim signalom majhne amplitude [12]. Vzbujalni signali so lahko sinusne oblike ali poljubni frekvenčno bogati signali. Med tokovnim vzbujanjem baterije se baterija odzove z napetostnim odzivom, ki je neposredno odvisen od elektrokemijske impedance baterije. Med vzbujanjem baterije je potrebno signala toka in napetosti vzorčiti ter ju nato z ustreznimi metodami obdelave signalov obdelati in iz njih pridobiti impedančno karakteristiko.

Znan predstavnik neposrednih metod je metoda napetostne meritve, ki je bila uporabljena v nadaljnjih analizah.

2.1.1 Metoda napetostne meritve

Meritve napetosti je razširjena metoda, vendar ne velja za natančno. Določitev stanja napolnjenosti baterije samo na podlagi napetosti je računsko manj zahtevna kot štetje naboja, vendar je lahko zavajajoča [1]. Napaka v oceni SOC-a, ki temelji na meritvah napetosti, je lahko popravljena, če je odvisnost med napetostjo baterije, temperaturo in praznjenjem znana. Če to vključimo v izračun, metoda postane bolj zapletena kot štetje naboja.

2.2 Metode integriranja

Metode integriranja kot vhodni podatek uporabljajo tok praznjenja ali polnjenja. Najbolj znan predstavnik metod

integriranja je štetje naboja.

2.2.1 Štetje naboja

Štetje naboja je preprosta za implementacijo in temelji na meritvi toka in integracije le-tega po času. Učinkovitost metode štetja naboja je odvisna od kvalitete senzorja za merjenje toka, temperature baterije in samopraznjenja. Samopraznjenje je izguba naboja, ko akumulator ni v uporabi. SOC izračunamo po enačbi 1, kjer $Q_{maksimalna}$ pomeni maksimalno kapaciteto baterije, $Q_{trenutna}$ pomeni trenutno količino shranjenega naboja baterije in SOC_0 je izhodiščna točka napolnjenosti [7].

$$SOC = \frac{Q_{trenutna}}{Q_{maksimalna}} = SOC_0 + \frac{\int_{t_{SOC_0}}^{t_{SOC_{end}}} Idt}{Q_{maksimalna}} \quad (1)$$

2.3 Adaptivni sistemi

Adaptivni sistemi so prilagodljivi sistemi, kot na primer sistemi z mehko logiko [13], sistem s Kalmanovim filtrom [3], metodo podpornih vektorjev [5] in ostale metode strojnega učenja.

Ena izmed uporabljenih metod za izračun SOC-a je nevronska mreža [9], kjer so za oceno SOC uporabili vzvratno propagirajočo nevronska mrežo. Sestavljajo jo tri plasti, in sicer vhodna, skrita ter izhodna plast. V vhodni plasti so uporabljeni trije nevroni, ki vključujejo napetost, tok in temperaturo. Skrita plast vsebuje g-nevronov. Izhodna plast kot rezultat vrne SOC.

Poleg nevronskih mrež se za oceno SOC uporablja tudi metoda podpornih vektorjev.

2.3.1 Metoda podpornih vektorjev

Metoda podpornih vektorjev (angl. Support Vector Machines oz. SVM) je metoda strojnega učenja, razvita iz statistične teorije. Metoda je primarno binarna klasifikacijska metoda, ki se lahko uporablja tudi za ločevanje več razredov in regresijskih problemov. Primerna je za učenje na velikih množicah primerov, z velikim številom manj pomembnih atributov. Slaba stran metode je, da je interpretacija naučenega modela težavna.

Hansen in Wang [6] sta uporabila SVM za oceno SOC. Pri tem sta ugotovila, da je metoda robustna in se lahko njena točnost ob primerni nastavitvi parametrov približa razširjenemu Kalmanovemu filtru. Ob tem se poraba procesorske moči lahko enači z štetjem naboja. Tudi v našem primeru je bil uporabljen SVM za reševanje problema.

2.4 Hibridne metode

Hibridne metode so kombinacija že omenjenih metod. Z njimi poskušamo izničiti ali vsaj omiliti slabosti posamezne metode.

