



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

**Mašininio mokymosi pritaikymas ir tyrimas akumuliatorių
ilgaamžiškumo vertinimui**

Baigiamasis magistro projektas

Justina Razukevičiūtė

Projekto autorė

Prof. dr. Robertas Alzbutas

Vadovas

Kaunas, 2020



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Mašininio mokymosi pritaikymas ir tyrimas akumuliatorių ilgaamžiškumo vertinimui

Baigiamasis magistro projektas

Taikomoji matematika (6211AX006)

Justina Razukevičiūtė

Projekto autorė

Prof. dr. Robertas Alzbutas

Vadovas

Lekt. dr. Mindaugas Kavaliauskas

Recenzentas

Kaunas, 2020



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Justina Razukevičiūtė

Mašininio mokymosi pritaikymas ir tyrimas akumuliatorių ilgaamžiškumo vertinimui

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Justinos Razukevičiūtės, baigiamasis projektas tema „Mašininio mokymosi pritaikymas ir tyrimas akumuliatorių ilgaamžiškumo vertinimui“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

(vardą ir pavardę įrašyti ranka)

(parašas)

Turinys

| | |
|---|-----------|
| Įvadas | 11 |
| 1. Literatūros apžvalga | 13 |
| 1.1. Ličio jonų ir kiti akumulatoriai | 13 |
| 1.2. Akumuliatorių ilgaamžiškumas | 14 |
| 1.3. Akumuliatorių valdymo sistema | 15 |
| 1.4. Akumuliatorių valdymo modeliavimas | 15 |
| 1.5. Akumuliatorių vidinių būsenų įvertinimas | 18 |
| 1.5.1. Kalmano filtrai ir dalelių filtrai..... | 20 |
| 1.5.2. Mašininio mokymosi taikymai | 21 |
| 1.6. Parametrai vidinėms būsenoms vertinti..... | 23 |
| 1.7. Literatūros apžvalgos išvados | 24 |
| 2. Tyrimo metodai ir įranga | 25 |
| 2.1. Akumuliatorių būsenų įvertinimas | 25 |
| 2.1.1. Įkrovimo būsenos įvertinimo modelis..... | 25 |
| 2.1.2. Kokybiško veikimo būsenos modelis..... | 26 |
| 2.1.3. Tyrimo rezultatų paklaidų vertinimas | 27 |
| 2.2. Akumuliatorių talpos prognozės metodai | 28 |
| 2.2.1. Gauso proceso regresinis modelis..... | 29 |
| 2.2.2. Vienkryptis neuroninis tinklas | 29 |
| 2.3. Tyrimo metodika ir algoritmo struktūra | 32 |
| 2.4. Taikyta programinė įranga..... | 33 |
| 3. Tyrimo duomenys ir rezultatai | 34 |
| 3.1. Duomenys ir jų analizė | 34 |
| 3.1.1. Tyrimo duomenų struktūra | 34 |
| 3.1.2. Duomenų ir jų kitimo analizė | 35 |
| 3.1.3. Duomenų agregavimas | 37 |
| 3.1.4. Duomenų standartizavimas | 38 |
| 3.1.5. Min-max normalizavimas..... | 39 |
| 3.2. Atskiro akumulatoriaus talpos vertinimas | 40 |
| 3.2.1. Atskiro neuroninio tinklo pritaikymo pavyzdys | 40 |
| 3.2.2. Talpos prognozavimas remiantis vienu parametru | 42 |
| 3.2.3. Talpos prognozavimas remiantis keliais parametrais | 46 |
| 3.3. Akumuliatorių tyrimo rezultatai..... | 49 |
| 3.4. Duomenų paruošimo įtaka rezultatams | 52 |

| | |
|---|-----------|
| 3.5. Neuroninio tinklo architektūros įtaka rezultatams | 53 |
| 3.6. Atliktų tyrimų palyginimas su kitų gautais rezultatais | 54 |
| Išvados | 57 |
| Rekomendacijos..... | 59 |
| Literatūros sąrašas | 60 |
| Priedai..... | 64 |

Paveikslų sąrašas

| | |
|---|----|
| 1 pav. Ličio jonų akumuliatorių veikimo principas. Šaltinis [4]..... | 13 |
| 2 pav. Degradavimo mechanizmo priežasčių ir pasekmių pavyzdys..... | 14 |
| 3 pav. Ličio jonų akumuliatorių modeliavimo tipai..... | 16 |
| 4 pav. Akumulatoriaus ekvivalenčios grandinės modelis. Šaltinis [16]..... | 17 |
| 5 pav. Akumuliatorių vidinių būsenų įverčiams rasti naudojami modeliai..... | 19 |
| 6 pav. Vienkryptis neuroninis tinklas..... | 30 |
| 7 pav. Neuroniniai tinklai su skirtinga architektūra..... | 31 |
| 8 pav. Vienkrypčio neuroninio tinklo pseudokodas..... | 32 |
| 9 pav. Tyrimo metodika ir algoritmo struktūra..... | 33 |
| 10 pav. Tyrime naudoto duomenų failo struktūra..... | 34 |
| 11 pav. Įtampos, srovės ir temperatūros kitimas įkraunant akumuliatorių; Pirmas ir paskutinis ciklai. | 36 |
| 12 pav. Talpos kitimo grafikas visiems akumulatoriams senstant..... | 36 |
| 13 pav. SOH įverčio kitimo grafikas visiems akumulatoriams senstant..... | 37 |
| 14 pav. Duomenų apdorojimo pseudokodas..... | 38 |
| 15 pav. Duomenų standartizavimo pseudokodas..... | 39 |
| 16 pav. Min-max normalizavimo pseudokodas..... | 39 |
| 17 pav. Neuroninio tinklo rezultatų kitimo kreivė apmokymo metu..... | 40 |
| 18 pav. Neuroninio tinklo paklaidų histograma..... | 41 |
| 19 pav. Neuroninio tinklo regresija..... | 42 |
| 20 pav. Talpos prognozė testavimo duomenims, naudojant t ir min-max normalizavimą, (5 akum.)... 43 | 43 |
| 21 pav. Pagrindinės charakteristikos, naudojant t ir min-max normalizavimą, (5 akum.)..... | 43 |
| 22 pav. Talpos prognozė visiems duomenims, naudojant t ir min-max normalizavimą, (5 akum.)..... | 44 |
| 23 pav. SOH prognozė, naudojant t ir min-max normalizavimą, (5 akum.)..... | 45 |
| 24 pav. Pagrindinės charakteristikos, naudojant I ir standartizavimą, (5 akum.)..... | 45 |
| 25 pav. Talpos prognozė (a) ir SOH prognozė (b), naudojant I ir standartizavimą, (5 akum.)..... | 46 |
| 26 pav. Talpos prognozė, naudojant I, V, t ir min-max normalizavimą, (5 akum.)..... | 47 |
| 27 pav. Pagrindinės charakteristikos, naudojant I,V, t ir min-max normalizavimą, (5 akum.)..... | 47 |
| 28 pav. SOH prognozė, naudojant I, V, t ir min-max normalizavimą, (5 akum.)..... | 48 |
| 29 pav. Pagrindinės charakteristikos, naudojant I,V ir standartizavimą, (5 akum.)..... | 48 |
| 30 pav. Talpos prognozė, naudojant I, V ir standartizavimą, (5 akum.)..... | 49 |
| 31 pav. Pagrindinės charakteristikos, naudojant I, t ir standartizavimą, (6 akum)..... | 50 |
| 32 pav. Talpos prognozė testavimo duomenims (a) ir visiems duomenims (b), naudojant I, t ir standartizavimą, (6 akum.)..... | 51 |
| 33 pav. Pagrindinės charakteristikos, naudojant I, t ir standartizavimą, (7 akum.)..... | 51 |
| 34 pav. Vidutinių MAE ir RMSE paklaidų, pagal neuroninio tinklo tipą, grafikas..... | 54 |
| 35 pav. Gauso proceso regresijos modeliu gautų MAE ir RMSE paklaidų grafikas. Šaltinis [13]..... | 56 |

Lentelių sąrašas

| | |
|---|----|
| 1 lentelė. Penktojo akumulatoriaus talpos prognozių paklaidos, vertinant pagal vieną parametą... | 42 |
| 2 lentelė. Penktojo akumulatoriaus talpos prognozių paklaidos, vertinant pagal kelis parametrus.. | 46 |
| 3 lentelė. Talpos prognozių paklaidų rezultatai | 50 |
| 4 lentelė. Rangų lentelės santrauka, tinkamiausiems prognozei parametrą rasti..... | 52 |
| 5 lentelė. Rangų lentelės santrauka, geriausia duomenų paruošimo metodui rasti..... | 52 |
| 6 lentelė. Rangų lentelės santrauka, efektyvesniam neuroniniam tinklui rasti | 53 |
| 7 lentelė. Vidutinės MAE ir RMSE paklaidos pagal neuroninio tinklo tipą, naudojant min-max normalizavimą..... | 54 |
| 8 lentelė. Vidutinės MAE ir RMSE paklaidos, gautos 2019 metais atliktame tyrime [6]..... | 55 |

Santrumpos

AEKF – adaptyvus išplėstinis Kalmano filtras (angl. *Adaptive Extended Kalman Filter*),
AF - adaptyvus filtras (angl. *Adaptive Filter*),
ANN - dirbtinis neuroninis tinklas (angl. *Artificial Neural Network*),
BMS - akumuliatorių valdymo sistema (angl. *Battery Management System*),
DNN - gilusis neuroninis tinklas (angl. *Deep Neural Network*),
EIS - elektrocheminės varžos spektroskopija (angl. *Electrochemical Impedance Spectroscopy*),
EKF - išplėstinis Kalmano filtras (angl. *Extended Kalman Filter*),
EOL – veikimo pabaigos būseną (angl. *End-of-Life*),
FES - funkcijos išraiška balais (angl. *Feature Expression Scoring*),
FNN - vienkryptis neuroninis tinklas (angl. *Feedforward Network*),
GA – genetinis algoritmas (angl. *Genetic Algorithm*),
GPR - Gauso proceso regresija (angl. *Gaussian Process Regression*),
 $H_{\infty}F$ - H begalins filtras (angl. *H Infinite Filter*),
IC - papildomos talpos kreivė (angl. *Incremental Capacity Curve*),
KF - Kalmano filtras (angl. *Kalman Filter*),
LR - tiesinė regresija (angl. *Linear Regression*),
LS – mažiausių kvadratų metodas (angl. *Least Squares Method*),
NN – neuroninis tinklas (angl. *Neural Network*),
MAE – vidutinė absoliutinė paklaida (angl. *Mean Average Error*),
ME – didžiausia paklaida (angl. *Maximum Error*),
OCV - atviros grandinės įtampa (angl. *Open Circuit Voltage*),
OFCL - išorinis grįžtamojo ryšio korekcijos ciklas (angl. *Outer Feedback Correction Loop*),
PF - dalelių filtras (angl. *Particle Filter*),
PSO - dalelių spiečiaus optimizavimas (angl. *Particle Swarm Optimization*),
RLS - rekursinis mažiausių kvadratų metodas (angl. *Recursive Least Square*),
RMSE - vidutinė kvadratinė paklaida (angl. *Root Mean Square Error*),
RUL – likusio gyvavimo laiko būseną (angl. *Remaining Useful Life*),
SOC - įkrovos būseną (angl. *State of Charge*),
SOH - kokybiško veikimo būseną (angl. *State of Health*),
SOL - gyvavimo būseną (angl. *State of Life*),
SPKF - sigma taško Kalmano filtras (angl. *Sigma Point Kalman Filter*),
SVM – atraminių vektorių metodas (angl. *Support Vector Machine*),
UKF - netiesinis Kalmano filtras (angl. *Unscented Kalman Filter*).

Razukevičiūtė Justina. Mašininio mokymosi pritaikymas ir tyrimas akumuliatorių ilgaamžiškumo vertinimui. Magistro baigiamasis projektas / vadovas prof. dr. Robertas Alzbutas; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Taikomoji matematika (A02), Matematika (N001).

Reikšminiai žodžiai: akumuliatorių valdymo sistema, kokybiško veikimo būseną, vienkryptis neuroninis tinklas, akumuliatorių ilgaamžiškumas.

Kaunas, 2020. 63 p.

Santrauka

Baigiamojo projekto metu buvo sudarytas ličio jonų akumuliatorių talpos prognostinis modelis, kuris leidžia įvertinti akumuliatoriaus kokybiško veikimo būseną (SOH). Modeliavimui buvo naudojami trys vidiniai akumuliatorių parametrai bei jų kombinacijos, du duomenų apdorojimo metodai ir vienkryptis neuroninis tinklas su skirtinga architektūra. Realizuotų modelių tikslumui vertinti, buvo apskaičiuojamos vidutinės absoliutinės (MAE) ir vidutinės kvadratinės (RMSE) paklaidos. Išanalizavus gautus rezultatus buvo nustatyta, kad duomenų paruošimo metodai ir neuroninių tinklų architektūra turi įtakos rezultatų tikslumui. Neatsižvelgiant į vidinių parametru įtaką prognostiniam modeliui, buvo gauta, kad talpos prognozavimui yra tinkamesnis vienkryptis neuroninis tinklas turintis dešimt neuronų paslėptajame sluoksnyje, o duomenų apdorojimui tikslingiausia naudoti min-max normalizavimą. Atlikus akumuliatorių vidinių parametru įtakos analizę akumuliatoriaus talpos prognozei, nustatyta, kad vertinant paklaidas pagal MAE, tikslingiausia į prognostinį modelį įtraukti akumuliatoriaus įtampos ir temperatūros vidinius parametrus. Pritaikius tokį modelį turimiems duomenimis vidutinė MAE paklaida buvo gauta lygi 0,0227 Ah, t. y. apie 0,9 %. Palyginus tyrimo metu sukurtą prognostinį modelį su kitų atliktais tyrimais, buvo nustatyta, kad šio modelio talpos prognozių paklaidos yra mažesnės nei ankstesniuose tyrimuose, todėl gaunamos kokybiško veikimo būsenos labiau atspindi realybėje galimas reikšmes. Šio modelio detalesnis tyrimas ir taikymas ateityje, galėtų stipriai prisidėti prie tikslesnio akumuliatorių ilgaamžiškumo vertinimo ir akumuliatorių valdymo sistemų tobulinimo.

Razukevičiūtė Justina. Application and research of machine learning for the estimation of battery lifetime. Master's Final Degree Project / supervisor assoc. prof. dr. Robertas Alzbutas; Faculty of Mathematics and natural science, Kaunas University of Technology.

Study field and area (study field group): Applied Mathematics (A02), Mathematica (N001).

Keywords: Battery Management System, State of health, Feedforward Neural Network, Battery life.

Kaunas, 2020. 63pages.

Summary

The prognostic model of lithium-ion batteries capacity is designed during the final project work. This model lets to estimate one of the battery management system state – state of health (SOH). Three internal battery variables and their combinations, two data processing methods, and a feedforward neural network with different architecture were used for modelling. To evaluate the accuracy of the implemented models, the mean average error (MAE) and root mean square error (RMSE) were calculated. After analysing the obtained results, it was found out that the data preparation methods and neural network architecture make a strong impact on the accuracy of the results. Irrespective of the influence of internal parameters on the prognostic model, it was found that a feedforward neural network with ten neurons in the hidden layer is more suitable for capacity prediction, and min-max normalization would be most appropriate for data processing. After the analysis of the influence of the internal variables for battery capacity prognosis, it was found that estimating the errors according to the MAE, it is most appropriate to include the internal variables of the voltage and temperature to the prognostic model. Applying such a model to the available data, the mean of MAE was 0,022 Ah, this is about 0,9%. Comparing the prognostic model developed in this work with the studies performed by others, it was found that the errors of the capacity predictions of this model are smaller than in previous studies, therefore the obtained state of health performance states better reflect the possible values in reality. A more detailed study and application of this model in the future could contribute to a more accurate assessment of the battery lifetime and enhancement of the battery management system.

Ivadas

Akumulatoriai yra pagrindiniai elektrinių ir elektroninių sistemų, tokių kaip mobilieji telefonai ar elektromobiliai, energijos šaltiniai. Ličio jonų akumulatoriai pasižymi dideliu energijos ir galios tankiu, ilgu tarnavimo laiku bei ekologiškumu. Tinkamai suprojektuota akumuliatorių valdymo sistema yra didžiausias garantas, kad tokie akumulatoriai veiks saugiai, patikimai ir optimaliai. Pagrindiniai akumuliatorių valdymo sistemos parametrai yra įkrovimo ir kokybiško veikimo būsenos. Deja, tokie parametrai yra sunkiai išmatuojami realiu laiku, todėl jų kitimą laike tenka stebėti naudojant tinkamus įvertinimo metodus: įvairias filtracijas, būsenų stebėjimo ar mašininio mokymosi metodus.

Šiame darbe yra realizuotas mašininio mokymosi metodas, kuris padeda atlikti akumuliatorių talpos prognozę, bei apskaičiuoti kokybiško veikimo būseną. Įprastai akumuliatorių talpos prognostinis modelis yra sudaromas pagal kurį nors vieną, realiu laiku išmatuojamą, vidinį parametą. Šiame darbe yra atliktas akumulatoriaus talpos prognozavimas remiantis tiek vienu, tiek ir keliais parametrais.

Darbo tikslas – pritaikius mašininį mokymąsi, iširti ličio jonų akumuliatorių ilgaamžiškumą, vidinių parametų įtaką talpos prognostiniam modeliui ir nustatyti rezultatų tikslumą.

Tiksłams įgyvendinti užsibrėžti šie uždaviniai:

1. Apžvelgti su akumuliatorių valdymo sistema ir jų ilgaamžiškumo problematika susijusią literatūrą bei metodus.
2. Realizuoti pasirinktą mašininio mokymosi metodą ir išanalizuoti prognostinio modelio kintamųjų įtaką prognozei.
3. Išanalizuoti duomenų apdorojimui naudojamų metodų (pvz. min-max normalizavimo) įtaką prognozės rezultatams.
4. Išanalizuoti tyrimui sudaryto mašininio mokymosi architektūros (pvz. neuronų skaičiaus) įtaką rezultatams.
5. Palyginti atliktų talpos prognozių paklaidas su kitų atliktų tyrimų paklaidomis.

Tyrimo metu naudojami keturių ličio jonų akumuliatorių iškrovimo duomenys. Siekiant palyginti gautus rezultatus, yra apskaičiuojamos vidutinės prognozės absoliutinės ir kvadratinės paklaidos. Geriausio prognozės varianto radimui yra atliekamos mašininio mokymosi architektūros, duomenų paruošimo, bei atitinkamų parametų įtraukimo į prognostinį modelį analizės.

Šio darbo struktūra išdėstyta taip: pirmame skyriuje apžvelgiami ličio jonų akumulatoriai, jų valdymo sistema ir literatūroje pristatomi metodai, skirti akumulatoriaus vidinių būsenų prognozavimui. Antrame skyriuje apibūdinamos vidinės akumuliatorių būsenos, tyrime naudoti prognozės metodai ir

tyrimo algoritmo struktūra. Trečiajame skyriuje aptariami gauti rezultatai ir jų palyginimas su kitų atliktais tyrimais. Išvadose pateikiami esminiai pastebėjimai, gauti atlikus tyrimą.


1. Literatūros apžvalga

1.1. Ličio jonų ir kiti akumuliatoriai

Šiuo metu rinkoje yra paplitę keturios akumuliatorių rūšys. Pirmoji - nikelio kadmio (NiCd) akumuliatoriai. Jie yra naudojami ten, kur svarbus ilgas tarnavimo laikas, didelis iškrovos greitis ir nedidelė kaina. Pagrindinis jų trūkumas- mažas energijos tankis, o taip pat dėl savyje esančių nuodingų metalų, jie yra laikomi ne ekologiškais. Nikelio - metalo hibridiniai (NiMH) akumuliatoriai turi šiek tiek didesnę energijos tankį, tačiau trumpesnį gyvavimo ciklą, lyginant su NiCd akumuliatoriais. Švino rūgšties akumuliatoriai yra ekonomiškiausi, kai yra reikalinga didesnė galia ir nerūpi akumuliatoriaus svoris. Ketvirtoji akumuliatorių rūšis yra ličio jonų (angl. *Lithium-ion*).

Ličio jonų akumuliatoriai yra pasirenkami kaip galingi energijos šaltiniai daugelyje elektros energiją naudojančių sistemų nuo tada, kai jie pirmą kartą buvo pristatyti rinkai 1990 metais. Lyginant su tradiciniais, tokiais kaip NiMH, ličio jonų akumuliatoriai yra daug lengvesni, turintys didesnę galios tankį ir ilgesnę gyvenimo trukmę. Šiomis dienomis ličio jonų akumuliatoriai yra plačiai naudojami nešiojamiems prietaisams, jūrų laivynų sistemoms, elektriniams automobiliams, aviacijos ir kitoms sistemoms.

Ličio jonų akumuliatoriai susideda iš trijų komponentų: anodo, katodo ir elektrolitų [17]. Katodas (pozityvus elektrodas) – tai koks nors metalo oksidas, o anodas (neigiamas elektrodas) – sudarytas iš porėtosios anglies. Esant akumuliatoriaus iškrovimo procesui, jonai skrieja nuo anodo link katodo per elektrolitų sluoksnį. Esant akumuliatoriaus įkrovimo procesui, jonų srautas yra priešingas – per elektrolitų sluoksnį, jie keliauja nuo katodo link anodo [4]. Procesą iliustracija pateikta pirmame paveiksle (žr. 1 pav.).



