

# Elektromobilių baterijų likutinės vertės prognozavimas

## Kasparas Veličkevičius

Vilniaus universitetas, Taikomosios matematikos institutas,  
Naugarduko g. 24, Vilnius  
kasparas.velickevicius@gmail.com

**Santrauka.** Elektromobilio baterijos likutinė vertė (angl. *state of health, SoH*) yra baterijos tikrosios elektrinės talpos ir gamintojo nustatytos talpos santykis. Šis rodiklis apibūdina baterijos degradaciją. Nuo tikslaus baterijos *SoH* įvertinimo priklauso automobilio efektyvumas ir saugumas. Šio darbo tikslas – prognozuoti baterijos likutinę vertę, naudojant krovimo įtampos duomenis. Tam parinktas *XGBoost* modelis, gebantis prognozuoti elektromobilių baterijų elementų *SoH*, remiantis krovimo įtampos kreivų požymiais.

**Raktiniai žodžiai:** elektromobiliai, baterijos, įtampos kreivės, *SoH*, *XGBoost*

## 1 Įvadas

Pastaraisiais dešimtmečiais pasaulyje kyla vis rimtesnių problemų, susijusių su globaliniu atšilimu ir iškastinio kuro išteklių trūkumu, todėl žmonės vis labiau domisi švarios energijos naudojimu. Tai suteikia poreikį plėtoti elektromobilius, kurie plačiai pripažįstami kaip svarbi priemonė kovojant su aplinkos tarša ir energijos resursų stoka. Ličio jonų baterijos plačiai naudojamos kaip elektromobilių energijos šaltinis dėl jų efektyvumo. Tačiau jų veikimas laikui bėgant blogėja dėl senėjimo ir kitų veiksnių, o tai sumažina baterijų energijos kaupimo ir energijos perdavimo pajėgumą. Tikslus baterijos būklės (*SoH*) įvertinimas tapo svarbiu uždaviniu elektromobilių pramonėje, nes tai lemia saugų ir efektyvų transporto priemonės funkcionavimą.

Šiame darbe nuspręsta prognozuoti *SoH*, nagrinėjant kelių įtampos kreivės regionų (krovimo ir atsipalaidavimo) požymius kartu, o ne atskirai, kaip įprasta literatūroje. Taip siekiama išnaudoti visą krovimo įtampos kreivės informaciją ir potencialiai gauti didesnę prognozavimo tikslumą.

## 2 Literatūros apžvalga

*SoH* vertinimas plačiai sprendžiamas uždavinys literatūroje. [2, 3] straipsniuose tirti baterijos elektros stiprio, įtampos, temperatūros kreivių požiū-

miai. *SoH* prognozavimui autoriai naudojo *RVM*, neuroninius tinklus. [4, 5] straipsniuose pagrįsta, kad praktiškiausia tirti krovimo duomenis, nes jie mažiau priklauso nuo automobilio vairavimo ypatumų, lyginant su iškrovos duomenimis. Kaip modelio požymius autoriai naudojo laiką įvairiuose voltų intervaluose, pastovaus stiprio krovimo metu. Parinkti *RFR*, *LS-SVM* modeliai. [6, 7] straipsniuose iš įtampos kreivių apskaičiavo tokius požymius, kaip pastovaus stiprio krovimo laikas, pastovios įtampos krovimo laikas, įtampos kreivės krypties koeficientas fiksuotam voltų intervale. Prognozavimui parinkti *GPR* ir *LSTM* modeliai. [8] straipsnyje pagrįsta, kad atsipalaidavimo periodas po įkrovimo stipriai susijęs su *SoH*. Anot autorių, naudinga tirti šį įtampos kreivės regioną, nes jis mažiau priklauso nuo krovimo sąlygų. Iš įtampos kreivių atsipalaidavimo metu apskaičiuoti statistiniai požymiai, *SoH* prognozavimui parinkti *SVR* ir *XGBoost* modeliai.