Ena izmed hibridnih metod, je metoda odprtih sponk z razširjenim Kalmanovim filtrom, ki jo je predstavil Lee [10]. Ta metoda naj bi bila optimalno prilagodljiv algoritem na podlagi rekurzije. Za izboljšanje učinkovitosti morajo biti izbrani pravi parametri. Vedeti je potrebno, da parametri, kot so upornost, kapacitivnost in OCV-SOC (OCV pomeni napetost odprtih sponk), niso konstantni pri spremembah SOC-a, temperature ter staranja. Razmerje med OCV-SOC se razlikuje, zato pride do napak v

oceni. Predlaga se modificiranje razmerja, ki bo neodvisno od pogojev baterije.

V naši raziskavi smo uporabili kombinacijo dveh vrst metod in sicer napetostno meritev ter metodo podpornih vektorjev.

3 Uporaba metod in evalvacija

3.1 Zajem in opis podatkov

Učne podatke smo pridobili v realnem okolju in sicer v prototipnem avtodomu Sonic A11(1770 SL), katerega namen je testiranje uporabnosti novih materialov, senzorjev in umetne inteligence. Razvili smo ga s podjetjem Adria Mobil d.o.o. Obdelani, kot tudi izvorni senzorski podatki, se pošiljajo za avtodom prilagojenemu ekspertnemu sistemu, ki se nato samostojno ali s pomočjo uporabnika odloči za različne odzive ter akcije avtodoma. Dogajanje v avtodomu je prav tako mogoče spremljati in upravljati na daljavo preko mobilne aplikacije, na kateri lahko spremljamo dogajanje ter vplive na obnašanje nekaterih komponent avtodoma (trenutno prižgane luči, peč, projektirano platno, vodna črpalka, CO_2 , temperatura, svetloba in podatki o vlagi). V avtodomu je vgrajena baterija z $LiFePO_4$ katodnim materialom. Izdelana je bila namensko in je sestavljena iz štirih elektrokemičnih celic, ki so vezane serijsko.

Prva faza naše raziskave je bila zajemanje podatkov. Za cilj smo si zastavili pridobiti čim bolj realne podatke. V ta namen smo napisali skripto, s pomočjo katere so se prižigale in ugašale luči, vklapljalo se je prezračevanje in hladilnik. Čas preklapljanja porabnikov baterije je bil izbran naključno med eno in šestimi urami. Cikli praznjenja in polnjenja so različno dolgi ter se gibljejo med 39 in 90 urami. Uporabnih podatkov je bilo zbranih za 10 ciklov, ki smo jih uporabili za nadaljnjo obdelavo. Nekaj ciklov je bilo iz različnih razlogov neuporabnih. Učni podatki zajemajo naslednje vrednosti:

- pokrivajo vrednosti pri praznjenju med 10,7 in 13,22 V, ter tok med 0 in 13 A,
- pri polnjenju pa med 10,6 in 14,2 V, ter tok med 0 in 22 A.

Pridobljena sta še podatka o temperaturi in o priklopu na zunanji vir električne energije. Podatki so bili izmerjeni v različnih temperaturnih območjih med decembrom 2014 in julijem 2015.

Podatke o toku, napetosti, temperaturi in informaciji o priklopu na zunanji vir električne energije smo pridobivali v različnih časovnih intervalih, ki so se shranjevali v bazo podatkov na strežniku. Vse zbrane podatke je bilo potrebno prevzorčiti pred nadaljnjo obdelavo z namenom, da smo različne nize podatkov uskladili na skupno časovno enoto in bazo. Pri polnem stanju baterije smo izračunali kapaciteto in določili SOC s pomočjo metode štetja naboja.

3.2 Štetje naboja

Ker nimamo podatka o resničnem SOC-u, smo metodo štetja naboja uporabili kot referenčno vrednost v nadalj-

Filter	SVM Z RBF		SVM Z RBF in PLF		PLF	
	Ne	Da	Ne	Da	Ne	Da
MAE	3,17	4,06	2,39	2,73	2,79	3,29
MSE	19,37	16,89	18,45	16,43	16,89	18,12

Tabela 1: Prikaz rezultatov metod s končno testno množico.

njih raziskavah. Za večjo natančnost smo se oprli na nekaj kalibracijskih točk in predpostavk. Cikel smo razdelili na polnjenje in praznjenje s tem, da bi lažje zagotovili večjo natančnost metode. Predpostavili smo, da je baterija polna, ko se začne prazniti (SOC = 100%) in da je baterija prazna, ko jo začnemo polniti (SOC = 0%).