1 pav. Ličio jonų akumuliatorių veikimo principas. Šaltinis [4]

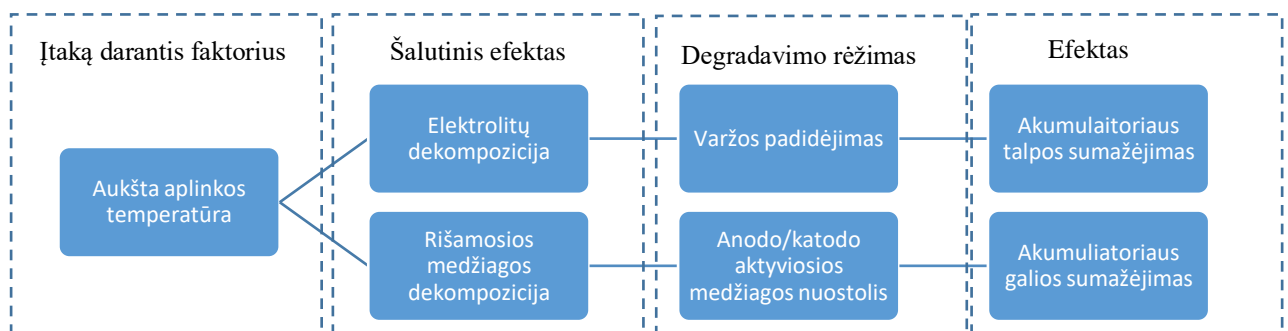
Akumuliatorių saugumas ir patikimumas realiose situacijose yra kritiniai sistemos veikimo faktoriai, kurių nesėkmė veda ne tik prie veikimo degradacijos, taisymo išlaidų ir nepatogumų, bet ir gali sukelti katastrofinių nelaimių dėl perkaitimo ar trumpojo jungimo. Todėl efektingas tokių akumuliatorių stebėjimas ir prognozavimas sulaukia labai daug dėmesio ir yra siekiama, kad jų valdymo sistema (angl. *Battery management system*, BMS) būtų kuo patikimesnė ir efektyvesnė [31].

1.2. Akumuliatorių ilgaamžiškumas

Ličio jonų akumuliatorių ilgaamžiškumas priklauso tiek nuo išorinių veiksnių, tiek ir nuo vidinių akumulatoriaus parametrų. Visus akumulatoriaus senėjimui įtaką darančius veiksnius galima suskirstyti į tris grupes, pagal jo projektavimo, gaminimo ir naudojimo etapus:

- Akumulatoriaus projektavimas. Šiai sričiai priskiriami tokie senėjimą skatinantys veiksniai, kurie susiję su pačiu akumulatoriaus projektavimu. Tai galėtų būti susiję su celių projektavimu (pavyzdžiui: medžiagos, iš kurios pagamintas anodas, katodas ar elektrolitai, pasirinkimas) arba viso akumulatoriaus projektavimu (pavyzdžiui, aušinimo sistemos pasirinkimas).
- Akumulatoriaus gaminimas. Šiai sričiai priskiriami veiksniai susiję su pačiu akumulatoriaus gaminimo procesu. Tai galėtų būti tiek išoriniai veiksniai, pavyzdžiui, gamybos linijoje esantis drėgmingumo lygis, tiek ir vidiniai veiksniai, pavyzdžiui, elektrolitų užpildymo į celes metodas.
- Akumulatoriaus naudojimas. Šiai sričiai priskiriami tokie veiksniai: aukšta arba žema aplinkos temperatūra, darbinė apkrova, aukšta ar žema įtampa.

Visi šie veiksniai trumpina akumulatoriaus veikimo laiką ir sukelia tam tikras šalutines reakcijas, kurios vėliau atsispindi degradavimo režimuose ir galiausiai paveikia patį akumuliatorių. Pavyzdžiui, aukšta aplinkos temperatūra turi įtakos akumulatoriaus rišamosios medžiagos ir elektrolitų dekompozicijai. Toks šalutinis rišamosios medžiagos dekompozicijos efektas atsispindi degradavimo režimuose, tokiuose kaip anodo/katodo aktyvios medžiagos nuostolis ir varžos padidėjimas [30]. Šie du degradavimo režimai sukelia akumulatoriaus talpos ir galios sumažėjimą (žr. 2 pav.).



2 pav. Degradavimo mechanizmo priežasčių ir pasekmių pavyzdys

Dažniausiai, akumulatoriai yra laikomi su pasibaigusia gyvavimo trukme tada, kai jų talpa nukrinta iki 80 % pradinės talpos. Iš tikrųjų akumulatoriaus gyvavimo trukmė gali būti suskirstyta į dvi dalis: kalendorinis gyvavimas ir ciklinis gyvavimas. Kalendorinis gyvavimas susijęs su akumulatoriaus degradavimu, kai talpa mažėja be ciklų, o ciklinis gyvavimas susijęs su nusidėvėjimu, sukeltu dėl įkrovimo ir iškrovimo ciklų [30].

Iš tikrųjų, ličio jonų akumulatoriai yra labai sudėtinga sistema, turinti daugybę senėjimui įtaką darančių veiksnių, o visų šių veiksnių įvertinimas yra labai sudėtingas procesas, kurio sprendimams rasti yra pasitelkiami dideli resursai. Daugybėje straipsnių yra tyrinėjama, kaip įvertinti visas senėjimui įtaką darančias aplinkybes ir sukurti patikimą akumuliatorių. Pavyzdžiui, trys prancūzų mokslininkai dar 2004 metais pristatė išsamų straipsnį apie ličio jonų akumuliatorių senėjimą [21].

1.3. Akumuliatorių valdymo sistema

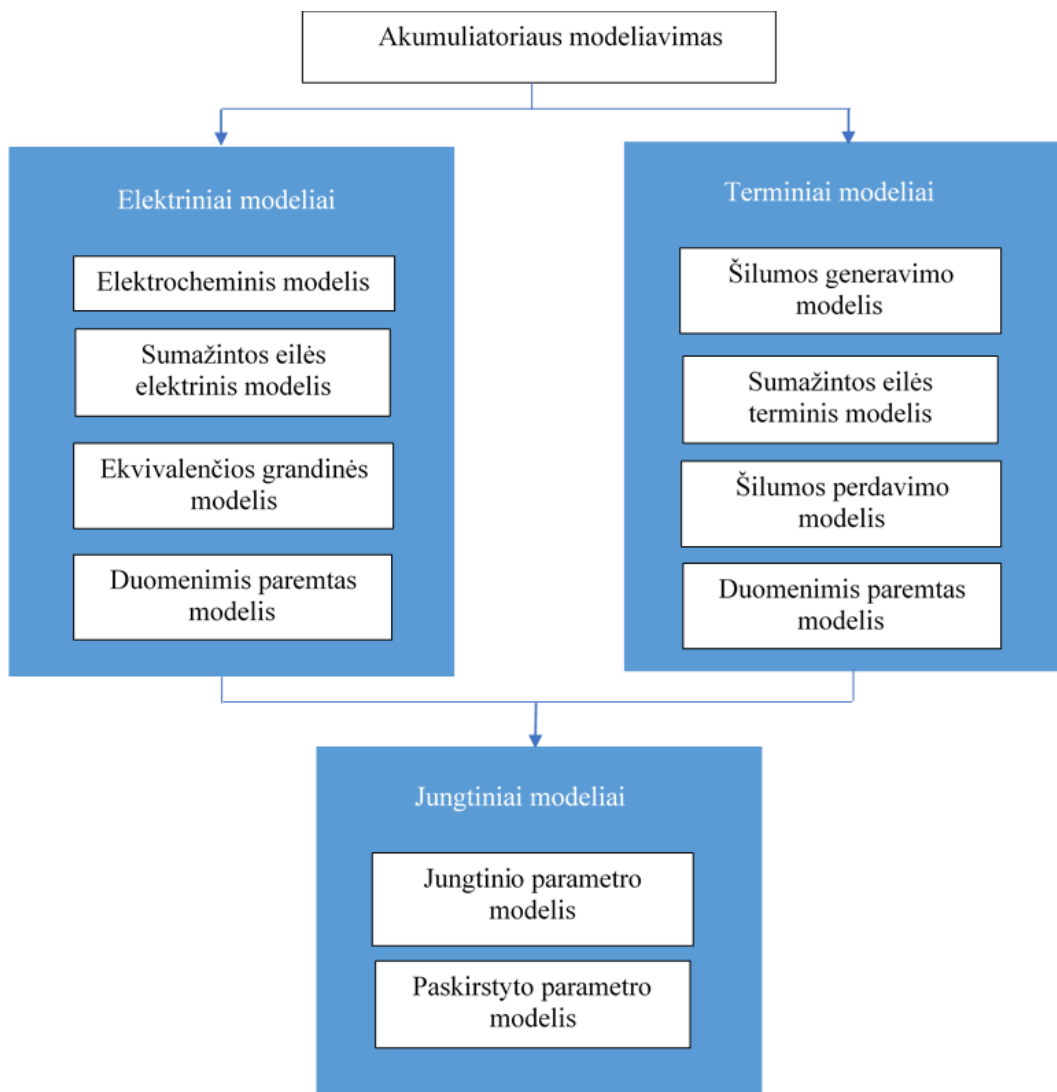
Akumuliatorių valdymo sistema (BMS) yra itin svarbi, norint užtikrinti akumuliatorių veikimo kokybę ir saugumą. Pagrindiniai BMS iššūkiai yra akumulatoriaus modeliavimas, vidinių būsenų įvertinimas ir akumulatoriaus įkrovimo metodo pasirinkimas. Efektyvus akumulatoriaus modelio sudarymas yra esminė dalis akumuliatorių elgesio analizėje, būsenų stebėjime, realaus laiko kontrolės kūrime, temperatūros valdyje ir klaidų diagnozėje. Be to, kai kurios akumulatoriaus vidinės būsenos, kurios vaidina svarbų vaidmenį valdant akumuliatorių veikimą, tokios kaip įkrovos būsena (angl. *State of charge*, SOC) ar kokybiško veikimo būsena (angl. *State of health*, SOH), negali būti išmatuotos tiesiogiai, todėl jas reikia stebėti naudojant tinkamus įvertinimo metodus. Akumuliatorių įkrovimas taip pat turi didelę reikšmę BMS sistemai, nes jis daro tiesioginį poveikį akumulatoriaus eksploatavimo saugai ir aptarnavimo galimybėms. Gerai parengta įkrovimo strategija apsaugo akumulatorius nuo pažeidimų, ribojamos temperatūros svyravimų, taip pat pagerina energijos konvertavimo efektyvumą. Lėtas įkrovimas turi neigiamos įtakos prietaiso naudojimui, tačiau per greitas įkrovimas gali sukelti didelius energijos nuostolius ir akumulatoriaus temperatūros pakilimą. Didelis temperatūros svyravimas sukelia greitesnį akumulatoriaus senėjimą, perkaitimą arba per didelį atvėsimą, kuris galiausiai sutrumpina akumulatoriaus gyvavimo laiką [16].

1.4. Akumuliatorių valdymo modeliavimas

Sukonstruoti tinkamą modelį, dažniausiai yra pradinė ir pagrindinė užduotis, kuriant BMS. Bėgant metams, buvo sukurta daugybė akumuliatorių modelių su įvairiais tikslumo lygiais ir kompleksiskumu. Šiuos modelius galima sugrupuoti į tris tipus (žr. 3 pav.):

- elektrinius,
- terminius,
- jungtinius.

Kitos modelių rūšys, tokios kaip akumuliatoriaus kinetiniai modeliai, kuriant BMS yra naudojamos labai retai [16].




3 pav. Ličio jonų akumuliatorių modeliavimo tipai

Elektriniai modeliai dažniausiai susideda iš elektrocheminių, sumažintos eilės, ekvivalenčios grandinės ir duomenimis paremtų modelių. Elektrocheminiai modeliai turi galimybę užfiksuoti akumuliatoriaus koncentracijos kitimą, elektrodo potencinę ir kinetinę energijas kiekvienoje fazėje, kad būtų

kontroliuojama interkalicijos¹ reakcija. Tuomet sudaromas elektrocheminis modelis, apibūdinantis akumulatoriaus elektrocheminį elgesį, naudojant dalelių spiečiaus metodą (angl. *Particle Swarm Optimization*, PSO), kurio tikslas optimizuoti kritinius modelio parametrus [16]. Pietų Korėjos universiteto mokslininkai W. Sung'as ir C. B. Shin'as [24] savo tyrime parodė, kad elektrocheminis modelis pateikia labai tikslias prognozes, tačiau turi reikšmingai didelių skaičiavimo sąnaudų modeliuojant algoritmą. Švedijos universiteto doktorantas C. Zou'sas ir kiti, 2016 metais pristatė sumažintos eilės elektrocheminį modelį [32], kurio pagalba prognozavo išsikrovimo metu akumulatoriaus talpą esant įvairioms sąlygoms. Nors šis tyrimas lemia tam tikrą informacijos praradimą, jis leidžia efektyviau atlikti tyrimą naudojant baterijas realiu laiku. Skaičiavimo apimtys tampa daug mažesnės, naudojant sumažintos eilės modelį, o atitinkamus parametrus galima atpažinti pagal išmatuotus srovės ir įtampos signalus.

Ekvivalenčios grandinės modeliuose, akumuliatorių elektrinės savybės yra užfiksuojamos vertinant grandinės komponentus, tokius kaip varža, talpa, srovės šaltinis. Dėl paprastos modelio struktūros ir ženkliai mažesnio modelio parametrų skaičiaus, šis metodas yra plačiai taikomas akumuliatorių realaus laiko tyrimuose. Tipinis akumulatoriaus ekvivalenčios grandinės modelis pavaizduotas ketvirtame paveiksle (žr. 4 pav.).



4 pav. Akumulatoriaus ekvivalenčios grandinės modelis. Šaltinis [16]

Duomenimis paremtais modeliais stengiamasi užfiksuoti ryšį tarp įėjimo ir išėjimo signalų. Tokių metodų tikslumas stipriai priklauso nuo testavimo duomenų, nes dažniausiai naudojami metodai, tokie kaip neuroniniai tinklai ar atraminiai vektoriai yra apmokomi naudojant būtent testavimo duomenis.

¹ Interkalicija - (lot. intercalatio - tarpas, priedas; sk. interkal'acija): chem. atomų, molekulių įsiterpimas į kitą medžiagą nekeičiant arba mažai keičiant jos struktūrą [14].

Tam, kad būtų pasiektas priimtinas modelio tikslumas ir lengvas realizavimas, bandymų duomenys turi turėti pakankamai didelį akumulatoriaus operacijų bei parametrų skaičių.

Terminis akumulatoriaus elgesys, toks kaip temperatūros kitimas, taip pat yra labai svarbus aspektas BMS sistemoje, nes temperatūra yra vienas iš svarbiausių veiksnių, stebint akumulatoriaus veikimo kokybę ir trukmę. Todėl yra naudojami įvairūs modeliai, kurie analizuoja terminę akumulatoriaus kaitą:

- šilumos generavimo modelis,
- šilumos perdavimo modelis,
- sumažintos eilės terminis modelis,
- duomenimis paremtas modelis.

Šilumos generavimo modelyje yra daugybė variantų apibūdinti šilumos generavimą, pavyzdžiui, ją išreiškiant aktyvacija, koncentracija ar omniais nuostoliais. Tuo tarpu, šilumos perdavimo modeliuose temperatūros gradientas yra vertinamas vienoje kryptyje. Tokio metodo panaudojimo išlaidos dažniausiai yra per didelės norint taikyti juos realaus laiko matavimams. Todėl šį metodą reikia rinktis netiesioginiam modeliavimui. Akumuliatorių sumažintos eilės terminis modelis buvo sukurtas, kad būtų pagerintas jų terminis valdymas.

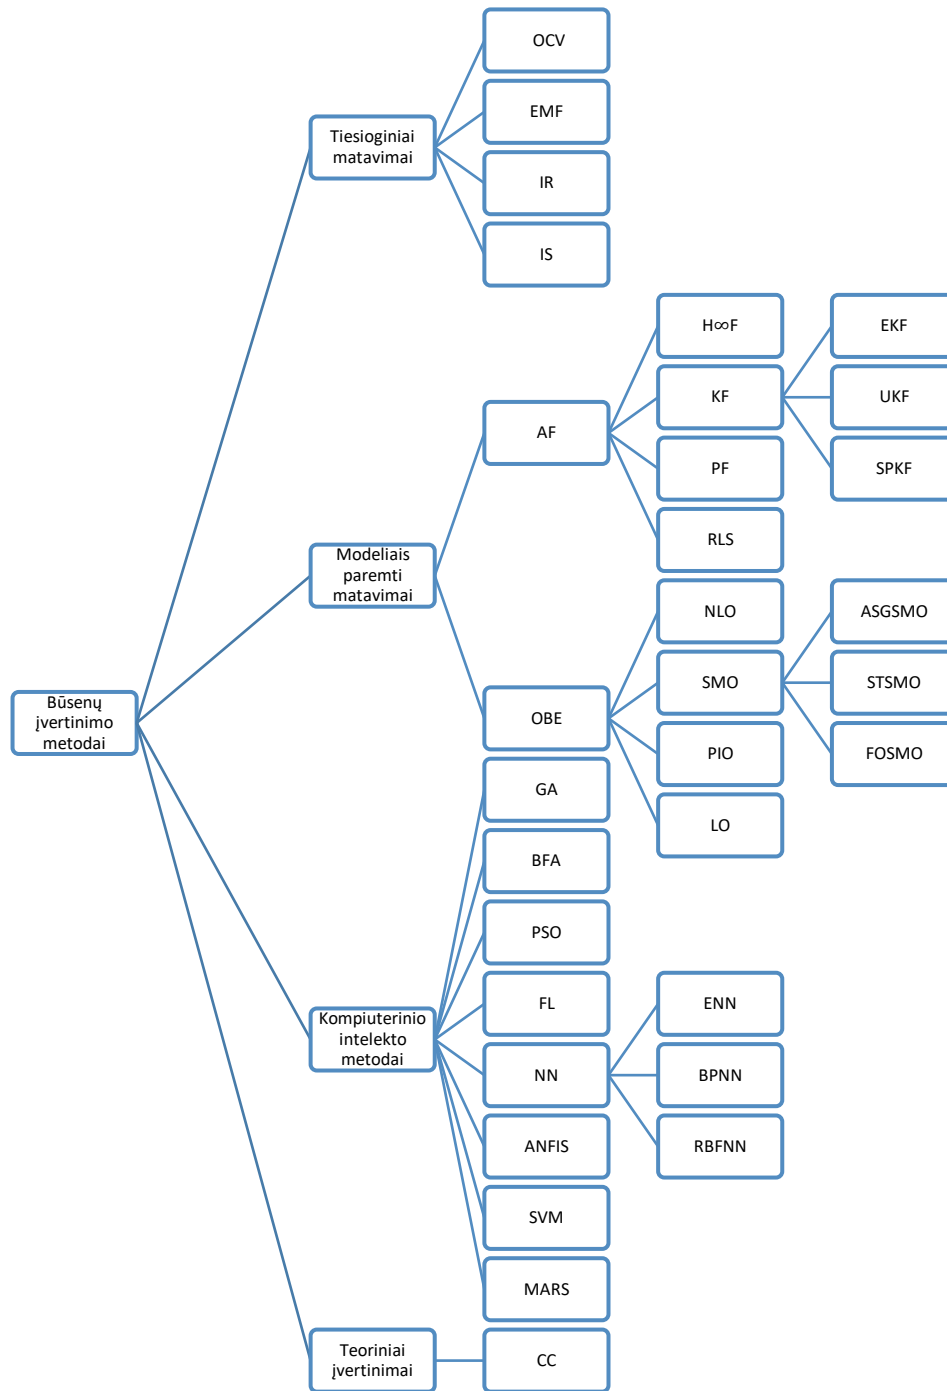
Yra nustatytas stiprus ryšys tarp akumulatoriaus elektrinių ir terminių savybių. Tam, kad būtų įvertintos elektrinės akumulatoriaus savybės (tokios kaip įtampa, srovė, SOC) ir terminės savybės (tokios kaip paviršiaus ir vidinė temperatūra) tuo pačiu metu, buvo sukurti keli jungtiniai modeliai:

- jungtinio parametro modelis (angl. *lump-parameter model*),
- paskirstyto parametro modelis.

Įveikus pirmojo etapo sunkumus ir sukūrus patikimą akumulatoriaus modelį, kuriant BMS toliau atliekamas akumuliatorių vidinių būsenų vertinimas.

1.5. Akumuliatorių vidinių būsenų įvertinimas

Pagrindinės ir dažniausiai akumuliatorių valdymo sistemoje vertinamos yra įkrovos (SOC) ir kokybiško veikimo (SOH) būsenos. SOC apibūdina trumpo laikotarpio esamų parametrų pasikeitimus, o SOH – ilgo laikotarpio.



5 pav. Akumuliatorių vidinių būsenų įverčiams rasti naudojami modeliai

Kadangi šios būsenos negali būti matuojamos realiu laiku, joms vertinti yra naudojama daugybė skirtingų metodų, o pagrindiniai iš jų yra:

- Adaptyvūs filtrai (angl. *adaptive filters*, AF),
- H begaliniai filtrai (angl. *H infinite filters*, $H_{\infty}F$),
- Kalmano filtrai (angl. *Kalman filters*, KF),
- Išplėstiniai Kalmano filtrai (angl. *Extended Kalman filters*, EKF),

- Netiesiniai Kalmano filtrai (angl. *Unscented Kalman filters*, UKF),
- Sigma taško Kalmano filtrai (angl. *Sigma point Kalman filters*, SPKF),
- Dalelių filtrai (angl. *Particle filters*, PF),
- Rekursinis mažiausių kvadratų metodas (angl. *Recursive Least Square*, RLS),
- Stebėtojais paremti įverčiai (angl. *Observer-based estimation*). Tokiais metodais laikomi netiesinio stebėtojo metodas (angl. *Non-linear observer*), Stumdomo režimo stebėtojo metodas (angl. *Sliding mode observer*) ir kiti,
- Kompiuteriniu intelektu pagrįsti metodai. Tai galėtų būti genetiniai algoritmai (angl. *Genetic Algorithm*, GA), PSO, Neuroniniai tinklai (angl. *Neural Network*, NN), atraminių vektorių metodas (angl. *Support Vector Machine*, SVM) ir kiti [16].

Tiesa, kol kas nėra sutariama, kuris iš jų yra tiksliausias, ieškant šių būsenų įverčių, todėl literatūroje yra gana platus spektras tyrimų su skirtingomis metodų realizacijomis. Visi modeliai naudojami būsenų įverčiams rasti yra pateikti penktame paveiksle (žr. 5 pav.).

1.5.1. Kalmano filtrai ir dalelių filtrai

Vienas iš SOC tyrimų buvo atliktas šešių Čilės mokslininkų 2015 metais [25]. Savo darbe jie įvertino SOC bei prognozavo ličio jonų baterijų išsikrovimo laiką. Tyrimas buvo atliktas naudojant klasikinį dalelių filtrą (PF) ir netiesinę Kalmano filtraciją (UKF) bei sujungiant juos su išoriniais grįžtamojo ryšio korekcijos ciklais (angl. *Outer Feedback Correction Loops*, OFCL). Atlikus tyrimą, buvo nustatyta, kad taikyti algoritmai yra efektingesni sujungus juos su OFCL. UKF be OFCL generavo labai prastus rezultatus, tačiau prijungus OFCL, rezultatai tapo net geresni už PF rezultatus. Taip pat reikia paminėti, kad taikant OFCL, procesai ir, idealiu atveju, stebėjimų triukšmas turi būti pakankamai maži arba mažėti OFCL proceso metu. Buvo padaryta išvada, kad UKF + OFCL metodo rezultatai yra geriausios kokybės ir gaunami per trumpiausią laiką.