### 3 Duomenys


Duomenys paimti iš viešai prieinamo duomenų rinkinio, kuris buvo naudojamas [8] straipsnyje. Duomenys surinkti laboratorijoje testuojant komerciškai prieinamas ličio jonų baterijas. Testuotos 105 dviejų cheminių sudėčių baterijos: nikelio-kobalto-aliuminio (*NCA*) ir nikelio-kobalto-mangano (*NCM*). Testai atlikti kameroje su kontroliuojama temperatūra (25, 35 ir 45 °C). Naudotas pastovaus stiprio – pastovios įtampos (*CCCV*) krovimo protokolas ir pastovaus stiprio iškrova. Vienas baterijos testavimo ciklas apima penkis procesus: pastovaus stiprio krovimą, pastovios įtampos (*CV*) krovimą, 30 min atsipalaidavimą po įkrovimo, *CC* iškrovimą ir 30 min atsipalaidavimą po iškrovimo.

Tirti šie požymiai: *F1* – pastovaus stiprio krovimo laikas, *F2* – pastovios įtampos krovimo laikas, *F3* – įtampos kreivės krypties koeficientas voltų intervale [4; 4,2] pastovaus stiprio krovimo metu; *F4* – maksimali įtampos reikšmė atsipalaidavimo periode; *F5* – minimali įtampos reikšmė atsipalaidavimo periode; *Ch* – baterijos cheminė sudėtis; *T* – baterijos testavimo aplinkos temperatūra.

### 4 Rezultatai ir išvados

Tikslui įgyvendinti parinktas *XGBoost* modelis. Tai ansamblinio mokymo algoritmas, paremtas gradientų tobulinimo pasirinkimų medžiais. Šis metodas parenka silpnus sprendimų medžius paeiliui ir kiekvienas medis pako-

reguoja prieš tai parinkto medžio prognozes [1]. Buvo optimizuoti šie modelio hiperparametrai: maksimalus medžio gylis, minimalus mazgo svoris, dalinės imties dydis, požymių dalis medyje, žingsnio dydis, medžių skaičius. Hiperparametrų optimizavimui naudotas *Grid search* algoritmas. Modelio prognozavimo tikslumo testinėje aibėje metrikos  $MAE = 0,0022$ ,  $MAPE = 0,0027$ ,  $RMSE = 0,0030$ . 1 pav. pateiktas grafikas, rodantis mažas paklaidas tarp prognozuotų ir tikrųjų reikšmių. Taigi šiame darbe parinktas modelis, gebantis aukštu tikslumu prognozuoti elektromobilio baterijos likutinę vertę, remiantis baterijos krovimo įtampos duomenimis.



**1 pav.** Dviejų testinės aibės baterijų tikrosios ir prognozuotos SoH reikšmės, didėjant testavimo ciklų skaičiui.

## Literatūra

- [1] T. Chen and C. Guestrin. XGBoost: A scalable tree boosting system. 2016.
- [2] C. Du, R. Qi, Z. Ren, and D. Xiao. Research on state-of-health estimation for lithiumion batteries based on the charging phase. *Energies*, 16(3):1420, Feb. 2023.
- [3] P. Guo, Z. Cheng, and L. Yang. A data-driven remaining capacity estimation approach for lithium-ion batteries based on charging health feature extraction. *J. Power Sources*, 412:442–450, Feb. 2019.
- [4] C. Lin, J. Xu, M. Shi, and X. Mei. Constant current charging time based fast state-of-health estimation for lithium-ion batteries. *Energy (Oxf.)*, 247(123556):123556, May2022.
- [5] X. Shu, G. Li, J. Shen, Z. Lei, Z. Chen, and Y. Liu. A uniform estimation framework for state of health of lithium-ion batteries considering feature extraction and parameters optimization. *Energy (Oxf.)*, 204(117957):117957, Aug. 2020.
- [6] D. Yang, X. Zhang, R. Pan, Y. Wang, and Z. Chen. A novel gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve. *J. Power Sources*, 384:387–395, Apr. 2018.
- [7] U. Yayan, A. T. Arslan, and H. Yucel. A novel method for SoH prediction of batteries based on stacked LSTM with quick charge data. *Appl. Artif. Intell.*, 35(6):421–439, May 2021.
- [8] J. Zhu, Y. Wang, Y. Huang, R. Bhushan Gopaluni, Y. Cao, M. Heere, M. J. Mühlbauer, L. Mereacre, H. Dai, X. Liu, A. Senyshyn, X. Wei, M. Knapp, and H. Ehrenberg. Data-driven capacity estimation of commercial lithium-ion batteries from voltage relaxation. *Nat. Commun.*, 13(1):2261, Apr. 2022.