3.3 Metoda napetostne meritve

Najprej smo preizkusili metodo, ki s pomočjo nivoja napetosti oceni SOC. Pri tej metodi smo problem razdelili na manjše podprobleme. Napetost smo razdelili na n enakih delov, kjer vsak del ostaja ločen z minimalno in maksimalno napetostjo (V_{min} in V_{max}), ter V_{tr} predstavlja trenutno napetost. SOC smo izračunali po enačbi 2, za 4 napetostne krivulje pri praznjenju s konstantnimi tokovi 3 A, 6 A, 10 A in 13 A in eno krivuljo pri polnjenju. Metoda postane nenatančna pri večji variaciji temperature.

$$SOC = SOC_{min} + \frac{V_{tr} - V_{min}}{V_{max} - V_{min}} (SOC_{max} - SOC_{min}) \quad (2)$$

3.4 Metoda podpornih vektorjev

Za izvedbo učenja z metodo podpornih vektorjev smo najprej ustrezno nastavili parametre metode. Uporabili smo linearno, polinomsko in radialno bazno jedro (RBF). Linearno jedro smo po nekaj poskusih opustili, saj je v našem primeru neučinkovito in daje slabe rezultate. Polinomsko jedro so že uporabljali v preteklih raziskavah [6]. Odločili smo se za radialno bazno jedro, ki se tudi že pojavlja v prejšnjih raziskavah [14]. Vrednosti parametra ϵ (kaznovanje napak) in C (cena napačne klasifikacije) smo nastavili eksperimentalno in sicer pri modelu polnjenja baterije $\epsilon = 0,203$ in $C = 5$, pri modelu praznjenja baterije $\epsilon = 0,403$ in $C = 5$. Pri metodi podpornih vektorjev smo za vhodne podatke uporabili tok in napetost.

3.5 Metoda podpornih vektorjev v kombinaciji z metodo napetostnih meritvev

Kot primer za hibridne metode smo preizkusili metodo podpornih vektorjev v kombinaciji z metodo napetostnih meritvev. Model smo želeli narediti čim bolj robusten na temperaturne spremembe. Atribut temperature je bilo potrebno diskretizirati, ker ni bilo dovolj meritvev za določeno vrednost. Ker se baterija nahaja v realnem sistemu avtomoda, se notranja temperatura v avtodomu preko dneva spreminja tudi do 20 °C. Atribut temperature smo diskretizirali na naslednje vrednosti "do 15 °C", "med 15 in 25 °C" in "več kot 25 °C", glede na učne podatke. Poleg temperature in SOC-a napetostne meritve, smo uporabili še attribute toka in napetosti. Z mrežnim iskanjem smo našli najbolj optimalno rešitev parametrov za oba modela. Pri modelu polnjenja smo uporabili vrednost $\epsilon = -0,2$ in

vrednost $C = 5$ in pri modelu praznjenja smo uporabili vrednost $\epsilon = -0,4$ in vrednosti $C = 5$.

3.6 Primerjava implementiranih metod

Oceno uspešnosti smo preverili s srednjo absolutno napako in srednjo kvadratno napako. Srednja absolutna napaka je mera uspešnosti, ki je definirana kot povprečna absolutna razlika med napovedano in pravo vrednostjo. Srednja kvadratna napaka je mera uspešnosti, ki je definirana kot povprečni kvadrat razlike med napovedano in pravo vrednostjo.


Podatke smo razdelili na učno in testno množico in sicer smo cikel podatkov uporabili za končno testno množico. Za gradnjo modela smo uporabili prečno preverjanje ($k=5$) na učni množici, ki je bila uporabljena za nastavitve parametrov.

V tabeli 1 so prikazane metoda podpornih vektorjev (SVM z RBF), metoda napetostne meritve (PLF) in metoda podpornih vektorjev z napetostno meritvijo (SVM z RBF in PLF). Pri stolpcih *Da* smo rezultat filtrirali z uporabo filtra z drsečim povprečjem. V rezultatih se je pojavljala napaka, ki se je kazala kot velika nestabilnost izhodnih podatkov (hitri preskoki vrednosti SOC-a). Nekaj nestabilnosti sicer povzroča menjava modelov, zato smo se odločili, da izhodni rezultat še dodatno filtriramo. S tem smo izločili prevelika nihanja v oceni SOC-a. Filter smo implementirali po enačbi 3 in nastavili parameter v velikosti okna na 200.

$$y = \frac{1}{velikostOkna} (x_1 + x_2 + \dots + x_{velikostOkna-1}) \quad (3)$$

Napake so izračunane na podlagi filtriranega rezultata in njene prave vrednosti. Pri stolpcih *Ne* je napaka, ki je izračunana na podlagi rezultata in njene prave vrednosti. Filtrirani rezultati malo pokvariijo rezultat, vendar zagotovijo večjo stabilnost [2]. Najbolje se na testni množici obnese metoda podpornih vektorjev z napetostno meritvijo, njena povprečna absolutna napaka znaša 2,39 oz. če je rezultat filtriran 2,73. Zelo dobro se obnese tudi metoda napetostne meritve. Njena povprečna absolutna napaka znaša 2,79.