Dar vienas tyrimas, naudojant Kalmano filtrus, buvo atliktas 2016 metais, kai Iliojaus universiteto darbuotojas S. Al-Hallajus bei dar trys jo kolegos publikavo straipsnį, kuriame pristatė pažangų SOC ir SOH vertinimo metodą elektrinių dviračių akumulatoriams vertinti [2]. Tyrimo metu buvo nustatytas ir patvirtintas ličio jonų akumuliatorių būsenų erdvės modelis. SOC įvertinimo problema buvo išspręsta naudojant EKF ir adaptyviają EKF versiją (angl. *Adaptive Extended Kalman filter*, AEKF). Šie algoritmai buvo pritaikyti ir ištestuoti su modeliavimo bei bandymų duomenimis, o rezultatai buvo palyginti. Gauti rezultatai parodė, kad EKF metodo įverčio paklaida yra apie 5 %, kai tuo tarpu AEKF generuoja tik apie 1 % paklaidą. Taip pat buvo pritaikytas mažiausių kvadratų metodas (angl. *Least squares method*, LS), įvertinant akumulatoriaus gyvavimo ciklo talpą bei gautas jungtinis SOC ir SOH

įvertinimo būdas, kai senėjimo parametrai yra vertinami kartu su SOC. 2018 metais buvo atliktas kitas tyrimas, kuriame buvo pristatytas naujas ličio jonų baterijų SOC ir SOH vertinimo metodas, atsižvelgiantis į šalutines reakcijas [8]. SOC įvertinimas pateikiamas įtraukiant ir ECM kartu su elektrocheminėmis savybėmis. Pritaikytame modelyje buvo daroma prielaida, kad akumulatoriaus interkaliacijos proceso metu pirminis senėjimo faktorius yra anodo šalutinė reakcija. Tam, kad būtų galima sujungti ECM ir SOC įverčius, buvo naudojama OCV ir SOH koreliacija. Buvo nustatyta, kad būsenos įverčio rezultatai tenkino leistinos srities specifikaciją ir buvo geresni, lyginant juos su metodu, kuris nevertina senėjimo. Todėl buvo daroma išvada, kad SOC ir SOH įverčių radimas, įtraukiant šalutines reakcijas, prijungtas OCV metodu, yra gana tikslus metodas vertinant akumulatoriaus būsenas.

1.5.2. Mašininio mokymosi taikymai

Vienas iš mašininio mokymosi metodų naudojamų BMS įverčiams rasti yra Gauso proceso regresinis modelis (angl. *Gaussian Process Regression*, GPR). Tokio metodo panaudojimas įvertinant SOH buvo atliktas 2019 metais *Pekino technologijų institute* (angl. *Beijing Institute of Technology*) [13]. Tyrimui atlikti buvo naudojami NASA duomenų bazėje [18] esantys duomenys apie ličio jonų akumuliatorių iškrovimo ir įkrovimo būsenas. Tyrimo metu buvo pristatytas Bajeso neparаметrinis modelis SOH įverčiui rasti, remiantis gyvybingumo indeksais, gautais iš dalies įkrauto akumulatoriaus papildomos talpos kreivės (angl. *Incremental Capacity Curve*, IC). Pasiūlyto GPR parento metodo privalumas yra didelis tikslumas ir robusiškumas, tačiau pagrindinis trūkumas yra ribotas tinkamumas kitokio tipo duomenims dėl skirtingų IC kreivių. Taip pat tyrimo metu buvo parodyta, kad pasiūlyto metodo maksimali RMSE paklaida buvo gauta 1,1 %, kai tuo tarpu minimali tik 0,68 %.

SOH įverčiams rasti vis dažniau yra naudojami ir dirbtinio intelekto modeliai. Jau 2018 metais Kinijoje buvo atliktas SOH įverčio radimas, remiantis mašininio mokymosi metodais [29]. Tyrimui buvo naudoti tie patys NASA duomenų bazės duomenys bei pateikti *regresijos medžio* (angl. *Regression Tree*) bei *atsitiktinio miško* (angl. *Random Forest*) metodai. Atlikus tyrimą buvo gauta, kad MAE *regresijos medžio* modelyje yra 0,0006, kai tuo tarpu *atsitiktinio miško* modelio atveju 0,0002. Taigi, buvo nustatyta, kad abiejų metodų rezultatai yra labai tikslūs, tačiau *atsitiktinio miško* metodo rezultatai yra šiek tiek geresni.

Ši NASA duomenų aibė labai populiari atliekant tyrimus ir dažnai naudojama metodų realizacijai. Ji buvo naudojama ir 2019 metais išleistame straipsnyje, pristatant *giliojo mokymosi algoritmą* (angl. *Deep Learning Algorithm*) SOH vertinimui [11]. Tyrimo metu buvo pristatytas gilusis neuroninis tinklas (angl. *Deep Neural Network*, DNN), kurio rezultatai buvo lyginami su įvairiais mašininio mokymosi metodais, tokiais kaip SVM, k-artimiausio kaimyno (angl. *K-nearest Neighbors*), dirbtinio neuroninio tinklo (angl. *Artificial Neural Network*, ANN) ir tiesine regresija (angl. *Linear Regression*, LR). Tyrimo metu buvo

parodyta, kad duomenimis paremti metodai turi daugiau privalumų, lyginant su paprastais fizika paremtais metodais. Jie yra ne tokie sudėtingi, o tai leidžia sumažinti tam tikrų sričių ekspertų dalyvavimą tyrime (pavyzdžiui, nebereikia chemines akumuliatorių savybes suprantančio mokslininko). Taip pat, tokie metodai gali būti taikomi realaus laiko situacijose, be to jų realizacijos išlaidos yra mažesnės. Atlikus skaičiavimus, buvo gauta, kad pasiūlytas DNN algoritmas yra geriausias lyginant su prieš tai minėtais mašininio mokymosi metodais.

Gana dažnai naudojamas mašininio mokymosi metodas yra ilgalaikės-trumpalaikės atminties metodas (angl. *Long Short-term memory*, LSTM) [3], [26]. O 2019 metais du Kinijos mokslininkai pasiūlė naują SOH prognozavimo metodą, kuriame yra naudojamas perduodamasis mokymasis (angl. *Transfer Learning*) kartu su LSTM tinklu [26]. Tyrimo metu buvo sukurtas naujas matas pavadintas FES (angl. *feature expression scoring*). Remiantis juo buvo taikomos skirtingos perduodamojo mokymosi strategijos. Atlikus tyrimą buvo nustatyta, kad siūlomas modelis turi didelę reikšmę ličio jonų akumuliatorių SOH įvertinimui. Priešingai negu įprasti perdavimo metodai, pasiūlytas modelis yra efektyvus ir naudojant mažas akumuliatorių duomenų aibes. Tiesa, kadangi tiek perdavimo modelis, tiek ir bazinis remiasi prognozėmis nustatytomis tuo pačiu įkrovimo procesu, šis modelis gali netikti kitokio tipo akumuliatorių SOH prognozavimui.

Vienas naujausių tyrimų naudojant NASA duomenų rinkinio dalį (kitą, nei tirtą šiame darbe) buvo pristatytas 2019 metų lapkritį [27]. Eksperimento metu buvo pristatytas nepriklausomas rekurentinis neuroninis tinklas (angl. *Independently Recurrent Neural Network*, IndRNN), padedantis įvertinti SOH. Tyrimo metu, naujai pristatytas metodas buvo lyginamas su kitais, rekurentiniais neuroniniais tinklais (angl. *Reccurent Neural Network*, RNN), tokiais kaip: LSTM ir apjungto rekurentinio mato metodu (angl. *Gated Recurrent Unit*, GRU). Taip pat, šiuo atveju buvo keičiamas laiko žingsnis bei vertinamas geriausias variantas. Gauti rezultatai parodė, kad IndRNN yra tikslesnis metodas už kitus du RNN modelius. IndRNN generavo 1,33 % RMSE paklaidą ir 1,14 % MAE paklaidą, kai tuo tarpu LSTM generavo atitinkamai 3,16 % ir 2,73 %, o GRU – 2,54 % ir 2,39 %.

Neuroniniais tinklais paremtas SOH vertinimas buvo pristatytas ir 2019 metų liepą, kai keturi Pietų Korėjos *Sogango* universiteto darbuotojai realizavo tris modelius: vienkryptį neuroninį tinklą (angl. *Feedforward Neural Network*, FNN), konvoliucinį neuroninį tinklą (angl. *Convolution Neurol Network*, CNN) ir ilgalaikės-trumpalaikės atminties metodą (LSTM), vertinant kelis parametrus: įtampą (V), srovę (I) ir temperatūrą (t) [6]. Atlikus eksperimentus (su atskiru akumulatoriumi), skaitiniai rezultatai parodė, kad duomenų įvairovė yra labai svarbi norint tiksliai įvertinti BMS. Buvo pademonstruota, kad naudojantis kelių parametru modeliais, rezultatai vieno parametro modelio atžvilgiu, pagerėjo 58 %, 46 % ir 25 % atitinkamai FNN, CNN ir LSTM atvejais.

Nagrinėjant du paskutinius straipsnius galima pažymėti, kad, nors LSTM tinklas taikomas gana dažnai, tačiau jo pagalba gautų prognozių rezultatai nėra labai tikslūs. Atsižvelgiant į paskutiniajame straipsnyje [6] vykdytus tyrimus ir mašininio mokymosi metodais gautus rezultatus, šiame darbe buvo pasirinkta SOH prognostinio modelio kūrimui naudoti vienkryptį neuroninį tinklą.

1.6. Parametrai vidinėms būsenoms vertinti

Norint atlikti kokybiško veikimo būsenos prognozavimą, reikia ne tik surasti tinkamą metodą, tačiau ir susikurti priimtina prognostinį modelį. Apžvelgus kitų atliktus tyrimus [6], [11], [27] pastebėta, kad SOH prognozė dažniausia remiasi akumulatoriaus talpos prognozavimu laike, kuomet į prognostinį modelį reikia įtraukti tam tikrus vidinius akumuliatorių parametrus (kintamuosius). Dažniausia į prognostinius modelius yra atskirai įtraukiamas akumulatoriaus srovės, įtampos, temperatūros parametras arba viena, ar kita tokių parametru kombinacija.

Vienas pirmųjų darbų, kuriame kalbama apie temperatūros įtaką akumulatoriaus talpos prognozei buvo pristatytas dviejų Kalifornijos mokslininkų, dar 2006 metais [19]. Šiame straipsnyje buvo pristatytas analitinis modelis, kuris atlieka akumulatoriaus likutinės talpos prognozes. Šio išsamaus modelio efektyvumas buvo patvirtintas modeliavimo rezultatais. Vidutinės prognozės paklaidos buvo 1,03 %, o maksimali paklaida nesiekė 3 % (2,94%).

Taip pat, yra atliekami ir nauji modeliavimo bandymai, kur talpos prognozėms naudojami ne tik vidinių parametru duomenys ar jų kombinacijos, bet ir aukštesnių eiliu diferencialinės kreivės. 2017 metais penkių Korėjos mokslininkų publikuotame darbe, buvo pasiūlytas talpos prognozavimo metodas, kai į prognozę yra įtraukiamos antros eilės srovės diferencialinės kreivės [9]. Šis metodas buvo patikrintas su skirtinga iškrovimo srove turinčiais penkiais akumuliatoriais. Buvo gauta, kad talpos prognozių paklaidos yra mažesnės nei 2 % iki tol kol yra pasiekama 76,5 % talpos riba.

Nagrinėjant pačius naujausius tyrimus, galima matyti, kad vis dar yra bandoma atrasti patį geriausią prognostinį modelį ir nėra apsiribojama tik jau analizuotų būsenų vertinimu, o yra tiriami ir nauji santykiai tarp parametru. 2019 metais, keturių Kinijos mokslininkų publikuotame straipsnyje [28], buvo pristatytas modelis, kuriame yra parodoma, kad nuolatinės srovės įtampos profilio įkrovimo kreivė yra susijusi su SOH būseną ir buvo gautas naujas sveikatos rodiklis (angl. *health index*), įvertinamas tik iš nuolatinės įtampos stebėjimų. Visa sistema buvo sukurta remiantis netiesiniu modeliu, o jos pagrįstumas ir efektyvumas buvo patikrintas naudojant ličio jonų akumuliatorių duomenis, esančius NASA duomenų bazėje [18].

1.7. Literatūros apžvalgos išvados

Apžvelgus literatūrą galima teigti, kad ličio jonų akumulatoriai yra vieni populiariausių rinkoje, tačiau jų kokybiško veikimo užtikrinimas yra gana didelis iššūkis. Akumuliatorių ilgaamžiškumas priklauso nuo daugelio aspektų – nuo pačio akumulatoriaus modelio pasirinkimų, iki jau veikiančio akumulatoriaus eksploatavimo sąlygų keitimo. Norint užtikrinti efektingą akumuliatorių veikimą, reikia nuolatos stebėti jų parametrus ir stengtis sumažinti akumuliatorių funkcionavimo trūkumus. Kadangi tiesiogiai galima stebėti ne visų parametrų ir būsenų kitimą, reikia pasitelkti tam tikrus matematinius modelius jiems įvertinti. Akumuliatorių valdymo sistema (BMS) padeda užtikrinti efektingą akumuliatorių veikimą. Sistemai įtaką daro trys pagrindiniai jos sudarymo etapai: akumulatoriaus modeliavimas, vidinių būsenų įvertinimas ir akumulatoriaus įkrovimo metodų taikymas. Pirmoji užduotis vertinant BMS yra tikslus akumulatoriaus modeliavimas, kurio pagrindas gali būti trijų tipų: elektrinis modelis, terminis modelis ar jungtinis modelis. Sudarius patikimą modelį yra vertinamos vidinės būsenos. Populiariausios ir dažniausiai naudojamos yra įkrovimo būseną (SOC) ir kokybiško veikimo būseną (SOH). SOC apibūdina trumpo laikotarpio esamų parametrų pasikeitimus, o SOH – ilgo laikotarpio. Šiems parametrams vertinti yra pasitelkiami įvairūs matematiniai modeliai, pavyzdžiui Kalmano filtrai ar dalelių filtrai ir jų modifikacijos, stebėjimais paremti metodai ar įvairūs dirbtiniu intelektu paremti modeliai ir metodai – įvairūs neuroniniai tinklai, dalelių spiečiaus algoritmai ar atraminių vektorių metodai. SOH įverčio radimas yra vienas sunkiausių ir svarbiausių etapų BMS sudarymui. Todėl šiame darbe buvo pasirinkta realizuoti vienkryptį neuroninį tinklą, kuris padėtų sudaryti modelį SOH būsenų prognozavimui.

2. Tyrimo metodai ir įranga

2.1. Akumuliatorių būsenų įvertinimas

Vienas iš svarbiausių akumuliatorių valdymo sistemos etapų yra įvertinti vidines akumulatoriaus būsenas. Kaip anksčiau minėta, dažniausia yra vertinamos SOC ir SOH būsenos. Taip pat yra naudojamos ir kitos būsenos, tokios kaip veikimo pabaigos būseną (angl. *end-of-life*, EOL), gyvavimo būseną (angl. *state of life*, SOL) ar likusio gyvavimo laiko būseną (angl. *remaining useful life*, RUL) [5]. Tačiau nagrinėti jų visų nėra tikslinga, nes pavyzdžiui EOL būseną yra atvirkščiai proporcinga SOH būsenai, o kitų būsenų įvertinimas yra taip pat tarpusavyje susijęs.

2.1.1. Įkrovimo būsenos įvertinimo modelis

Įkrovimo būseną (SOC) apibūdina likusią akumulatoriaus talpą procentais lyginant su visa talpa toje pačioje situacijoje. 100 % reiškia, kad akumulatorius yra pilnai įkrautas lyginant su visa talpa, kai tuo tarpu 0 % nurodo, kad akumulatorius pilnai iškrautas. Tikslus SOC įvertinimas vaidina svarbų vaidmenį stebint esamą talpą, kad būtų užtikrintos saugios ir naudingos akumulatoriaus operacijos.

Iš tikrųjų, yra nustatyti du SOC vertinimo metodų tipai: tiesioginis įvertinimas ir modeliavimu paremtas įvertinimas. Tiesioginiai įvertinimo metodai remiasi tiesioginiu akumulatoriaus įtampos ir srovės matavimu. SOC dažniausiai yra skaičiuojamas dviem skirtingais būdais: *ampervalandžiais* (angl. *Amperehour*, Ah) ir *kulono skaičiavimo metodu* (angl. *Coulomb counting method*) integruotu su atviros grandinės įtampa (angl. *open circuit voltage*, OCV) paremtu metodu. Ah metodas yra bendras ir paprastas būdas apskaičiuoti SOC, kuris gali būti užrašomas:

$$SOC(k) = SOC(k_0) + \int_{k_0}^k \eta I(t) dt / C_n, \quad (1)$$

čia, $SOC(k_0)$ yra žinoma pradinė SOC reikšmė, η yra akumulatoriaus įkrovimo ir iškrovimo efektyvumas, C_n yra tikėtina talpa, $I(t)$ yra srovės reikšmė laiko momentu t , kuri yra teigiama, kai akumulatorius įkraunamas ir neigiama, kai iškraunamas [16].

Nuo tada, kai esamas įkrovimas ir iškrovimas gali būti lengvai išmatuojamas, Ah metodas tapo paprasčiausiu pasirinkimu matuojant SOC. Deja, Ah metodas yra stipriai priklausomas nuo srovės matavimų bei klaidų susikaupimo, kas gali reikšmingai paveikti įvertinimo tikslumą. Be to, yra nelengva realiu laiku tiksliai nustatyti pradinę SOC reikšmę, ypač, kai akumulatorius yra kraunamas nustatytame intervale, pavyzdžiui, 10 % - 90 %. Pradinės SOC reikšmės ir srovės sulyginimas tampa dideliu iššūkiu SOC matavimams pritaikant Ah metodą.

Yra įrodyta, kad egzistuoja netiesinis sąryšis tarp SOC ir OCV. Todėl SOC matavimas naudojant OCV tapo efektyviu ir populiariu metodu, kuris naudojamas daugybėje taikymų. Naudojant OCV metodą gali būti pasiekiamas didelis SOC įverčio tikslumas, tačiau poilsio laiko (angl. *resting time*) įtaka nulemia pagrindinį šio metodo ribotumą. Iš tikrųjų, prireikia daug laiko, kol po apkrovos srovės atjungimo yra pasiekiamas pusiausvyros taškas. Taip pat ryšys tarp SOC ir OCV keičiasi, kai akumulatorius sensta ir vyksta temperatūros pokyčiai [16].

Dėl prieš tai minėtų trūkumų, dažniausiai yra naudojami modeliavimu paremti įverčiai, kurie apskaičiuoja OCV. Naudojant šiuos modelius, reikia būti įsitikinusi, kad akumulatoriaus modelis yra sukonstruotas tinkamai. Paprastai yra pasirenkamas akumulatoriaus ekvivalentinis grandinės modelis ir elektrocheminis modelis standartinės erdvės būsenos pavidalu, kai norima įvertinti akumulatoriaus SOC. Tokiam įverčio radimui yra naudojama daugybė metodų (žr. 1.5 skyrelį).

2.1.2. Kokybiško veikimo būsenos modelis

Paskutinį dešimtmetį labai daug dėmesio yra skiriama bandymams surasti tinkamiausią metodą, kuriuo būtų galima nustatyti ličio jonų akumuliatorių kokybiško veikimo būseną (SOH). Beveik visoje literatūroje dėmesys yra fokusuojamas tik į iškrovimo/įkrovimo srovės santykį ir temperatūrą, kaip į pagrindinius faktorius, darančius įtaką SOH. Tačiau vis dar nėra priimto vieno, tikslaus apibrėžimo kaip apibūdinti akumulatoriaus SOH būseną [12]. Bendrai SOH gali būti apibūdinimas:

$$SOH(t) = SOH(t_0) + \int_{\tau=t_0}^t \delta_{funk}(I, T, SOC, \text{ir kita}) d\tau \quad (2)$$

čia, $SOH(t_0)$ nurodo pradinę akumulatoriaus SOH būseną, δ_{funk} yra senėjimo greičio funkcija, kuri stipriai priklauso nuo faktorių, tokių kaip srovė, temperatūra, SOC. Gali būti ir kitų stresinių faktorių, tokių kaip mechaninė vibracija ar per didelis potencialas (angl. *over-potential*).

Akumulatoriaus senėjimas sumažina jo talpą ir padidina vidinę varžą. Todėl akumulatoriaus SOH gali būti įvertintas pagal vidinę varžą arba naudojamą talpos dydį. Yra publikuojama daugybė tyrimų kaip įvertinti SOH. Šie tyrimai yra klasifikuojami į tris grupes:

- įverčiai, neparemti modeliais (angl. *model-free*),
- įverčiai, paremti modeliais (angl. *model-based*),
- duomenų tirybos metodai (angl. *data mining*).

Naudojant modeliais neparemtus metodus, akumulatoriaus SOH gali būti skaičiuojamas pagal formules:

$$SOH = \frac{C_{senėjantis}}{C_n} \times 100\%,$$

$$SOH = \frac{R_{vidinė}}{R_n} \times 100\% \quad (3)$$

čia, $C_{senėjantis}$ ir C_n yra atitinkamai senėjančio akumulatoriaus ir nominali (naujo akumulatoriaus) talpos, $R_{vidinė}$ ir R_n yra atitinkamai didėjanti vidinė ir nominali varžos [16].

Pagal turimą SOH apibūdinimą (3) galima būtų taikyti standartinę talpos testą [20] arba impulsų srovės testą [4], kad būtų išmatuota akumulatoriaus talpa bei vidinė jo varža senėjimo laikotarpiu. Tačiau šis tiesioginis metodas yra nepatogus ir nėra rekomenduojamas todėl, kad į normalų akumulatoriaus veikimą įsiterpia tokios būsenos, kaip pilnas iškrovimas, naudojant kontroliuojamą srovę ir temperatūrą. Akumulatoriaus elektrocheminės varžos spektroskopija (angl. *Electrochemical Impedance Spectroscopy*, EIS) gali pateikti kur kas daugiau informacijos apie akumulatoriaus kokybiško veikimo būsenas nei tiesioginių $C_{senėjantis}$ ir $R_{vidinė}$ matavimų metodas. Tiesa, šis EIS metodas reikalauja specialių instrumentų, kurie riboja tokio metodo naudojimą. Taip pat tokie testai reikalauja ir didelių laiko sąnaudų [16].

Naudojant modeliais paremtus metodus, akumulatoriaus talpa ir vidinė varža yra imami kaip laike kintantys parametrai. Tuomet įvairūs metodai, kurie taikomi ir SOC įvertinimams (žr. 1.4.2. skyrelį), yra naudojami talpos ir varžos įverčiams rasti, kas vėliau leidžia atlikti ir SOH skaičiavimus [16]. Modeliais paremtiems metodams reikalingi duomenys yra linkę turėti neapibrėžtumą ir nepilnumą, nes išbandyti visus faktorius, veikiančius akumulatoriaus gyvenimo ciklą yra neįmanoma. Tačiau tam tikri dėsningumai galioja ir tokie metodai gali būti gana efektyvūs prognozės metodai. Jie naudojami atrasti akumulatoriaus veikimo taisykles taip, kad būtų galima prognozuoti SOH, naudojant bandymų duomenis. Tokie metodai nereikalauja mechaninio baterijos veikimo ir tokių sistemų veikimo principų žinojimo. Jie panaudoja surinktą informaciją taip, kad būtų galima prognozuoti SOH, naudojant įvairius duomenų analizės ir mašininio mokymosi metodus. Taip yra išvengiama modelio supratimo sunkumų ir dėl to tai dažniau yra taikoma praktikoje [31].

2.1.3. Tyrimo rezultatų paklaidų vertinimas

Geriausio ar tiksliausio modelio radimui ir palyginimui dažniausiai naudojami vidutinė absoliutinė paklaida (angl. *mean average error*, MAE), didžiausia paklaida (angl. *maximum error*, ME) ir vidurkio kvadratinė paklaida (angl. *root mean square error*, RMSE).

Kintamųjų tikrųjų ir išmatuotų reikšmių skirtumas visoje aibėje yra žinomas kaip MAE paklaida. Ji matuoja vidutinį klaidų dydį prognozuojamam reikšmių rinkiniui, neatsižvelgiant į skirtumo kryptį. RMSE yra kvadratinė metrika, kuri taip pat atspindi vidutinį klaidos dydį. Ji gali būti apskaičiuojama traukiant kvadratinę šaknį iš skirtumo tarp tikrosios ir įvertintos reikšmės kvadrato vidurkio. Matematiškai MAE ir RMSE gali būti užrašomi [1]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |tikroji\ reikšmė - \grave{ı}vertinta\ reikšmė|, \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (tikroji\ reikšmė - \grave{ı}vertinta\ reikšmė)^2}. \quad (5)$$

Tiek MAE, tiek ir RMSE išreiškia vidutinę modelio prognozavimo paklaidą dominančio kintamojo mato vienetais. Abi metrikos gali įgyti reikšmes nuo nulio iki begalybės ir neatspindi paklaidos ženklo. Abi jos yra neigiamai orientuoti matai, o tai reiškia, kad mažesnis įvertis reiškia tikslesnę prognozę.

Vidutinių kvadratinių paklaidų kvadratinės šaknies vertinimas turi keletą įdomių pasekmių RMSE rezultatui. Kadangi klaidos yra pirmiausia pakeliamos kvadratu prieš apskaičiuojant vidutines reikšmes, RMSE suteikia palyginti didelį svorį didelėms klaidoms. Tai reiškia, kad RMSE turėtų būti naudingesnis, kai yra didelės klaidos ir tokie nuokrypiai nėra pageidaujami taikant modelį. Iš tikrųjų, esant vienodam MAE, RMSE didėja, nes didėja ir dispersija, susijusi su nukrypimų dydžių pasiskirstymu [1].

Šiame darbe bus sudaromi prognostiniai modeliai, kurių pagalba būtų galima įvertinti SOH būseną. Modelių tikslumui nustatyti naudojamos MAE ir RMSE paklaidos.

2.2. Akumuliatorių talpos prognozės metodai

Talpos prognozavimas yra vienas iš sudėtingesnių etapų vertinant BMS. Šioms prognozėms rasti yra pasitelkiami daugybė metodų nuo įvairių filtracijų iki mašininio mokymosi metodų. Šiame darbe bus realizuotas vienas mašininio mokymosi grupei priklausantis metodas - vienkryptis neuroninis tinklas. Šio tinklo pagalba sudaryto prognostinio modelio rezultatai taip pat bus lyginami su kitų autorių atliktu tyrimu, kai prognostiniam modeliui buvo naudojamas Gauso proceso regresinis modelis.

2.2.1. Gauso proceso regresinis modelis

Gauso proceso regresinis modelis (GPR) yra laikomas idealiu laiko juostos filtru, kuriuo galima efektyviai atskirti žemo dažnio signalų triukšmą, nuo didelio dažnio signalų triukšmo. Pats metodas turi platų taikymų spektrą – jis naudojamas vaizdų apdorojime ir vienos ar daugiau dimensijų signalų apdorojime. GPR turi Gauso pasiskirstymo charakteristiką, kuri gali būti išreikšta taip:

$$G(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(\frac{-(x - \mu)^2}{2\sigma^2}\right) \quad (6)$$

čia, μ yra vidurkis, o σ – standartinis nuokrypis.

GPR algoritmas yra plačiai taikomas mašininio mokymosi ir statistikos srityse. Įprastai, regresiniai modeliai modeliavimui naudoja aiškius parametrus, tačiau GPR modeliavimams naudoja tikimybinius metodus. GPR nustatomas pagal vidurkio ir kovariacinę funkcijas, o aposterioriniam įverčiui gauti naudojamas Bajeso metodas. Prognostinio modelio, vertinančio SOH būseną tikslas yra modeliuoti vaizdavimus, vertinant įvesčių savybes, kol gaunamas galutinis SOH įvertis. Įvesčių savybės yra gaunamos iš kiekvieno ciklo. Dėl šios priežasties įvesčių duomenų rinkinius galima interpretuoti kaip laiko eilutes, o imties intervalas yra vienas ciklas [13].

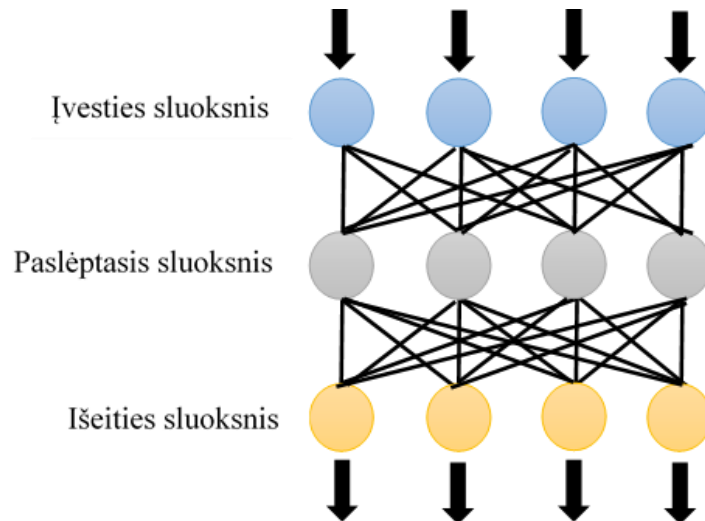
2.2.2. Vienkryptis neuroninis tinklas

Šiame darbe buvo kuriamas prognostinis modelis paremtas vienkrypčiu neuroniniu tinklu (angl. *feedforward network*, FNN). Šis neuroninis tinklas literatūroje gali būti sutinkamas ir kaip gilusis vienkryptis tinklas (angl. *Deep feedforward network*) arba daugiasluoksniai perceptronai² (angl. *multilayer perceptrons*).

Iš tikrųjų, FNN yra pirmasis ir vienas paprasčiausių ANN tipų. Vienkrypčio neuroninio tinklo tikslas yra aproksimuoti f^* funkciją. Pavyzdžiui, klasifikatoriaus $y = f^*(x)$ kategorijai y yra priskiriama įvestis x . Tuomet, FNN nusako priskyrimą, pagal $y = f(x; \theta)$ ir tinklas išmoksta θ reikšmes, esant geriausiai funkcijos f aproksimacijai [10].

² Perceptronas - (angl. perceptron < lot. perceptio) - pažinimas, suvokimas + (elek)tronas) - smegenų modelis, padedantis tirti natūralųjį intelektą fizikinėmis ir matematinėmis priemonėmis [15].

Tokie modeliai yra vadinami vienkrypčiais todėl, kad turima informacija x tarsi sklinda per tarpinius skaičiavimus, apibūdinančius f funkciją, kol galiausiai gaunama išvestis y . Kitaip tariant, jungtys tarp mazgų nėra ciklinės, t. y. informacija tinkle visada juda tik viena kryptimi ir negrįžta atgal į tą patį mazgą (žr. 6 pav.). Tokie tinklai turi reikšmingą pranašumą skaičiavimuose, tačiau neturi vidinės dinamikos. FNN yra labai svarbus mašininio mokymosi taikymuose, nes jis suformuoja pagrindą svarbiems, realių uždavinių taikymams.



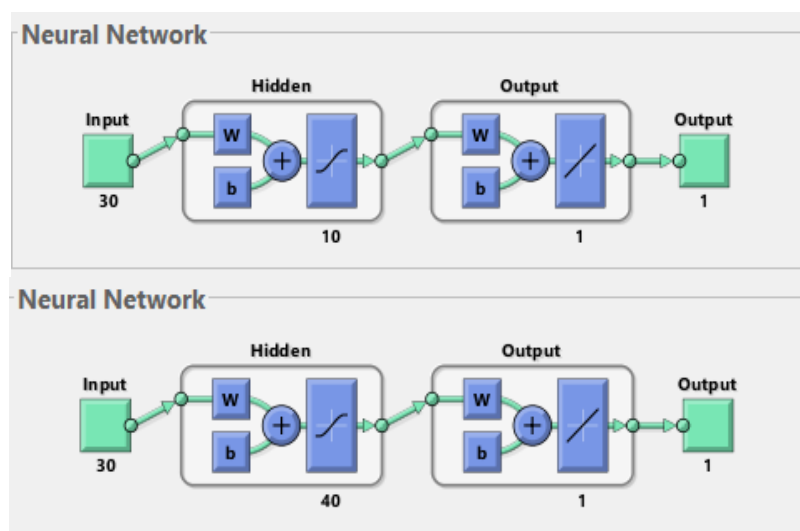
6 pav. Vienkryptis neuroninis tinklas

FNN vadinamas tinklu, todėl, kad jis reprezentuoja daugybę kartu sujungtų atskirų funkcijų. Pavyzdžiui, turime tris funkcijas $f^{(1)}$, $f^{(2)}$ ir $f^{(3)}$, kurios yra sujungtos į grandinę $f(x) = f^{(3)}(f^{(2)}(f^{(1)}(x)))$. Tokios grandinių struktūros yra dažnos neuroniniuose tinkluose. Šiuo atveju, $f^{(1)}$ yra pirmasis tinklo sluoksnis, $f^{(2)}$ – antrasis ir t.t. Galiausiai visas grandinės ilgis nurodo neuroninio tinklo gyly. Paskutinis neuroninio tinklo sluoksnis vadinamas išvesties sluoksniu. Todėl ir gauname, kad apmokant neuroninį tinklą norime, kad $f(x)$ atitiktų $f^*(x)$. Kiekvienas imties x kintamasis yra susietas su y : $y \approx f^*(x)$. Apmokymo imties pavyzdžiai tiksliai nurodo, kokios reikšmės turi būti gražinamos išvesties sluoksnyje kiekviename x taške. Apmokymo duomenys tiksliai neapibrėžia kitų sluoksnių elgesio, nėra nusakyta, ką kiekvienas sluoksnis turi daryti. Dėl šių priežasčių tokie sluoksniai vadinami paslėptaisiais. Neuroninio tinklo bendras neuronų ir paslėptųjų sluoksnių skaičius, kartu su visomis jungtimis sudaro neuroninio tinklo architektūrą.

Neuroniniame tinkle epocha vadinamas ciklas, trunkantis per visą apmokymą su duomenų rinkiniu. Įprastai norint apmokyti neuroninį tinklą vienos epochos nepakanka. Kitaip tariant, tinklui apmokymų duomenys yra pateikiami daugiau nei vieną kartą, tam, kad pateikus testavimo duomenis būtų surandamas geriausias rezultatas. Maksimalus epochų skaičius modeliuojant neuroninį tinklą yra nustatomas tam, kad būtų kontroliuojamas įvykdomų apmokymų skaičius [22].

Įprastai, norint tinkamai apmokyti neuroninį tinklą, duomenų rinkinys yra skaidomas į tris imtis. Pirmoji ir didžiausioji imtis yra vadinama apmokymo duomenimis. Nėra tiksliai nustatyta, kokia visų duomenų dalis turi būti priskirta apmokymo duomenims. Dažniausia tai siekia 50 % - 80 % visų duomenų, tačiau tai priklauso nuo sprendžiamo uždavinio. Antroji duomenų imtis yra vadinama validavimo imtimi. Ji naudojamas norint nešališkai įvertinti modelio tinkamumą apmokymo duomenims, kai yra nustatinėjami hiperparametrai. Trečioji imtis vadinama testavimo imtimi. Ji naudojama nešališkai vertinti galutinį modelį. Šios imties dydis įprastai yra nedidelis, siekia 10 % - 25 % visų duomenų rinkinio.

Tyrimo metu buvo atliekami bandymai su skirtingą architektūrą turinčiais FNN tinklais. Siekiant tyrimus palyginti su kitais, buvo pasirinkta, kad pirmasis FNN tinklas turi dešimt neuronų paslėptajame sluoksnyje, o antrasis – keturiasdešimt neuronų paslėptajame sluoksnyje (žr. 7 pav.).



7 pav. Neuroniniai tinklai su skirtinga architektūra

Abejais atvejais buvo nustatomas maksimalus epochų skaičius, kuris lygus trimis šimtams. Tinklui apmokyti duomenys yra skaidomi į apmokymo, validavimo ir testavimo imtis, atitinkamai imant atitinkamai 70 %, 15 % ir 15 % iš duomenų rinkinio. Tinklo apmokymui buvo naudojama *Neural Network Toolbox* funkcija *train*. Toliau yra pateiktas neuroninių tinklų apmokymo ir realizavimo pseudokodas (žr. 8 pav.).

```

%FNN su 10 neuronų paslėptajame sluoksnyje
netFNN10 = feedforwardnet(10);
netFNN10.trainParam.epochs = 300;
[netFNN10, tr] = train(netFNN10, Train_Input', Train_Output', 'useparallel', 'yes');
epoch1(iter) = tr.num_epochs;
%FNN su 40 neuronų paslėptajame sluoksnyje
netFNN40 = feedforwardnet(40);
netFNN40.divideFcn = 'divideind';
netFNN40.divideParam.trainInd = tr.trainInd;
netFNN40.divideParam.valInd = tr.valInd;
netFNN40.divideParam.testInd = tr.testInd;
netFNN40.trainParam.epochs = 300;
[netFNN40, tr40] = train(netFNN40, Train_Input', Train_Output', 'useparallel', 'yes');
epoch2(iter) = tr40.num_epochs;
%Apmokyties tinklams paduodami testiniai duomenys
pFNN10 = netFNN10(Train_Input(tr.testInd, :));
pFNN40 = netFNN40(Train_Input(tr.testInd, :));
%Perskaičiuojamos reikšmės
Train_Output = Train_Output(tr.testInd, :)*yr + ym;
pFNN10 = pFNN10*yr+ ym;
pFNN40 = pFNN40*yr + ym;

```

8 pav. Vienkrypčio neuroninio tinklo pseudokodas

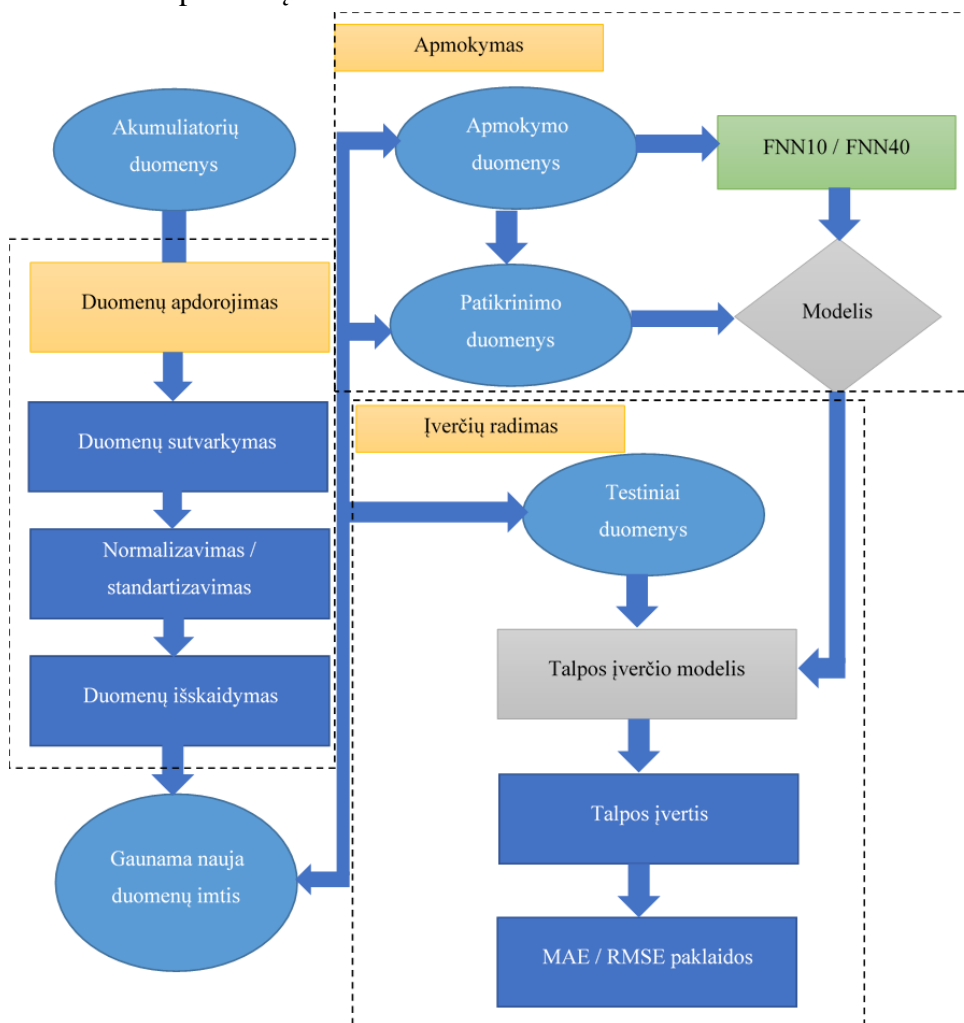
2.3. Tyrimo metodika ir algoritmo struktūra

Visas tyrimas buvo atliktas remiantis devintame paveiksle (žr. 9 pav.) pavaizduota algoritmo struktūra. Algoritmas susideda iš trijų etapų:

- duomenų apdorojimo,
- apmokymo,
- įvertinimo.

Pirmame etape (duomenų apdorojimas) yra sutvarkomi akumuliatorių duomenys – panaikinamos išskirtys, tuščios reikšmės ir pasirenkami tik nagrinėjamų parametrų duomenys. Tada atliekamas duomenų standartizavimas arba normalizavimas (žr. 3.1.3 ir 3.1.4 skyrius). Tuomet, turimi duomenys yra išskaidomi į tris duomenų imtis: apmokymo, validavimo ir testavimo. Galiausia yra gaunamos sutvarkytos srovės, įtampos, temperatūros ir akumuliatorių talpos duomenų imtys. Antrame etape (apmokymas) vyksta neuroninių tinklų parametrų įvertinimas taikant apmokymo duomenis. Apmokymo duomenys yra pateikiami vienam iš neuroninių tinklų (FNN10 arba FNN40) ir įvertinami parametrai bei pasinaudojus validavimo duomenimis atrenkamas prognostinis modelis. Trečiajame etape (įverčių radimas) yra panaudojama testavimo duomenų imtis, kurios pagalba randamas talpos įvertis. Galiausiai turimiems įverčiams apskaičiuojamos paklaidos. Norint patikimiau įvertinti modelio tikslumą, kiekvienas modelis yra realizuojamas 25 kartus, kai atsitiktinai parenkamos vis kitos apmokymo,

validavimo ir testavimo imtys. Apskaičiavus visų 25-ių modelių paklaidas, yra apskaičiuojamas aritmetinis MEA ir RMSE paklaidų vidurkis.



9 pav. Tyrimo metodika ir algoritmo struktūra

2.4. Taikyta programinė įranga

Tyrimui buvo naudota MATLAB programinė įranga. Ši programinė įranga buvo pasirinkta dėl savo universalių pritaikomumo galimybių bei funkcionalumo. Be to, pagal *Analytics Insight* publikuotą straipsnį [23], MATLAB patenka tarp populiariausių duomenų analitikos programinių įrangų 2020 metais. Ji yra vertinama dėl gausybės statistinių ir mašininio mokymosi pasirinkimo galimybių, taip pat dėl papildomų metodų, tokių kaip netiesinis optimizavimas, paveikslėlių ir vaizdo įrašų apdorojimas ar techninis, finansinis modeliavimas, kurie yra nesudėtingai realizuojami. Tyrimui buvo naudota MATLAB R2016a versija, bei neuroninių tinklų priemonių rinkinys (angl. *Neural Network Toolbox*).

Skaiciavimams atlikti buvo naudojamas MSI kompiuteris, kuriame buvo Intel® Core™ 8th Gen i5 procesorius, įdiegta 8,00 GB RAM atmintis, 64 bitų operacinė sistema ir GL63 8RC SSD diskas bei 1 TB HDD diskas.