Na sliki 1 je z rdečo barvo (polna črta) prikazana naša referenčna vrednost štetja naboja. Prikazane metode odstopajo v podobnih časovnih intervalih, vendar nekatere bolj intenzivno, kot druge. Z nekaj izboljšavami pri napetostnih metodah (upoštevanje toka), smo dosegli večjo točnost pri oceni stanja napolnjenosti, kot je to sposobna oceniti metoda podpornih vektorjev. Slednja se v danem primeru tudi najslabše obnaša. Na testnih podatkih se naše metode najpogosteje zmotijo v začetku praznjenja in okoli petnajste ure pri praznjenju in proti koncu polnjenja, natančneje med petintrideseto in štirideseto uro.



Slika 1: Prikaz rezultatov.

V celoti gledano najboljše oceni stanje napolnjenosti metoda podpornih vektorjev z napetostno meritvijo in je bila vgrajena v avtodom. Ker se včasih pojavi razlika med laboratorijskimi testi in testiranjem v avtodomu, bomo skušali v prihodnosti to razliko omiliti (nenapovedano menjavanje režima polnjenja in praznjenja na sredi cikla).

4 Zahvala

Delo je delno financirano s strani ARRS in evropskega raziskovalnega projekta OPTIMUM (H2020-MG-636160).

Literatura

- [1] Inaccuracies of estimating remaining cell capacity with voltage measurements alone. Dosegljivo: <http://www.maximintegrated.com/en/appnotes/index.mvp/id/121>.
- [2] Matej Senožetnik, Ocenjevanje stanja napolnjenosti baterije v inteligentnem avtodomu
- [3] Simon J. Julier, Jeffrey K. Uhlmann, A New Extension of the Kalman Filter to Nonlinear Systems
- [4] Janko Petrovčič Andrej Debenjak, Gregor Papa. Modularni sistem za upravljanje li-ion baterije.
- [5] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Mach. Learn.*, 20(3):273–297, September 1995.
- [6] Terry Hansen and Chia-Jiu Wang. Support vector based battery state of charge estimator. *Journal of Power Sources*, 141(2):351–358, 2005.
- [7] J. Jiang and C. Zhang. *Fundamentals and Application of Lithium-ion Batteries in Electric Drive Vehicles*. Wiley, 2015.
- [8] I. Kononenko and M.R. Šikonja. *Inteligentni sistemi*. Založba FE in FRI, 2010.
- [9] Wen-Yeou Chang. The state of charge estimating methods for battery: a review. *ISRN Applied Mathematics*, 2013, 2013.
- [10] Daniel Le and Xidong Tang. Lithium-ion battery state of health estimation using ah-v characterization. In *Proceedings of the Annual Conference of Prognostics and Health Management (PHM) Society, Montreal, QC, Canada*, volume 2529, page 367373, 2011.
- [11] Sabine Piller, Marion Perrin, and Andreas Jossen. Methods for state-of-charge determination and their applications. *Journal of power sources*, 96(1):113–120, 2001.
- [12] Valer Pop, Henk Jan Bergveld, Dmitry Danilov, Paul P.L. Regtien, and Peter H.L. Notten. *Battery Management Systems: Accurate State-of-Charge Indication for Battery-Powered Applications (Philips Research Book Series) (Philips Research Book Series)*. Springer Publishing Company, Incorporated, 1 edition, 2008.
- [13] Alvin J Salkind, Craig Fennie, Pritpal Singh, Terrill Atwater, and David E Reisner. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology. *Journal of Power Sources*, 80(1):293–300, 1999.
- [14] J.C. Alvarez Anton, P.J. Garcia Nieto, C. Blanco Viejo, and J. A. Vilan Vilan. Support vector machines used to estimate the battery state of charge. *Power Electronics, IEEE Transactions on*, 28(12):5919–5926, Dec 2013.