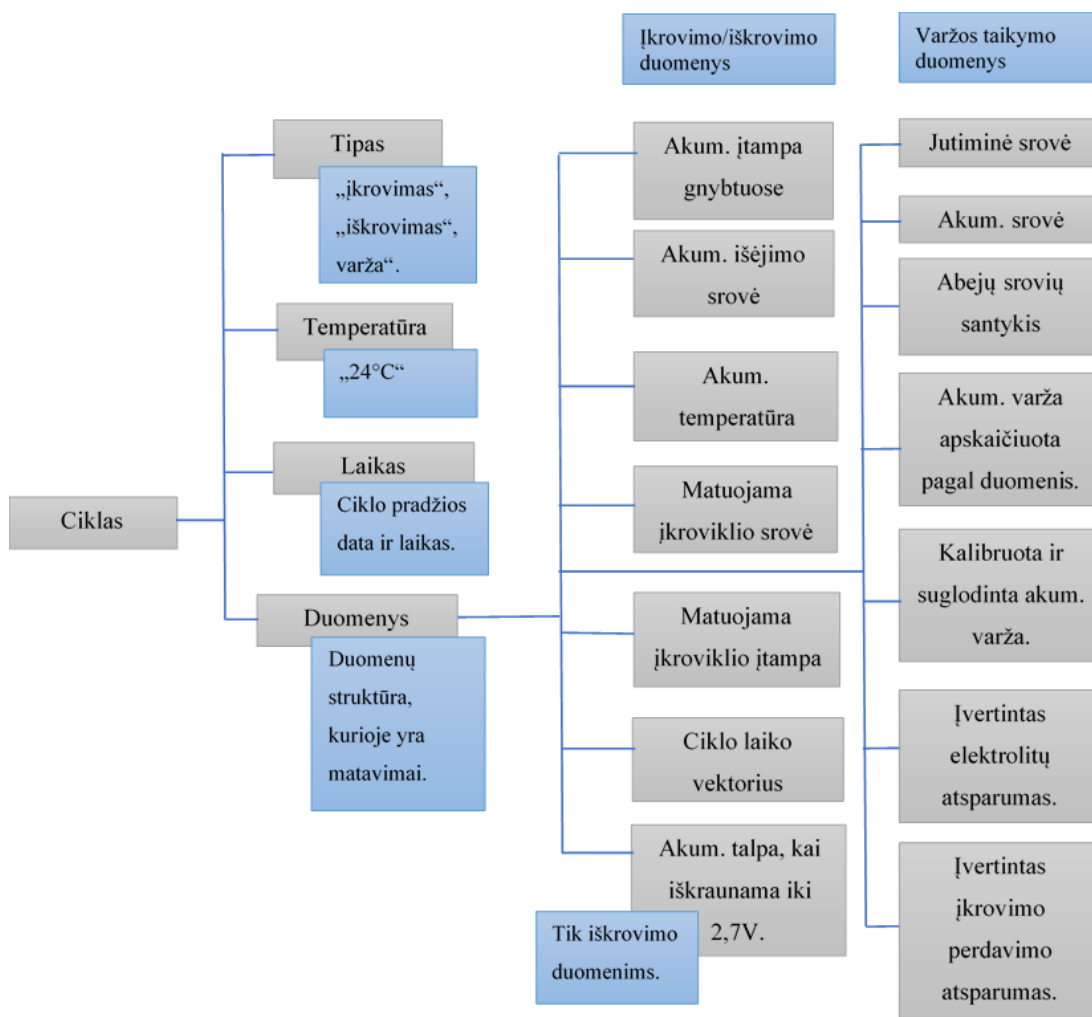
3. Tyrimo duomenys ir rezultatai

3.1. Duomenys ir jų analizė

Pirmajame tyrimo etape buvo atlikta duomenų, jų struktūros ir duomenų charakteristikų (parametrų) analizė, bei duomenų paruošimas neuroninio tinklo apmokymui.

3.1.1. Tyrimo duomenų struktūra

Tyrimui buvo naudojami duomenys iš NASA duomenų rinkinio [18]. Darbe buvo naudojamas pirmasis duomenų rinkinys, kurį sudaro 5-to, 6-to, 7-to ir 18-to (atitinkamai B0005, B0006, B0007 ir B0018) ličio jonų akumuliatorių duomenys. Duomenys apie kiekvieną akumuliatorių buvo pateikiami atskiruose *.mat* formato failuose. Kiekviename faile yra struktūrinio masyvo tipo duomenys. Struktūrinis masyvas, tai toks duomenų tipas, kuris sugrupuoja susijusius duomenis į duomenų konteinerius, dar vadinamus laukais. Kiekvienas laukas gali saugoti bet kokio tipo duomenis. Tyrimui naudojamų failų struktūra pateikta dešimtame paveiksle (žr. 10 pav.).



10 pav. Tyrime naudoto duomenų failo struktūra


Akumuliatoriai buvo testuojami kambario temperatūroje (24 °C), prie trijų skirtingų veikimo būsenų: įkrovimo, iškrovimo ir veikiant varžai. Įkrovimas vyko nuolatinės srovės režimu esant 1,5 A, kol akumulatoriaus įtampa pasiekia 4,2 V ir tęsiamas pastovios įtampos režimu, kol krovimo srovė nukrenta iki 20 mA. Iškrovimas vyko esant 2 A pastoviai srovei, kol akumulatoriaus įtampa nukrisdavo iki 2,7 V, 2,5 V, 2,2 V ir 2,5 V atitinkamai 5, 6, 7 ir 18 akumulatoriams. Varžos stebėjimas vyko naudojant elektrocheminės varžos spektroskopiją, kai ji kito nuo 0,1 Hz iki 5 Hz. Pasikartojantis akumuliatorių įkrovimas ir iškrovimas lemia greitesnį jo senėjimą. Bandymai buvo baigiami, kai akumuliatoriai pasiekdavo EOL kriterijų. Kriterijus laikomas pasiektu, kai akumuliatorių talpa sumažėja apie 30 % (t. y. nuo 2 Ah iki 1,4 Ah).

Modeliuojant prognostinį modelį buvo naudojami tik išrovimo duomenys kiekvienam akumuliatoriui. Kadangi kiekvieno akumulatoriaus stebėtų ciklų skaičius yra skirtingas ir duomenys yra gana jautrūs ciklų kiekiui, o pats tyrimas tampa komplikuoatas esant dideliame duomenų skaičiui, todėl buvo atliktas jų pertvarkymas.

3.1.2. Duomenų ir jų kitimo analizė


Šiame darbe yra tiriama ar akumulatoriaus įvairių vidinių parametrų įtraukimas į modelį gali jį pagerinti. Remiantis 2019 metais išleistu straipsniu [6] yra daroma prielaida, kad talpos pokyčius, kai akumulatorius senėja, galima vertinti pagal srovės, įtampos ir temperatūros kitimus. Todėl pradžioje atskiro akumulatoriaus atveju (tyrimas darytas penktajam akumuliatoriui) buvo nagrinėjama, kaip šie parametrai kinta laike (žr. 11 pav.), pirmame ir paskutiniame – 164 gyvavimo cikle.

Iš grafiko (žr. 11 pav.) matyti, kad reikiamą įtampą nebe naujas akumulatorius pasiekia lėčiau negu naujas akumulatorius. Naujas tai padaro iš karto, o senas tam užtrunka apie 1800 sekundžių (30 minučių). Taip pat matyti, kad nuolatinė srovė iki pastovaus lygio nukrenta greičiau, o temperatūra pakyla žemiau, kai akumulatorius yra naujas. Dar vienas svarbus parametras, matomas iš grafiko, yra įkrovimo laikas. Naujam akumuliatoriui įkrauti reikalingas laikas yra apie 7500 sekundžių (2 valandos ir 5 minutės), tuo tarpu, senam akumuliatoriui įkrauti reikia apie 10500 sekundžių (2 valandos ir 55 minutės). Iš gautų rezultatų galima daryti išvadą, kad akumuliatoriui senėjant galima stebėti srovės, įtampos bei temperatūros kitimus, todėl jų įtraukimas į modelį, galėtų būti reikšmingas.



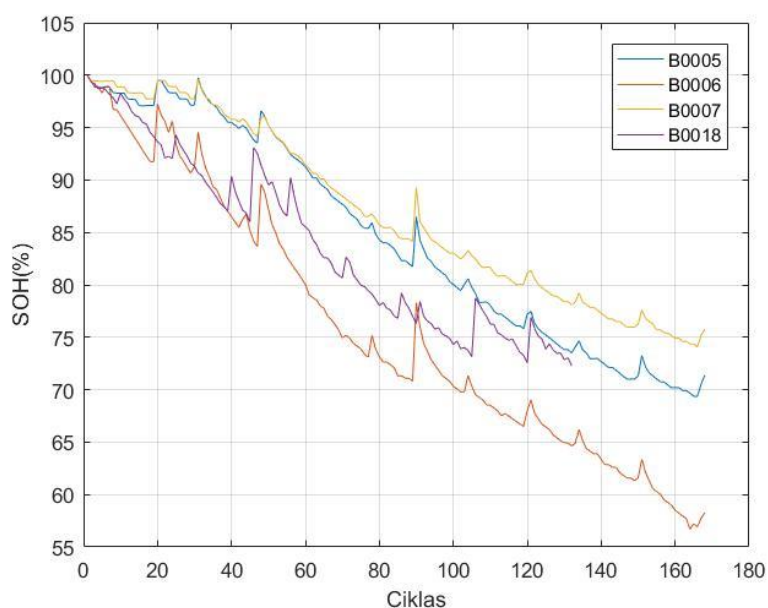
11 pav. Įtampos, srovės ir temperatūros kitimas įkraunant akumuliatorių; Pirmas ir paskutinis ciklai

Toliau, analizuojant duomenis, buvo gautas akumuliatorių talpos kitimo grafikas (žr. 12 pav.). Iš grafiko matyti, kad visų akumuliatorių talpa mažėja gana tolygiai, bet skirtingas akumuliatorius ne tame pačiame cikle pasiekia gedimo ribą, kuri yra 1,4 Ah. Pavyzdžiui, 18-tas akumuliatorius gedimo riba pasiekiamą jau 98 cikle, tuo tarpu 7-tas akumuliatorius tik 166 cikle.



12 pav. Talpos kitimo grafikas visiems akumuliatoriams senstant

Pagal (3) formulę buvo apskaičiuotas SOH įvertis kiekvienam akumuliatoriui atskirai ir pavaizduotas grafiškai (žr. 13 pav.). Analizuojamoje duomenų imtyje EOL kriterijus yra lygus 30%. Buvo laikoma, kad vidutiniškai pradinė akumuliatorių talpa yra 2 Ah, dėl to gedimo riba ir yra 1,4 Ah. Kadangi EOL yra atvirkštinis įvertis SOH, būtų galima teigti, kad akumulatoriai turėtų pasiekti gedimo ribą, kai SOH yra 70%. Tačiau, nagrinėjant kiekvieną akumuliatorių atskirai (žr. 13 pav.) matyti, kad ne visi akumulatoriai pasiekia 70% ribą. Taip nutinka todėl, kad visų akumuliatorių pradinė talpa nėra vienoda ir esant mažesnei pradinei talpai (pvz.: 18 akumulatoriaus atveju pradinė talpa yra 1,855 Ah), nustatyta gedimo riba (1,4 Ah) pasiekama greičiau ir nėra pasiekama 70 % SOH riba (18 akumulatoriaus atveju, pasiekama 72,3 % SOH).



13 pav. SOH įverčio kitimo grafikas visiems akumuliatoriams senstant

3.1.3. Duomenų agregavimas

Pirmiausia buvo pasirenkamas vienas iš iškrovimo parametrų: srovė (I), įtampa (V) arba laikas (t). Tuomet, turimas duomenų vektorius ilgis savo absoliučia verte padalijamas iš 10 ir vektorius pertvarkomas taip, kad būtų gauta naują matrica su $\frac{\text{vektorius ilgis}}{10}$ eilučių ir 10 stulpelių. Toliau apskaičiuojamas kiekvieno stulpelio vidurkis ir gaunamas naujas duomenų vektorius. Taip pertvarkomi visų trijų parametrų I, V, t duomenys ir gaunami nauji, pirmojo ciklo duomenys turintys 30 stulpelių. Tokiu būdu yra apdorojami kiekvieno ciklo duomenys ir apjungiami į vieną matricą.

Šiems veiksams atlikti buvo sukurta nauja funkcija *ikrovimo_duomenys.m*. Sukurtos funkcijos įvestis – struktūrinis akumulatoriaus duomenų masyvas. Funkcijos išvestis – aukščiau aprašyta duomenų

matrica su apdorotais I, V, t duomenimis. Toliau yra pateiktas šios duomenų apdorojimo funkcijos pseudokodas (žr. 14 pav.).

```
function x = ikrovimo_duomenys(Akumulatoriaus_duomenys)
bcycle = Akumulatoriaus_nr.cycle;
for i = 1:length(bcycle)-1
    if bcycle(i)tipas yra „charge“
        le = „įtampos duomenų vektoriaus ilgis padalijamas iš 10 ir imama sveikoji gauto
skaičiaus
        dalis
        %itampos duomenys
        vTemp = itampos_duomenys(:, 1:end-le);
        vTemp = reshape(vTemp, ilgis(vTemp)/10, []);
        vTemp = vidutine vTemp reikšmė;
        %srovės duomenys
        iTemp = srovės_duomenys(:, 1:end-le);
        iTemp = reshape(iTemp, ilgis(iTemp)/10, []);
        iTemp = vidutine iTemp reikšmė;
        %temperatūros duomenys
        tTemp = temperatūros_duomenys(:, 1:end-le);
        tTemp = reshape(tTemp, ilgis(tTemp)/10, []);
        tTemp = vidutine tTemp reikšmė
        x1(i, :) = [vTemp, iTemp, tTemp];
    end
end
Toliau yra ieškoma ar yra neapibrėžtų reikšmių gautoje matricoje ir jos pakeičiamos imties
vidutine reikšme
```

14 pav. Duomenų apdorojimo pseudokodas

Toliau šiems apdorotiems duomenims taikomas vienas iš šių metodų:

- duomenų standartizavimas,
- min-max tiesinis normalizavimas.

Vėliau, tyrimas atliekamas skirtingais metodais, siekiant įvertinti, ar skirtingas duomenų paruošimas gali turėti įtakos modelio tikslumui.

3.1.4. Duomenų standartizavimas

Duomenų standartizavimas iš tikrųjų yra jų pertvarkymas į duomenis, kurių vidurkis yra 0, o standartinis nuokrypis lygus 1. Tuo tarpu normalizavimas reiškia, kad duomenys yra perskaičiuojami į skalę (0,1).

Duomenys buvo standartizuoti pagal formulę:

$$x' = \frac{x - \bar{x}}{\sigma}, \quad (7)$$

čia, x – esamas dydis, \bar{x} – vektoriaus x vidurkis, σ – standartinis nuokrypis.

Atliekant tyrimą buvo sukurta funkcija *stand.m*, kurioje buvo atliekami duomenų standartizavimo veiksmai. Funkcijos įvestis – struktūrinis akumulatoriaus duomenų failas, pradinė akumulatoriaus talpa ir akumulatoriaus talpos vektorius kiekvienu laiko momentu. Toliau yra pateiktas duomenų standartizavimo funkcijos pseudokodas (žr. 15 pav.).

```
function [xData, yData, ym, yr] = stand(x, C, cap)
r = randamas x standartinis nuokrypis;
x = randamas x – vidurkis(x) vektorius;
xData = randama x/r reikšmė;
comp = ilgis(x) - ilgis(cap);
yData = sudaromos tikslo reikšmės;
ym = min(yData);
yr = max(yData) - min(yData);
yData = (yData - ym)/yr;
```

15 pav. Duomenų standartizavimo pseudokodas

3.1.5. Min-max normalizavimas

Min-max normalizavimas buvo atliekamas pagal formulę:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (8)$$

Atliekant tyrimą buvo sukurta funkcija *minmax_norm.m*, kurioje buvo atliekami duomenų normalizavimo veiksmai. Funkcijos įvestis – struktūrinis akumulatoriaus duomenų failas, pradinė akumulatoriaus talpa ir akumulatoriaus talpos vektorius kiekvienu laiko momentu. Toliau yra pateiktas duomenų normalizavimo funkcijos pseudokodas (žr. 16 pav.).

```
function [xData, yData, ym, yr] = minmax_norm(x, C, cap)
r = randamas skirtumas tarp maksimalių ir minimalių, kiekvieno duomenų stulpelio, x reikšmių
xx = randamas skirtumas tarp tikrųjų x reikšmių ir minimalių kiekvieno stulpelio x reikšmių;
xData = randamas xx/r santykis;
comp = ilgis(x) - ilgis(cap);
yData = sudaromos tikslo reikšmės;
ym = min(yData);
yr = max(yData) - min(yData);
yData = (yData - ym)/yr;
```

16 pav. Min-max normalizavimo pseudokodas

Šie pertvarkymai buvo taikomi tiek kompleksiniam prognozavimui, kai naudojami sujungti I, V, t duomenys, tiek ir vertinant talpą pagal vieną pasirinktą parametą.


3.2. Atskiro akumulatoriaus talpos vertinimas

Buvo atliekami bandymai, kai akumulatoriaus talpos prognostinis modelis realizuojamas remiantis tik vienu iš kelių parametrų, t. y. tik: srove (I), įtampa (V) ar temperatūra (t). Duomenys buvo transformuojami standartizavimo ir min-max normalizavimo metodais bei apmokomi du vienkrypčiai neuroniniai tinklai – turintys dešimt ir keturiasdešimt neuronų paslėptajame sluoksnyje.

3.2.1. Atskiro neuroninio tinklo pritaikymo pavyzdys

Pirmiausia buvo pritaikytas ir išanalizuotas vienas FNN tinklas. Pavyzdiniame tinkle buvo naudojamas prognostinis modelis, kai į jį įtraukiami visi trys akumulatoriaus vidiniai parametrai (I, V, t), min-max normalizavimas, FNN turintis keturiasdešimt neuronų paslėptajame sluoksnyje ir 5-tojo akumulatoriaus duomenys.


Sėkmingam tinklo apmokymui prireikė 11 epochų ir tai užtruko 12 sekundžių.



17 pav. Neuroninio tinklo rezultatų kitimo kreivė apmokymo metu

Stebint neuroninio tinklo rezultatų kitimo grafą (žr. 17 pav.) matyti, kad vidutinė kvadratinė paklaida mažėjo apmokant tinklą. Šiame grafe matomas mokymosi (mėlyna linija), validavimo (žalia linija) ir testavimo (raudona linija) rinkinių našumas. Galutiniu tinklu yra pasirenkamas tas, kuris geriausiai veikia pagal validavimo duomenis. Šiuo atveju, geriausias rezultatas buvo gautas penktoje epochoje, kai MSE paklaida buvo 0,00053261 Ah.

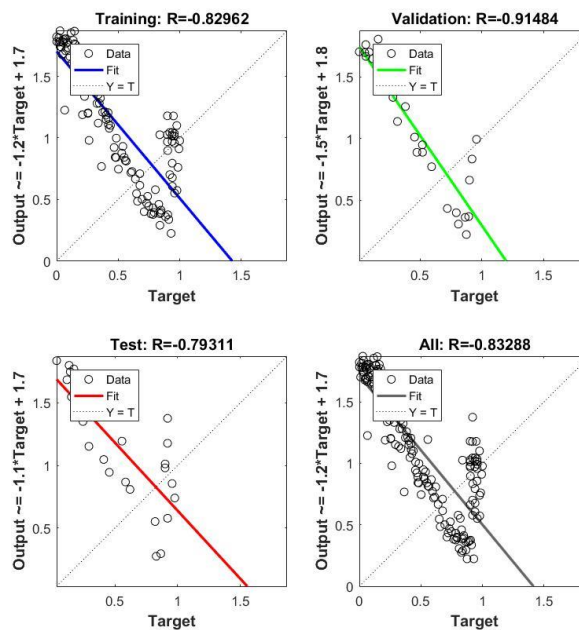
Dar vienas būdas nustatyti kaip neuroninis tinklas pritaiko duomenis (prisiderina prie duomenų), yra paklaidų histograma (žr. 18 pav.).



18 pav. Neuroninio tinklo paklaidų histograma

Šioje histogramoje (žr. 18 pav.) yra matoma, kaip pasiskirstę paklaidų dydžiai skirtingoms imtims. Šios paklaidų reikšmės vaizduoja, kaip prognozuojamos (išvesties) reikšmės skiriasi nuo tikrųjų (tikslų) reikšmių. Iš histogramos matyti, kad paklaidos yra gana toli nutolusios nuo 0 ir ypač didelė jų koncentracija yra ties -1,653 reikšme. Kadangi daugiau reikšmių nutolusių į neigiamą pusę, galima daryti išvadą, kad modeliui sunkiai sekasi prognozuoti talpos šuolius ir dažniausiai jie yra pervertinami, t. y. prognozuojama didesnė reikšmė, negu yra.

Dar vienas prognozės atitikimo matas yra regresijos grafas (žr. 19 pav.). Regresijos grafas yra taikomas visiems duomenų rinkiniams ir rodo tikrąsias tinklo išvestis, nubraižytas pagal susijusias tikslo reikšmes. Šiuo atveju, visiems duomenims buvo gauta regresijos lygtis: $y^* = -1,2 \cdot y + 1,7$. Taip pat matyti, kad ji nėra visiškai tiksli, nes nemaža dalis duomenų yra nutolusių nuo regresijos linijos.



19 pav. Neuroninio tinklo regresija

Toliau buvo atliekamos talpos prognozės atskiram penktajam akumuliatoriui.

3.2.2. Talpos prognozavimas remiantis vienu parametru

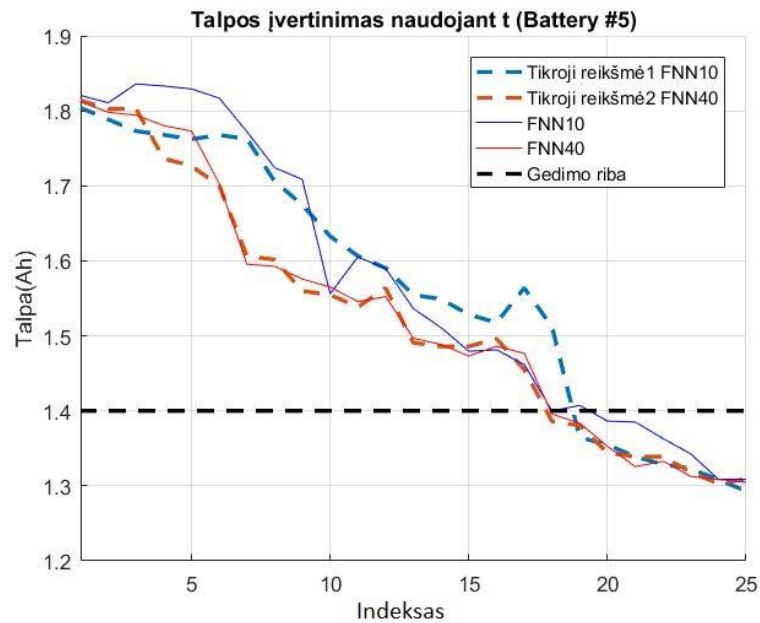
Atliktų prognozių vidutinės MAE ir RMSE paklaidų reikšmės yra pateiktos pirmoje lentelėje (žr. 1 lentelę). Lentelėje, geltonai pažymėta mažiausia penktojo akumuliatoriaus MAE paklaida, žaliai – mažiausia gauta RMSE paklaida. Iš gautų rezultatų matyti, kad tiksliausia prognozė buvo gauta, kai duomenų pertvarkymams buvo naudojamas min-max normalizavimas, vienkryptis neuroninis tinklas su dešimt neuronų paslėptajame sluoksnyje ir akumuliatoriaus talpa prognozuojama pagal temperatūrą (geltonas ir žalias langeliai).

1 lentelė. Penktojo akumuliatoriaus talpos prognozių paklaidos, vertinant pagal vieną parametą

| Duomenų paruošimo metodas | Neuroninis tinklas | Paklaida | I | V | t |
|---------------------------|--------------------|----------|--------|--------|--------|
| Min-max normalizavimas | FNN10 | MAE | 0,0256 | 0,0188 | 0,0185 |
| | | RMSE | 0,0508 | 0,0366 | 0,0285 |
| | FNN40 | MAE | 0,0239 | 0,0201 | 0,0214 |
| | | RMSE | 0,0599 | 0,0404 | 0,0357 |
| Standartizavimas | FNN10 | MAE | 0,0226 | 0,0203 | 0,0187 |
| | | RMSE | 0,0499 | 0,0397 | 0,0294 |
| | FNN40 | MAE | 0,0231 | 0,0200 | 0,0237 |
| | | RMSE | 0,0527 | 0,0399 | 0,0396 |

Neuroninio tinklo apmokymui buvo naudojama 70 % turimų duomenų, 15 % buvo naudojama validavimui, o likusieji 15 % - testinei prognozei. Testavimo duomenų taikymas, kai buvo gauta

mažiausia MAE paklaida, naudojant min-max normalizavimą ir talpą prognozuojant pagal temperatūrą, yra pavaizduota 20-tame paveiksle (žr. 20 pav.).



20 pav. Talpos prognozė testavimo duomenims, naudojant t ir min-max normalizavimą, (5 akum.)

Pateiktame paveiksle (žr. 20 pav.) yra vaizduojamos prognozės, kai FNN10 atveju MAE paklaida yra 0,0112 Ah, o FNN40 atveju – 0,0113 Ah. Šiame prognozės grafike matyti, kad abu atvejai nėra labai tikslūs ir prognozė turi nuokrypių. Ypač daug netikslumų matyti FNN10 atveju (mėlyna linija). Tačiau žvelgiant į šiuos geriausių prognozių grafikus būtų sunku tiksliai pasakyti, kuris metodas yra geresnis bendru atveju FNN10 ar FNN40. Tam, kad būtų tiksliai įvertintos prognozės buvo skaičiuojamos vidutinės MAE ir RMSE reikšmės. Jos buvo gaunamos, randant visų gautų paklaidų aritmetinį vidurkį.


| | <u>FNN10_epochs</u> | <u>FNN40_epochs</u> | <u>FNN10_MAE</u> | <u>FNN40_MAE</u> | <u>FNN10_RMSE</u> | <u>FNN40_RMSE</u> |
|-----------------|---------------------|---------------------|------------------|------------------|-------------------|-------------------|
| Vidurkis | 13.2 | 10.56 | 0.0185 | 0.0214 | 0.0285 | 0.0357 |
| Min | 8 | 8 | 0.0112 | 0.0113 | 0.0157 | 0.0158 |
| Max | 37 | 26 | 0.0361 | 0.0449 | 0.0627 | 0.0915 |

21 pav. Pagrindinės charakteristikos, naudojant t ir min-max normalizavimą, (5 akum.).

Stebint gautus rezultatus (žr. 21 pav.), galima matyti, kad didžiausia gauta MAE reikšmė (didžiausia prognozės paklaida) yra 0,0361 Ah, o mažiausia – 0,0112 Ah. Taip pat galima pastebėti, kad naudojant tinklą su dešimt neuronų paslėptajame sluoksnyje vienam tinklui apmokyti prireikia daugiau epochų nei tinklui su keturiasdešimt neuronų paslėptajame sluoksnyje. Tai reiškia, kad atlikti skaičiavimus naudojant FNN10 prireikia daugiau laiko. Žvelgiant į FNN40 rezultatus matoma, kad didžiausia MAE

paklaida yra 0,0449 Ah, o mažiausia – 0,0113 Ah. Stebint RMSE paklaidų dydžius pastebima tokia pati tendencija – FNN10 prognozės yra tikslesnės ir jų dispersija yra mažesnė. Taigi, jeigu geresnis metodas būtų pasirenkamas tik pagal bandymo duomenų prognozės grafiką, jis būtų mažiau tikslus. Įvertinus ne tik vidutines, bet ir minimalias, bei maksimalias reikšmes galima, daryti išvadą, kad FNN10 tinklo pagalba gautos talpos prognozės yra tikslesnės, o rezultatų dispersija yra mažesnė.

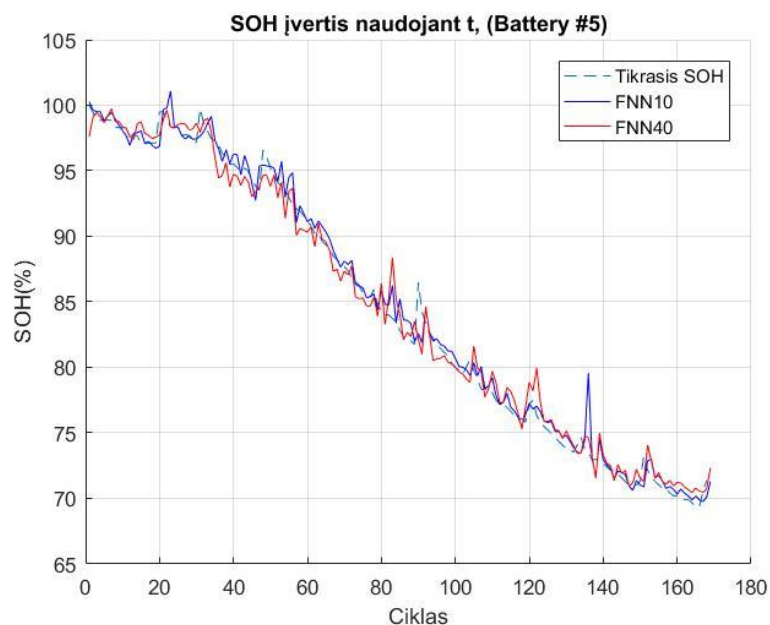
Taip pat buvo braižomas net tik bandymų duomenų prognozių grafikas bet ir pilnas visų duomenų prognozės grafikas (žr. 22 pav.).



22 pav. Talpos prognozė visiems duomenims, naudojant t ir min-max normalizavimą, (5 akum.)

Pritaikius visus duomenis apmokytam tinklui, galima pastebėti, kad modelio prognozės nedaug nukrypsta nuo tikrųjų reikšmių. Kiek daugiau didesnių nuokrypių matyti FNN40 prognozės grafike (raudona linija). Čia pastebimi didesni nuokrypiai ties 11, 44, 51 ir 56 ciklais. Taip pat galima pastebėti, kad nei vienam metodui nepavyko tiksliai įvertinti devyniasdešimtajame cikle esančio talpos šuolio į viršų. Tame cikle netgi buvo fiksuotas talpos kritimas abejais prognozių atvejais. Vien iš šio grafiko, jau būtų galima daryti prielaidą, kad FNN10 generuoja tikslesnius talpos prognozės rezultatus nei FNN40.

Iš visos talpos prognozės duomenų taip pat galima nubraižyti SOH prognozės grafiką. Jis atitinka talpos grafiką, kadangi SOH apskaičiavimams yra naudojama (3) formulė, kurioje naudojamas prognozuojamas ir tikrosios talpos santykis. Šis grafikas pateiktas šešioliktame paveiksle (žr. 23 pav.).




23 pav. SOH prognozė, naudojant t ir min-max normalizavimą, (5 akum.)

Iš gautų tyrimo rezultatų (žr. 1 lentelę) taip pat galima pastebėti, kad vertinant talpą pagal įtampą, paklaidos taip pat nėra labai didelės, kai tuo tarpu vertinant pagal srovę, paklaidos jau yra kiek didesnės.


Žvelgiant į patį blogiausią rezultatą (FNN40, duomenys standartizuoti, vertinama pagal I) matyti (žr. 24 pav.), kad MAE paklaidos didžiausia reikšmė yra 0,0556 Ah, kuri yra 54 % didesnė už geriausios prognozės didžiausią MAE reikšmę. Žvelgiant į mažiausią reikšmę, matyti, kad tiek ir FNN10, ir FNN40 yra daug mažesnė nei geriausios prognozės atveju. Tokie patys pastebėjimai matomi ir vertinant RMSE paklaidas. Galima daryti išvadą, kad vertinant pagal temperatūrą visi rezultatai yra gana panašūs, turi nedidelę paklaidų dispersiją, kai tuo tarpu vertinant pagal srovę, paklaidų nuokrypiai yra didesni, todėl sunku gauti tikslius rezultatus.

| | <u>FNN10_epochs</u> | <u>FNN40_epochs</u> | <u>FNN10_MAE</u> | <u>FNN40_MAE</u> | <u>FNN10_RMSE</u> | <u>FNN40_RMSE</u> |
|-----------------|---------------------|---------------------|------------------|------------------|-------------------|-------------------|
| Vidurkis | 17.64 | 17.6 | 0.0226 | 0.0231 | 0.0499 | 0.0527 |
| Min | 7 | 7 | 0.0091 | 0.0082 | 0.0108 | 0.01 |
| Max | 92 | 67 | 0.0504 | 0.0556 | 0.1881 | 0.2159 |

24 pav. Pagrindinės charakteristikos, naudojant I ir standartizavimą, (5 akum.)



(a)



(b)

25 pav. Talpos prognozė (a) ir SOH prognozė (b), naudojant I ir standartizavimą, (5 akum.)


3.2.3. Talpos prognozavimas remiantis keliais parametrais

Toliau buvo atliekamos prognozės bandant akumulatoriaus talpą vertinti kombinuojant parametrus, t. y. akumulatoriaus talpos prognozes atlikti remiantis ne vieno parametro pokyčiais, bet kelių. Buvo naudojamos keturios skirtingos parametru kombinacijos: (I, V), (I, t), (V, t) ir (I, V, t). Gauti rezultatai pateikti antroje lentelėje.

2 lentelė. Penktojo akumulatoriaus talpos prognozių paklaidos, vertinant pagal kelis parametrus

| Duomenų paruošimo metodas | Neuroninis tinklas | Paklaida | I, V | I, t | V, t | I, V, t |
|---------------------------|--------------------|----------|--------|--------|--------|---------|
| Min-max normalizavimas | FNN10 | MAE | 0,0187 | 0,0174 | 0,0202 | 0,0162 |
| | | RMSE | 0,0423 | 0,0384 | 0,0444 | 0,0308 |
| | FNN40 | MAE | 0,0199 | 0,0189 | 0,0217 | 0,0185 |
| | | RMSE | 0,0330 | 0,0462 | 0,0475 | 0,0399 |
| Standartizavimas | FNN10 | MAE | 0,0217 | 0,0170 | 0,0215 | 0,0205 |
| | | RMSE | 0,0452 | 0,0338 | 0,0505 | 0,0418 |
| | FNN40 | MAE | 0,0262 | 0,0196 | 0,0215 | 0,0222 |
| | | RMSE | 0,0564 | 0,0407 | 0,0492 | 0,0560 |

Stebint gautus rezultatus (žr. 2 lentelę) matyti, kad prognozė su mažiausia tiek MEA, tiek RMSE paklaida buvo gauta, kai buvo naudojami visi trys parametrai (I, V, t), duomenų paruošimui naudojamas min-max normalizavimas ir pritaikytas vienkryptis neuroninis tinklas su dešimt neuronų paslėptajame sluoksnyje (geltonas ir žalias langeliai).



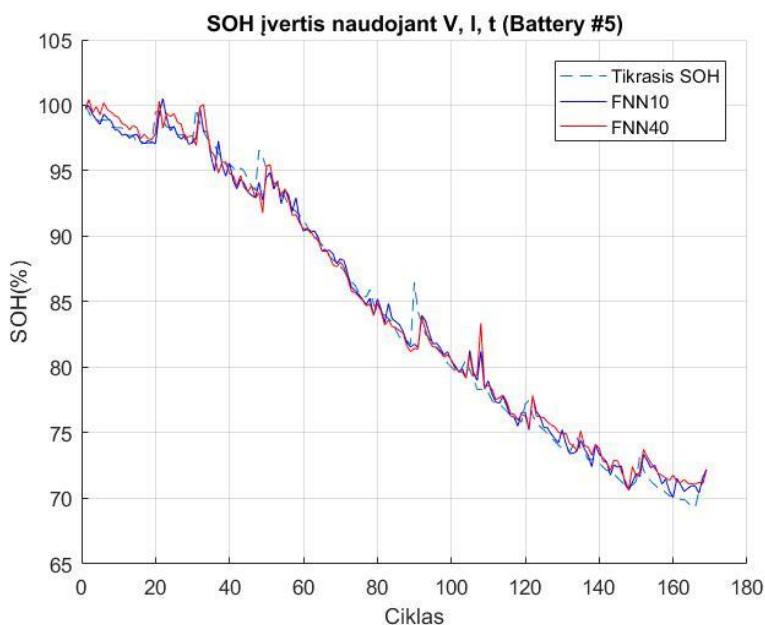
26 pav. Talpos prognozė, naudojant I, V, t ir min-max normalizavimą, (5 akum.)

Žvelgiant į prognozės grafiką (žr. 26 pav.) matyti, kad šiuo atveju prognozė yra gana tiksli ir atitinka tikrąsias reikšmes. Norint tiksliau įvertinti gautus rezultatus buvo apskaičiuotos maksimalios ir minimalios paklaidų reikšmės (žr. 27 pav.).

| | <u>FNN10_epochs</u> | <u>FNN40_epochs</u> | <u>FNN10_MAE</u> | <u>FNN40_MAE</u> | <u>FNN10_RMSE</u> | <u>FNN40_RMSE</u> |
|-----------------|---------------------|---------------------|------------------|------------------|-------------------|-------------------|
| Vidurkis | 15.28 | 13.64 | 0.0162 | 0.0185 | 0.0308 | 0.0399 |
| Min | 8 | 8 | 0.0079 | 0.006 | 0.0097 | 0.0092 |
| Max | 48 | 65 | 0.0393 | 0.0452 | 0.1103 | 0.1786 |

27 pav. Pagrindinės charakteristikos, naudojant I,V, t ir min-max normalizavimą, (5 akum.)

Iš gautų rezultatų (žr. 27 pav.) matyti, kad minimali gauta MAE paklaida naudojant tinklą su keturiasdešimt neuronų paslėptajame sluoksnyje (0,006 Ah) yra netgi mažesnė, nei naudojant tinklą su dešimt paslėptų sluoksnių (0,0079). Tačiau maksimali MAE paklaida naudojant FNN40 yra didesnė (0,0452 Ah) nei naudojant FNN10 (0,0393 Ah), o tai reiškia, kad prognozuojant su FNN10 paklaidų dispersija yra mažesnė ir rezultatai yra stabilesni. Tokias pat išvadas galima daryti ir vertinant RMSE.



28 pav. SOH prognozė, naudojant I, V, t ir min-max normalizavimą, (5 akum.)

Žvelgiant į gautą SOH prognozės grafiką (žr. 28 pav.), galima pastebėti, kad prognozės yra gana tikslios lyginant su tikrosiomis reikšmėmis. Didžiausias nuokrypis matyti, 85-tame cikle, kai abejiems FNN metodams nepavyko suprognozuoti tokio didelio talpos šuolio. Taip pat nedideli nuokrypiai matomi 50-tame ir 105-tame cikluose.

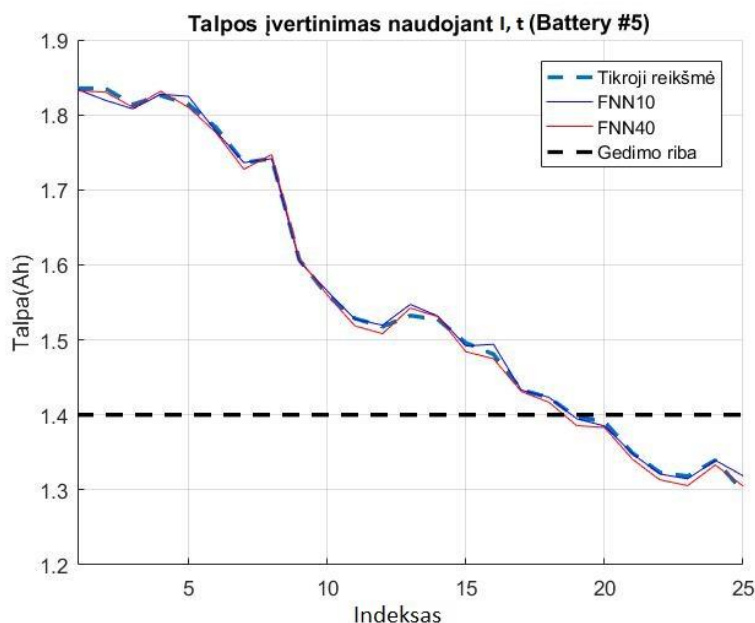
Taip pat stebint parametrų įtraukimo į prognozę visus variantus, buvo pabandyta surasti, kuris iš jų sugeneravo pačią mažiausią paklaidą. Išanalizavus visus gautus rezultatus buvo gauta, kad mažiausia MAE paklaida buvo gauta naudojant FNN10, į prognozę įtraukus tik srovę ir įtampą, o duomenų pertvarkymams naudojant standartizavimą (žr. 29 pav.).

| | <u>FNN10_epochs</u> | <u>FNN40_epochs</u> | <u>FNN10_MAE</u> | <u>FNN40_MAE</u> | <u>FNN10_RMSE</u> | <u>FNN40_RMSE</u> |
|-----------------|---------------------|---------------------|------------------|------------------|-------------------|-------------------|
| Vidurkis | 17.68 | 13.96 | 0.0217 | 0.0262 | 0.0452 | 0.0564 |
| Min | 9 | 7 | 0.005 | 0.0067 | 0.0075 | 0.0074 |
| Max | 52 | 41 | 0.0612 | 0.0835 | 0.1157 | 0.3563 |

29 pav. Pagrindinės charakteristikos, naudojant I,V ir standartizavimą, (5 akum.)

Šie rezultatai buvo kiek netikėti, nes žvelgiant į vidutines MAE reikšmes, kai prognozei naudojami I, V parametrai, buvo gauti vieni blogesnių rezultatų. Žinoma, tam įtaką daro gauta didžiausia MAE reikšmė, kuri lygi net 0,0612 Ah. Stebint RMSE paklaidų mažiausius rezultatus, taip pat buvo gauta, kad

mažiausia paklaida gaunama prieš tai minėtu atveju, tik vietoj FNN10 naudojant FNN40, ir ji yra lygi 0,0074 Ah.



30 pav. Talpos prognozė, naudojant I, V ir standartizavimą, (5 akum.)

Netgi stebint bandymo rezultatų geriausią grafiką (žr. 30 pav.), kai prognozei naudojama I, V ir duomenų standartizavimas, galima matyti, kad prognozė iš tikrųjų yra labai tiksli ir turi tik nedidelius nuokrypius ties didesniais tikrosios reikšmės kreivės išlinkimais.

Vertinant visus penkto akumulatoriaus talpos prognozių rezultatus, galima teigti, kad kombinuojant parametrus ir prognozei naudojant srovės, įtampos ir temperatūros duomenis, galima pasiekti tiksliausių rezultatus vertinant paklaidą pagal vidutinį MEA įvertį. Vertinant rezultatus pagal RMSE pats geriausias vidutinis rezultatas yra prognozuojant pagal temperatūrą, tačiau vertinant pagal visus tris parametrus vidutinė RMSE paklaida taip pat nėra didelė ir nuo geriausio rezultato skiriasi labai nedaug. Taip pat minimali rasta RMSE reikšmė yra mažesnė, kai prognozuojama pagal tris parametrus, o ne tik pagal temperatūrą. Be to, iš rezultatų galima išvelgti, kad prognozuojant pagal du parametrus rezultatai taip pat yra šiek tiek geresni, negu prognozuojant tik pagal vieną. O atliekant talpos prognozę pagal įtampą ir srovę buvo gautos pačios mažiausios MAE ir RMSE paklaidos.

3.3. Akumuliatorių tyrimo rezultatai

Norint įsitikinti ar tikrai kelių parametru kombinavimas yra efektyvus būdas prognozuoti talpą, eksperimentai buvo atlikti su dar trimis akumulatoriais. Visi rezultatai pateikti trečioje lentelėje (žr. 3 lentelę).

3 lentelė. Talpos prognozių paklaidų rezultatai

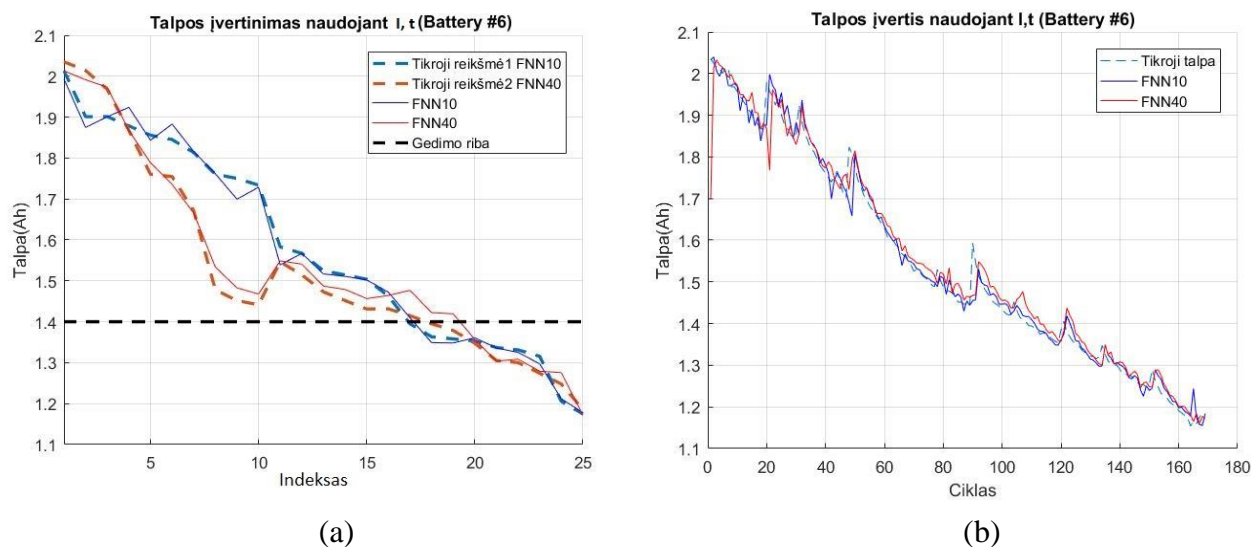
| Nr. | Duomenų paruošimo metodas | Neuroninis tinklas | Paklaida | I | V | t | I, V | I, t | V, t | I, V, t |
|-------------|---------------------------|--------------------|----------|--------|--------|--------|--------|--------|--------|---------|
| 5 akum. | Min-max normalizavimas | FNN10 | MAE | 0,0256 | 0,0188 | 0,0185 | 0,0187 | 0,0174 | 0,0202 | 0,0162 |
| | | | RMSE | 0,0508 | 0,0366 | 0,0285 | 0,0423 | 0,0384 | 0,0444 | 0,0308 |
| | | FNN40 | MAE | 0,0239 | 0,0201 | 0,0214 | 0,0199 | 0,0189 | 0,0217 | 0,0185 |
| | | | RMSE | 0,0599 | 0,0404 | 0,0357 | 0,0330 | 0,0462 | 0,0475 | 0,0399 |
| | Standartizavimas | FNN10 | MAE | 0,0226 | 0,0203 | 0,0187 | 0,0217 | 0,0170 | 0,0215 | 0,0205 |
| | | | RMSE | 0,0499 | 0,0397 | 0,0294 | 0,0452 | 0,0338 | 0,0505 | 0,0418 |
| FNN40 | MAE | 0,0231 | 0,0200 | 0,0237 | 0,0262 | 0,0196 | 0,0215 | 0,0222 | | |
| | RMSE | 0,0527 | 0,0399 | 0,0396 | 0,0564 | 0,0407 | 0,0492 | 0,0560 | | |
| 6 akum. | Min-max normalizavimas | FNN10 | MAE | 0,0313 | 0,0399 | 0,0314 | 0,0380 | 0,0327 | 0,0367 | 0,0321 |
| | | | RMSE | 0,0614 | 0,0759 | 0,0514 | 0,0682 | 0,0573 | 0,0704 | 0,0714 |
| | | FNN40 | MAE | 0,0360 | 0,0470 | 0,0392 | 0,0347 | 0,0301 | 0,0349 | 0,0379 |
| | | | RMSE | 0,0755 | 0,0835 | 0,0754 | 0,0669 | 0,0536 | 0,0720 | 0,0819 |
| | Standartizavimas | FNN10 | MAE | 0,0342 | 0,0539 | 0,0329 | 0,0426 | 0,0303 | 0,0309 | 0,0429 |
| | | | RMSE | 0,0723 | 0,1092 | 0,0540 | 0,0907 | 0,0585 | 0,0569 | 0,1006 |
| FNN40 | MAE | 0,0372 | 0,0535 | 0,0387 | 0,0482 | 0,0352 | 0,0354 | 0,0420 | | |
| | RMSE | 0,0748 | 0,1127 | 0,0684 | 0,1161 | 0,0691 | 0,0617 | 0,0998 | | |
| 7 akum. | Min-max normalizavimas | FNN10 | MAE | 0,0179 | 0,0217 | 0,0187 | 0,0189 | 0,0143 | 0,0200 | 0,0182 |
| | | | RMSE | 0,0344 | 0,0380 | 0,0321 | 0,0441 | 0,0233 | 0,0357 | 0,0274 |
| | | FNN40 | MAE | 0,0249 | 0,0198 | 0,0187 | 0,0222 | 0,0160 | 0,0247 | 0,0201 |
| | | | RMSE | 0,0503 | 0,0378 | 0,0312 | 0,0559 | 0,0271 | 0,0418 | 0,0358 |
| | Standartizavimas | FNN10 | MAE | 0,0178 | 0,0259 | 0,0190 | 0,0161 | 0,0142 | 0,0210 | 0,0144 |
| | | | RMSE | 0,0443 | 0,0541 | 0,0318 | 0,0277 | 0,0303 | 0,0372 | 0,0296 |
| FNN40 | MAE | 0,0205 | 0,0334 | 0,0228 | 0,0193 | 0,0161 | 0,0227 | 0,0190 | | |
| | RMSE | 0,0448 | 0,0652 | 0,0378 | 0,0351 | 0,0316 | 0,0440 | 0,0467 | | |
| 18 akum. | Min-max normalizavimas | FNN10 | MAE | 0,0326 | 0,0257 | 0,0367 | 0,0196 | 0,0262 | 0,0266 | 0,0223 |
| | | | RMSE | 0,0697 | 0,0425 | 0,0678 | 0,0325 | 0,0513 | 0,0484 | 0,0446 |
| | | FNN40 | MAE | 0,0326 | 0,0304 | 0,0442 | 0,0241 | 0,0258 | 0,0282 | 0,0242 |
| | | | RMSE | 0,0817 | 0,0479 | 0,0814 | 0,0466 | 0,0499 | 0,0555 | 0,0457 |
| | Standartizavimas | FNN10 | MAE | 0,0429 | 0,0338 | 0,0431 | 0,0200 | 0,0449 | 0,0285 | 0,0268 |
| | | | RMSE | 0,0847 | 0,0545 | 0,0881 | 0,0343 | 0,0838 | 0,0557 | 0,0612 |
| FNN40 | MAE | 0,0320 | 0,0336 | 0,0519 | 0,0269 | 0,0278 | 0,0275 | 0,0303 | | |
| | RMSE | 0,0635 | 0,0605 | 0,0997 | 0,0597 | 0,0488 | 0,0569 | 0,0666 | | |

Stebint visų akumuliatorių gautus rezultatus (žr. 3 lentelę) labiausiai išsiskiria šeštojo akumulatoriaus rezultatai. Visos paklaidos, tiek MEA tiek RMSE yra kur kas didesnės nei kitų akumuliatorių. Geriausia prognozė pagal MAE vis tiek yra su 0,0303 Ah paklaida, pagal RMSE ši paklaida dar didesnė – kiek daugiau nei 0,05 Ah (0,0514).

| | FNN10_epochs | FNN40_epochs | FNN10_MAE | FNN40_MAE | FNN10_RMSE | FNN40_RMSE |
|----------|--------------|--------------|-----------|-----------|------------|------------|
| Vidurkis | 15.76 | 10.2 | 0.0303 | 0.0352 | 0.0585 | 0.0691 |
| Min | 7 | 7 | 0.014 | 0.0216 | 0.0183 | 0.0266 |
| Max | 33 | 18 | 0.116 | 0.0948 | 0.1567 | 0.3432 |

31 pav. Pagrindinės charakteristikos, naudojant I, t ir standartizavimą, (6 akum)

Žvelgiant į minimalias ir maksimalias šeštojo akumulatoriaus paklaidas esant geriausiam rezultatui, matyti, kad MAE paklaida siekia net 0,014 Ah, o tuo tarpu maksimali paklaida yra apie 0,1 Ah.



32 pav. Talpos prognozė testavimo duomenims (a) ir visiems duomenims (b), naudojant I, t ir standartizavimą, (6 akum.)

Netgi žvelgiant į bandymo duomenų talpos vertinimo prognozę ir visų duomenų prognozę (žr. 32 pav.) matyti, kad prognozės nėra labai tikslios ir turi nemažai nuokrypių.

Patys tiksliausi rezultatai buvo sugeneruoti septintajam akumulatoriui. O mažiausia gauta MAE paklaida yra 0,005 Ah, mažiausia RMSE paklaida taip pat nesiekia 0,01 Ah (0,0067 Ah) (žr. 33 pav.).

| | FNN10_epochs | FNN40_epochs | FNN10_MAE | FNN40_MAE | FNN10_RMSE | FNN40_RMSE |
|-----------------|---------------------|---------------------|------------------|------------------|-------------------|-------------------|
| Vidurkis | 15.96 | 12.16 | 0.0142 | 0.0161 | 0.0303 | 0.0316 |
| Min | 8 | 7 | 0.005 | 0.0077 | 0.0067 | 0.0103 |
| Max | 37 | 26 | 0.0291 | 0.0469 | 0.1059 | 0.0983 |

33 pav. Pagrindinės charakteristikos, naudojant I, t ir standartizavimą, (7 akum.)

Tiriant visus akumulatorius buvo norėta patvirtinti, kad visų parametų įtraukimas į prognozę yra pats efektyviausias, tačiau stebint pačius geriausius gautus kiekvieno akumulatoriaus rezultatus (žr. 3 lentelę) matyti, kad taip nėra. Geriausio prognostinio modelio rezultatai, vertinant pagal MAE, buvo gauti įtraukiant I ir t parametrus (2 iš 4 akumuliatorių atveju), vertinant pagal RMSE geriausia prognozė yra vertinant pagal temperatūrą (2 iš 4 akumuliatorių atveju).

Norint išsiaiškinti, kokių parametų įtraukimas į talpos prognozę iš tiesų yra tikslesnis bendru atveju, buvo sudaryta rangų lentelė (žr. 1 priedas). Sudarinėjant ją buvo neatsižvelgiama į duomenų apdorojimo

metodą bei taikytą neuroninį tinklą. Rangai buvo sudarinėjami kiekvieno akumulatoriaus, visų metodų, MAE ir RMSE paklaidoms. Mažiausią paklaidą turinčiam parametru buvo priskiriamas 1, didžiausiam – 7. Mažiausią bendrą rangų sumą surinkęs parametras ar jų grupė yra laikomi efektyviausiu. Apibendrinti rezultatai pateikti 4lentelėje.

4 lentelė. Rangų lentelės santrauka, tinkamiausiems prognozei parametrams rasti

| | I | V | t | I, V | I, t | V, t | I, V, t |
|------------|-----|-----|-----|------|------|------|---------|
| Rangų suma | 164 | 158 | 126 | 119 | 78 | 136 | 115 |

Apžvelgus gautus rezultatus, negalima teigti, kad visų trijų parametrų įtraukimas į prognozę yra pats efektyviausias. Žvelgiant į rangų lentelę (žr. 4 lentelę) matyti, kad geriausi rezultatai yra gaunami, kai talpos prognozė yra atliekama pagal srovės ir temperatūros parametrus. Blogiausi rezultatai gaunami, kai prognozė atliekama pagal atskirą srovės arba įtampos parametras. Taigi galima daryti išvadą, kad kelių parametrų įtraukimas į prognozę yra efektyvesnis nei prognozuojant pagal vieną parametras, tačiau nebūtina naudoti visų trijų. Visų parametrų įtraukimas reikalauja didesnių laiko ir įrangos resursų, todėl tyrėjui reiktų nusistatyti, kokia tikslumo riba turėtų būti pasiekta ir pasirinkti tinkamą metodą.

3.4. Duomenų paruošimo įtaka rezultatams

Atliktame tyrime buvo naudojami du duomenų paruošimo metodai min-max normalizavimas ir duomenų standartizavimas. Plačiau jie aprašyti 3.1.4 ir 3.1.5 skyreliuose. Norint išsiaiškinti ar duomenų paruošimas turi įtakos rezultatams, buvo parengta rezultatų rangų lentelė, kurioje reitinguojamos paklaidų reikšmės pagal duomenų paruošimo būdą. Geresniam rezultatui buvo suteikta reikšmė 1, blogesniam (turinčiam didesnę paklaidą) – 2. Pilna rangų lentelė yra pateikta antrame priede (žr. 2 priedas).

5 lentelė. Rangų lentelės santrauka, geriausiam duomenų paruošimo metodui rasti

| 5 akumuliatorius | | 6 akumuliatorius | | 7 akumuliatorius | | 18 akumuliatorius | |
|------------------------|------------------|------------------------|------------------|------------------------|------------------|------------------------|------------------|
| Min-max normalizavimas | Standartizavimas | Min-max normalizavimas | Standartizavimas | Min-max normalizavimas | Standartizavimas | Min-max normalizavimas | Standartizavimas |
| 37 | 47 | 34 | 50 | 40 | 44 | 32 | 52 |

Atlikus rezultatų rangavimą, gauti rezultatai pateikti penktoje lentelėje (žr. 5 lentelę). Iš jos galima matyti, kad visų akumuliatorių prognozėms geresnius rezultatus generavo duomenys, kurie buvo paruošti min-max normalizavimo metodu. Mažiausias skirtumas tarp metodų buvo pastebimas 7 akumulatoriaus atveju, kurio prognozė buvo ir pačios tiksliausia. Netgi pati mažiausia MAE paklaida buvo gauta, kai duomenys buvo standartizuoti. Blogiausiai standartizavimas veikė prognozuojant 18 akumulatoriaus talpą.

Iš gautų rezultatų galima daryti išvadą, kad min-max normalizavimas yra kur kas efektyvesnis už duomenų standartizavimą, kai yra naudojamas vienkryptis neuroninis tinklas. Todėl atliekant SOH prognozes duomenų paruošimui reiktų rinktis min-max normalizavimą.

3.5. Neuroninio tinklo architektūros įtaka rezultatams

Taip pat šiame tyrime buvo taikyti du skirtingi vienkrypčio neuroninio tinklo modeliai, kurie skiriasi naudojamų neuronų paslėptajame sluoksnyje skaičiumi. Tam, kad būtų nustatyta, ar neuroninis tinklas su daugiau neuronų paslėptajame sluoksnyje gali generuoti geresnius rezultatus, buvo sudaryta rezultatų rangų lentelė, kuri pateikta trečiame priede (žr. 3 priedas).

6 lentelė. Rangų lentelės santrauka, efektyvesniam neuroniniam tinklui rasti

| 5 akumuliatorius | | | | 6 akumuliatorius | | | | 7 akumuliatorius | | | | 18 akumuliatorius | | | |
|------------------------|--------|------------------|--------|------------------------|--------|------------------|--------|------------------------|--------|------------------|--------|------------------------|--------|------------------|--------|
| Min-max normalizavimas | | Standartizavimas | | Min-max normalizavimas | | Standartizavimas | | Min-max normalizavimas | | Standartizavimas | | Min-max normalizavimas | | Standartizavimas | |
| FN N10 | FN N40 | FN N10 | FN N40 | FN N10 | FN N40 | FN N10 | FN N40 | FN N10 | FN N40 | FN N10 | FN N40 | FN N10 | FN N40 | FN N10 | FN N40 |
| 16 | 26 | 15 | 24 | 19 | 23 | 17 | 25 | 16 | 23 | 14 | 28 | 15 | 24 | 20 | 22 |

Atlikus neuroninių tinklų rangavimą, gauti rezultatai pateikti 6-oje lentelėje (žr. 6 lentelę). Iš gautų rezultatų galima matyti, kad visais atvejais vienkryptis neuroninis tinklas su dešimt neuronų paslėptajame sluoksnyje generavo rezultatus su mažesnėmis paklaidomis nepriklausomai nuo to, koks duomenų apdorojimas buvo atliktas. Didžiausias skirtumas buvo prognozuojant 7 akumuliatoriaus talpą ir naudojant standartizuotus duomenis. Beje, būtent šio varianto vidutinė MAE prognozė ir buvo pati mažiausia iš visų. Mažiausias skirtumas tarp metodų buvo atliekant prognozę 18-tam akumuliatoriui, kai naudojamas duomenų standartizavimas.

Iš gautų rezultatų galima daryti išvadą, kad neverta naudoti vienkrypčio neuroninio tinklo, turinčio daugiau neuronų sluoksnyje. Didesnis neuronų skaičius paslėptajame sluoksnyje, gali sąlygoti persimokymą, nes yra generuojama daugiau koeficientų tinkle ir jų didesnis kiekis įgalina per didelį prisiderinimą prie mokymosi duomenų imties, kas turi neigiamos įtakos rezultatų tikslumui, kai vykdoma prognozė su kitokiais duomenimis.

Apžvelgus visus gautus rezultatus, galima daryti prielaidą, kad norint tiksliausiai nustatyti SOH reikšmę, geriausia naudoti talpos prognozę remiantis srovės ir temperatūros parametrais, duomenims taikant

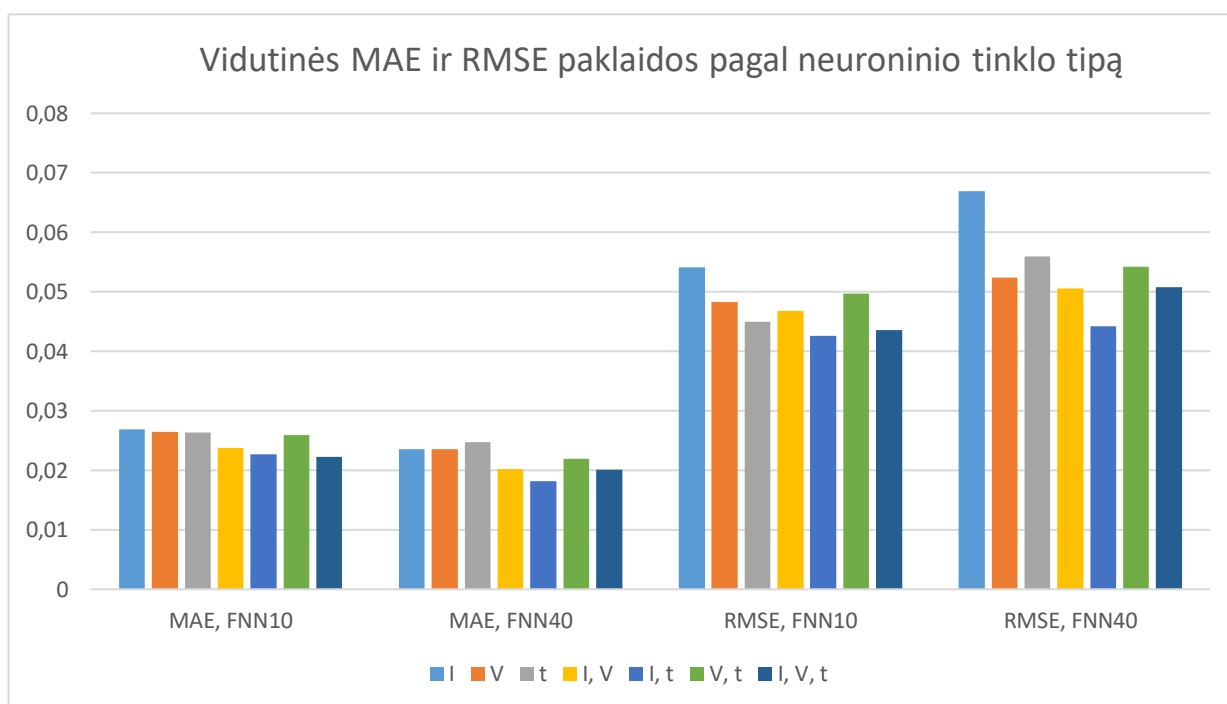
min-max normalizavimą ir naudojant vienkryptį neuroninį tinklą su dešimt neuronų paslėptajame sluoksnyje.

3.6. Atliktų tyrimų palyginimas su kitų gautais rezultatais

Kaip jau minėta anksčiau (žr. 1.5.2 skyrelyje), šiame tyrime naudojama duomenų aibė yra gana populiarė ir yra atlikta nemažai SOH prognozės kitokių skaičiavimų ir tyrimų su ja, todėl šiame tyrime gauti rezultatai buvo palyginti su dviem, anksčiau atliktų, tyrimų rezultatais.

7 lentelė. Vidutinės MAE ir RMSE paklaidos pagal neuroninio tinklo tipą, naudojant min-max normalizavimą

| | I | V | t | I, V | I, t | V, t | I, V, t |
|-------------------------------|--------|--------|--------|--------|--------|--------|---------|
| Vidutinė MAE paklaida, FNN10 | 0,0269 | 0,0265 | 0,0263 | 0,0238 | 0,0227 | 0,0259 | 0,0222 |
| Vidutinė MAE paklaida, FNN40 | 0,0235 | 0,0235 | 0,0247 | 0,0202 | 0,0182 | 0,0219 | 0,0201 |
| Vidutinė RMSE paklaida, FNN10 | 0,0541 | 0,0483 | 0,0450 | 0,0468 | 0,0426 | 0,0497 | 0,0436 |
| Vidutinė RMSE paklaida, FNN40 | 0,0669 | 0,0524 | 0,0559 | 0,0506 | 0,0442 | 0,0542 | 0,0508 |



34 pav. Vidutinių MAE ir RMSE paklaidų, pagal neuroninio tinklo tipą, grafikas

Šiame tyrime buvo apskaičiuotos vidutinės MAE ir RMSE paklaidos pagal neuroninio tinklo tipą (žr. 7 lentelę) bei pavaizduotos grafiškai (žr. 34 pav.). Jos buvo palygintos su kitu tyrimu [6], kurio patikrinimui ir buvo atliktas šis eksperimentas. 2019 metais atlikto tyrimo metu gautos MAE ir RMSE paklaidos pateiktos aštuntoje lentelėje (žr. 8 lentelę).


8 lentelė. Vidutinės MAE ir RMSE paklaidos, gautos 2019 metais atliktame tyrime [6]

| | V | I, V, t |
|-------------------------------|--------|---------|
| Vidutinė MAE paklaida, FNN10 | 0,0655 | 0,0329 |
| Vidutinė MAE paklaida, FNN40 | 0,0557 | 0,0242 |
| Vidutinė RMSE paklaida, FNN10 | 0,0736 | 0,0379 |
| Vidutinė RMSE paklaida, FNN40 | 0,0633 | 0,0298 |

Lyginant šiuos dviejų tyrimų rezultatus (žr. 7 ir 8 lenteles) galima pastebėti, kad anksčiau atliktame tyrime MAE paklaidos yra didesnės nei gautos šio tyrimo metu. Ypač didelis skirtumas pastebimas, kai talpos prognozė buvo atliekama remiantis tik įtampos parametru. Stebint RMSE paklaidas matyti, kad anksčiau atliktame tyrime jos yra mažesnės, kai prognozei naudojami visi trys parametrai, tačiau jos gerokai didesnės, kai prognozė remiasi tik įtampos duomenimis.

Visi šie rezultatų skirtumai galėjo atsirasti dėl skirtingo eksperimentų kiekio. Kito tyrimo atveju, kiekviena prognozė buvo atliekama vieną kartą, tai reiškia, kad galėjo pasitaikyti tiek labai geras prognozės atvejis, tiek ir vienas blogesnių. Šio tyrimo metu prognozės buvo atliekamos 25 kartus ir randamos vidutinės paklaidos, tokiu atveju buvo vengiama atsitiktinumų ir randamas galimai labiau realią situaciją atitinkantis rezultatas. 3.2. skyrelyje buvo išanalizuoti penkto akumulatoriaus rezultatai ir galima buvo pastebėti, kad skirtumas tarp maksimalių ir minimalių paklaidų yra gana didelis (žr. 3.2. skyrelį). Dar viena priežastis, kodėl gali skirtis rezultatai yra programinės įrangos skirtumai. Kito tyrimo metu, neuroniniams tinklams apmokyti buvo naudojama *Python Tensorflow* programinė įranga. Šiam tyrimui realizuoti buvo pasitelkta *MATLAB* programinė įranga su neuroninių tinklų priemonių rinkiniu.

Be to, tam pačiam duomenų rinkiniui kitų autorių buvo atliktas SOH prognozavimas remiantis GPR modeliu [13]. Prognozės buvo atliekamos remiantis įtampos ir srovės duomenimis, kurie gauti pradiniais duomenims pritaikius IC kreives ir panaudojus GPR. Tyrimo metu buvo gauta, kad paklaidos 5-tojo akumulatoriaus testavimo duomenims siekia apie 1,2 %, o tai yra apie 0,0324 Ah (pilna 5-tojo akumulatoriaus talpa yra 2,7 Ah). Kitų akumuliatorių MAE paklaidos yra kiek mažesnės – nesiekė 0,5 % (žr. 35 pav.). Taip pat buvo gauta, kad visų keturių akumuliatorių RMSE paklaidos siekia apie 1 % t. y. apie 0,027 Ah. Didžiausia RMSE paklaida buvo gauta 5-tam akumuliatoriui ir yra lygi 1,38 % (0,0373 Ah), o mažiausia gauta septintam akumuliatoriui – 0,78% (0,0172 Ah).



35 pav. Gauso proceso regresijos modeliu gautų MAE ir RMSE paklaidų grafikas. Šaltinis [13]

Tuo tarpu, šiuo tyrimo metu, kai buvo naudotas vienkryptis neuroninis tinklas, gauta mažiausia vidutinė MAE paklaida 5 akumuliatoriui buvo 0,0162 Ah (žr. 3 lentelę), o tai yra mažesnė paklaida nei naudojant GPR modelį. Jeigu vertintume 5-tą akumuliatorių pagal RMSE, taip pat yra gauta, kad neuroninio tinklo prognozės generuoja mažesnes paklaidas – atitinkamai 0,0285 Ah (žr. 3 lentelę) ir 0,0373 Ah (žr. 35 pav.).

Lyginant šiuos du tyrimus taip pat galima pastebėti, kad abejais atvejais mažiausios paklaidos gautos prognozuojant 7-to akumuliatoriaus talpą. Tačiau taikant neuroninius tinklus, didžiausios paklaidos gautos 6-tam akumuliatoriui, kai tuo tarpu naudojant GPR modelį – prognozuojant 5-to akumuliatoriaus talpą.

Palyginus šiame darbe aprašyto tyrimo prognozes su anksčiau atliktais tyrimais, galima daryti išvadas, kad yra tikslinga ličio jonų akumuliatorių talpos prognostiniam modeliui taikyti vienkryptį neuroninį tinklą. Be abejo, rezultatų tikslumas priklauso nuo turimų duomenų apdorojimo būdo ir parametrų įtraukimo į prognozę, tačiau palyginus su Gauso proceso regresijos modelio taikymu, vienkrypčio neuroninio tinklo modelis prognozuoja talpą su mažesnėmis paklaidomis.

Išvados

Nagrinėjant akumuliatorių valdymo sistemos principus, buvo nustatyta, kad vidinių būsenų vertinimas yra vienas iš esminių faktorių, užtikrinančių jos efektyvų veikimą. Tyrimo metu buvo sudaromas prognostinis modelis, galintis atlikti kuo tikslesnes talpos prognozes akumuliatoriams senstant. Į šiuos modelius buvo įtraukiami srovės, įtampos bei temperatūros vidiniai parametrai, pagal kurių pokyčius laike buvo atliekamas prognozavimas. Taip pat, buvo išanalizuota papildomų faktorių įtaka prognostinio modelio tikslumui. Išsprendus pagrindinius uždavinius galima daryti šias išvadas:

1. Apžvelgus literatūrą galima teigti, kad akumuliatorių valdymo sistema yra itin svarbi norint užtikrinti efektingą akumuliatorių veikimą, tačiau jos atskirų etapų įgyvendinimas yra sudėtingas procesas. Įveikus pirmąjį iššūkį ir sudarius priimtina modelį, toliau yra vertinamos vidinės būsenos, tokios kaip įkrovimo būseną (SOC) ar kokybiško veikimo būseną (SOH). Jų įverčiams rasti yra naudojami įvairūs matematiniai metodai: Kalmano ar dalelių filtrai, stebėjimais paremti metodai, dirbtiniu intelektu besiremiantys metodai – neuroniniai tinklai, dalelių spiečiaus algoritmai, atraminių vektorių metodai ir jų modifikacijos.
2. Realizavus vienkryptį neuroninį tinklą ir atlikus akumuliatorių talpos prognozes keturiems ličio jonų akumuliatoriams, tiksliausias rezultatas buvo gautas, prognozuojant septinto akumuliatoriaus talpą. Šios prognozės vidutinė absoliutinė paklaida (MAE) yra 0,0142 Ah (0,65 %), o vidutinė kvadratinė paklaida (RMSE) yra lygi 0,0233 (1,06 %). Atlikus rezultatų rangavimą, pagal į modelį įtraukiamus vidinius akumuliatoriaus parametrus, buvo nustatyta, kad paklaidos dydį vertinant pagal MAE, tiksliausias prognostinis modelis gaunamas, kai į jį įtraukiami srovės ir temperatūros parametrai. Tokio modelio vidutinė MAE paklaida yra 0,0227 Ah, vidutinė RMSE paklaida 0,0426 Ah.
3. Tiriant duomenų apdorojimo metodų įtaką prognozių tikslumui, buvo sudarinėjama rezultatų rangų lentelė. Palyginus min-max normalizavimo ir standartizavimo metodais apdorotų duomenų prognozių tikslumus, buvo nustatyta, kad visų akumuliatorių talpos prognozavimo rezultatai turi mažesnes paklaidas tada, kai duomenims, pateikiamiems neuroniniam tinklui, buvo atliktas min-max normalizavimas.
4. Taip pat buvo sudarinėjama rezultatų rangų lentelė, nustatinėjant neuroninio tinklo architektūros įtaką rezultatų tikslumui. Ją išanalizavus buvo nustatyta, kad visais atvejais vienkrypčio neuroninio tinklo su dešimt neuronų paslėptajame sluoksnyje talpos prognozių paklaidos buvo mažesnės, nepriklausomai nuo to, koks duomenų apdorojimo metodas buvo pasirinktas. Neuroninio tinklo su didesniu neuronų skaičiumi paslėptajame sluoksnyje tikslumui įtakos galėjo turėti persimokymas.

5. Tyrimo metu gauto prognostinio modelio rezultatai buvo lyginami su kitais tyrimais. Buvo pastebėta, kad į prognostinį modelį įtraukus tik srovės ir temperatūros parametrus yra gaunami tikslesni talpos prognozės rezultatai, kai prognozavimui naudojamas tas pats vienkryptis neuroninis tinklas ir lyginama pagal MAE. Taip pat, modelio, su vienkrypčiu neuroniniu tinklu, gautos talpos prognozių paklaidos buvo lyginamos su Gauso proceso regresijos modelio pagalba gautomis prognostinio modelio paklaidomis. Nustatyta, kad vienkrypčio neuroninio tinklo panaudojimas prognozėms yra tikslesnis. Stebint penktąjį akumuliatorių Gauso proceso regresijos modelio atveju vidutinė absoliutinė paklaida buvo gauta lygi 0,0324 Ah, o kvadratinė vidurkio paklaida - 0,0373 Ah, kai tuo tarpu neuroninio tinklo pagalba gautų talpos prognozių paklaidos atitinkamai yra 0,0162 Ah ir 0,0285 Ah. Iš gautų tyrimų palyginimų, galima teigti, kad vienkrypčio neuroninio tinklo ir priimtinių parametrų naudojimas akumuliatoriaus talpos prognostinio modelio sudarymui yra tiksliau prognozuojantis metodas.

Rekomendacijos

Duomenų analizės etape buvo išvelgta, kad ne tik srovė, įtampa ar vidinė temperatūra kinta akumuliatoriui senstant, tačiau ilgėja ir jo įkrovimo laikas. Tęsiant prognostinio modelio paieškas būtų naudinga iširti, ar įkrovimo laiko kitimo įvertinimas kiekvieno ciklo metu galėtų padėti sugeneruoti dar tikslesnes akumuliatoriaus talpos prognozes.

Taip pat būtų naudinga vienkrypti neuroninį tinklą apmokyti su kelių akumuliatorių duomenimis ir prognozavimą atlikti visiškai naujiems akumuliatoriams. Jeigu toks modeliavimas būtų gana tikslus, šis prognostinis modelis galėtų būti pritaikomas ir realiose situacijose.

Literatūros sąrašas

1. AL-HALLAJ S., SVEUM P., ONORI S., MAES S., KHAYAT N. A., TABORELLI C. Advanced battery management system design for SOC/SOH estimation for e-bikes applications. *International Journal of Powertrains*. [interaktyvus] 2016, 5(4) [žiūrėta 2020-04-15]. Prieiga per: <https://www.researchgate.net>
2. ALI M. U., ZAFAR A., NENGROO S. H., HUSSAIN S., ALVI M. J., KIM H. Towards a Smarter Battery Management System for Electric Vehicle Applications: A Critical Review of Lithium-Ion Battery State of Charge Estimation. *Energies*. [interaktyvus] 2019, 12(3), 446 [žiūrėtas 2020-04-14]. Prieiga per: doi: <https://doi.org/10.3390/en12030446>
3. BAK T., LEE S. Accurate estimation of battery soh and rul based on a progressive lstm with a time compensated entropy index. *Annual Conference of the PHM Society*. [interaktyvus] 2019, 11(1) [žiūrėtas 2020-05-16]. Prieiga per: doi: <https://doi.org/10.36001/phmconf.2019.v11i1.833>
4. *Battery University*, Types of Lithium-ion, *Learn about batteries*. [interaktyvus] 2019, BU-205, [žiūrėta 2020-05-13]. Prieiga per: <https://batteryuniversity.com/learn/>
5. CADINI F., SBARUFATTI C., CANCELLIERE F., GIGLIO M. State-of-life prognosis and diagnosis of lithium-ion batteries by data-driven particle filters. *Applied Energy*. [interaktyvus] 2019, 235, pp. 661-672 [žiūrėta 2020-05-14]. Prieiga per: doi: <https://doi.org/10.1016/j.apenergy.2018.10.095>
6. CHOI Y., RYU S., PARK K., KIM H. Machine Learning-Based Lithium-Ion Battery Capacity Estimation Exploiting Multi-Channel Charging Profiles. *IEEE Access*. [interaktyvus] 2019, 7, pp. 75143-75152 [žiūrėta 2020-04-15]. Prieiga per: <https://doi.org/10.1109/ACCESS.2019.2920932>
7. COLEMAN M., HURLEY W. G., LEE C. K. An improved battery characterization method using a two-pulse load test. *IEEE Transactions on Energy Conversion*. [interaktyvus] 2008, 23(2), pp. 708–713 [žiūrėta 2020-04-14]. Prieiga per: doi: <https://doi.org/10.1109/TEC.2007.914329>
8. GAO Y., ZHANG X., YANG J., GUO B. Estimation of State-of-Charge and State-of-Health for Lithium-Ion Degraded Battery Considering Side Reactions. *Journal of The Electrochemical Society*. [interaktyvus] 2018, 165(16) [žiūrėta 2020-04-15]. Prieiga per: <https://www.researchgate.net>
9. GOH T., PARK M., SEO M., KIM J., KIM S. Capacity estimation algorithm with a second-order differential voltage curve for Li-ion batteries with NMC cathodes. *Energies*. [interaktyvus] 2017, 135, pp. 257-268 [žiūrėta 2020-05-14]. Prieiga per: doi: <https://doi.org/10.1016/j.energy.2017.06.141>

10. GOODFELLOW I., BENGIO Y., COURVILLE A. Deep learning. *MIT Press*. [interaktyvus] 2016 [žiūrėta 2020-04-16]. Prieiga per: <http://www.deeplearningbook.org/>
11. KHUMPROM P., YODO N. A Data-Driven Predictive Prognostic Model for Lithium-ion Batteries based on a Deep Learning Algorithm. *Energies*. [interaktyvus] 2019, 12(4) [žiūrėta 2020-04-15]. Prieiga per: doi: <https://doi.org/10.3390/en12040660>
12. KONG X., BONAKDARPOUR A., WERRON B., WILKINSON D., GOPALUNI B., State of Health Estimation for Lithium-Ion Batteries. *IFAC-PapersOnLine*. [interaktyvus] 2018, 51(18), pp. 667-671 [žiūrėta 2020-05-02]. Prieiga per: doi: <https://doi.org/10.1016/j.ifacol.2018.09.347>
13. LI X., WANG., Z. State of health estimation for lithium-ion battery by combing incremental capacity analysis with Gaussian process regression. *Computer Science, Engineering*. [interaktyvus] 2019 [žiūrėta 2020-04-15]. Prieiga per: <https://www.semanticscholar.org/>
14. LIETUVIŲ KALBOS ŽODYNAS. [interaktyvus]. [žiūrėta 2020-04-15]. Prieiga per: <https://www.lietuviuzodynas.lt/terminai/Interkaliacija>
15. LIETUVIŲ KALBOS ŽODYNAS. [interaktyvus]. [žiūrėta 2020-04-16]. Prieiga per: <https://www.lietuviuzodynas.lt/terminai/Perceptronas>
16. LIU K., LI K., PENG Q., ZHANG C. A brief review on key technologies in the battery management system of electric vehicles. *Frontiers of Mechanical Engineering*. [interaktyvus] 2019, 14(1), pp. 47–64 [žiūrėta 2020-04-14]. Prieiga per: doi: <https://doi.org/10.1007/s11465-018-0516-8>
17. MIAO Q., XIE L., CUI H., LIANG W., PECHT M. Remaining useful life prediction of lithium-ion battery with unscented particle filter technique. *Microelectronics Reliability*. [Interaktyvus] 2013, 53(6), pp. 805–810. [žiūrėta 2020-01-10]. Prieiga per: doi: <https://doi.org/10.1016/j.microrel.2012.12.004>
18. NATIONAL AERONAUTICS AND SPACE ADMINISTRATION, Battery Data Set. *Prognostic center*. [interaktyvus] [žiūrėta 2020-04-15]. Prieiga per: <https://ti.arc.nasa.gov/tech/dash/groups/pcoc/prognostic-data-repository/#battery>
19. RONG P., PEDRAM M. An analytical model for predicting the remaining battery capacity of lithium-ion batteries. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems* [interaktyvus] 2006, 14(5), pp. 441-451 [žiūrėtas 2020-05-14]. Prieiga per: doi: <https://doi.org/10.1109/TVLSI.2006.876094>
20. ROSCHER M. A., ASSFALG J., BOHLEN O. S. Detection of utilizable capacity deterioration in battery systems. *IEEE Transactions on Vehicular Technology*. [interaktyvus] 2011, 60(1), pp. 98–103 [žiūrėta 2020-04-14]. Prieiga per: doi: <https://doi.org/10.1109/TVT.2010.2090370>

21. SARRE G., BLANCHARD P., BROUSSELY M. Aging of lithium-ion batteries. *Journal of Power Sources*. [interaktyvus] 2004, 177, pp. 65-71 [žiūrėtas 2020-05-14]. Prieiga per: doi: <https://doi.org/10.1016/j.jpowsour.2003.09.008>
22. SHARMA S. Epoch vs Batch Size vs Iterations. *Towards data science* [interaktyvus] 2017 [žiūrėtas 2020-05-18]. Prieiga per: <https://towardsdatascience.com/>
23. SRIVASTAVA S. Top 10 data science programming languages for 2020. *Analytics Insight*. [interaktyvus] 2019 [žiūrėta 2020-04-16]. Prieiga per: <https://www.analyticsinsight.net/>
24. SUNG W., SHIN C. B. Electrochemical model of a lithium-ion battery implemented into an automotive battery management system. *Computers & Chemical Engineering*. [interaktyvus] 2015, 76, pp. 87–97 [žiūrėta 2020-04-15]. Prieiga per: doi: <https://doi.org/10.1016/j.compchemeng.2015.02.007>
25. TAMPIER C., PEREZ A., JARAMILLO MONTOYA F., QUINTERO V., ORCHARD M., SILVA J. Lithium-Ion Battery End-of-Discharge Time Estimation and Prognosis based on Bayesian Algorithms and Outer Feedback Correction Loops: A Comparative Analysis. *Annual Conference of the Prognostics and Health Management Society* [interaktyvus] 2015, [žiūrėta 2020-01-10]. Prieiga per: <https://www.researchgate.net>
26. TAN Y., ZHAO G. A Novel State-of-Health Prediction Method for Lithium-ion Batteries based on Transfer Learning with Long Short-Term Memory Network. *IEEE Transactions on Industrial Electronics*. [interaktyvus] 2019 [žiūrėtas 2020-05-16]. Prieiga per: doi: <https://doi.org/10.1109/TIE.2019.2946551>
27. VENUGOPAL P., VINGESWARAN T. State-of-Health Estimation of Li-ion Batteries in Electric Vehicle Using IndRNN under Variable Load Condition. *Energies*. [interaktyvus] 2019, 12(22) [žiūrėta 2020-04-15]. Prieiga per: doi: <https://doi.org/10.3390/en12224338>
28. WANG Z., ZENG S., GUO J., QIN T. State of health estimation of lithium-ion batteries based on the constant voltage charging curve. *Energy*. [interaktyvus] 2019, 167, pp. 661-669 [žiūrėta 2020-05-14]. Prieiga per: doi: <https://doi.org/10.1016/j.energy.2018.11.008>
29. XU H., PENG Y., SU L. Health State Estimation Method of Lithium Ion Battery Based on NASA Experimental Data Set. *IOP Conference Series Materials Science and Engineering*. [interaktyvus] 2018, 452(3) [žiūrėta 2020-04-15]. Prieiga per: <https://www.researchgate.net>
30. XUEBING H., LANGUANG L., YUJIU Z., XUNING F., ZHE L., JIANQIU L., MINGGAO O. A review on the key issues of the lithium ion battery degradation among the whole life cycle. *eTransportation*. [interaktyvus] 2019, Vol. 1, [žiūrėtas 2020-05-14]. Prieiga per: doi: <https://doi.org/10.1016/j.etrans.2019.100005>
31. ZHOU D., YIN H., FU P., SONG X., LU W., YUAN L., FU Z. Prognostics for State of Health of Lithium-Ion Batteries Based on Gaussian Process Regression. *Mathematical Problems in*

Engineering. [interaktyvus] 2018, 1-11 [žiūrėta 2020-01-10]. Prieiga per: doi:
<https://doi.org/10.1155/2018/8358025>

32. ZOU C., MANZIE C., NEŠIĆ D. A framework for simplification of PDE-based lithium-ion battery models. *IEEE Transactions on Control Systems Technology*. [interaktyvus] 2016, 24(5), pp. 1594–1609 [žiūrėta 2020-04-15]. Prieiga per: doi:
<https://doi.org/10.1109/TCST.2015.2502899>

Priedai

1 priedas

Rangų lentelė, tinkamiausiems prognozei parametrams rasti

| Akumulatorius | Duomenų paruošimo metodas | Neuroninis tinklas | Paklaida | I | V | t | I, V | I, t | V, t | I, V, t |
|-------------------|---------------------------|--------------------|----------|------------|------------|------------|------------|-----------|------------|------------|
| 5 akumuliatorius | Min-max normalizavimas | FNN10 | MAE | 7 | 5 | 3 | 4 | 2 | 6 | 1 |
| | | | RMSE | 7 | 3 | 1 | 5 | 4 | 6 | 2 |
| | | FNN40 | MAE | 7 | 4 | 5 | 3 | 2 | 6 | 1 |
| | | | RMSE | 7 | 4 | 2 | 1 | 5 | 6 | 3 |
| | Standartizavimas | FNN10 | MAE | 7 | 3 | 2 | 6 | 1 | 5 | 4 |
| | | | RMSE | 6 | 3 | 1 | 5 | 2 | 7 | 4 |
| | | FNN40 | MAE | 5 | 2 | 6 | 7 | 1 | 3 | 4 |
| | | | RMSE | 5 | 2 | 1 | 7 | 3 | 4 | 6 |
| 6 akumuliatorius | Min-max normalizavimas | FNN10 | MAE | 1 | 7 | 2 | 6 | 4 | 5 | 3 |
| | | | RMSE | 3 | 7 | 1 | 4 | 2 | 5 | 6 |
| | | FNN40 | MAE | 4 | 7 | 6 | 2 | 1 | 3 | 5 |
| | | | RMSE | 5 | 7 | 4 | 2 | 1 | 3 | 6 |
| | Standartizavimas | FNN10 | MAE | 4 | 7 | 3 | 5 | 1 | 2 | 6 |
| | | | RMSE | 4 | 7 | 1 | 5 | 3 | 2 | 6 |
| | | FNN40 | MAE | 3 | 7 | 4 | 6 | 1 | 2 | 5 |
| | | | RMSE | 4 | 6 | 2 | 7 | 3 | 1 | 5 |
| 7 akumuliatorius | Min-max normalizavimas | FNN10 | MAE | 2 | 7 | 4 | 5 | 1 | 6 | 3 |
| | | | RMSE | 4 | 6 | 3 | 7 | 1 | 5 | 2 |
| | | FNN40 | MAE | 7 | 3 | 2 | 5 | 1 | 6 | 4 |
| | | | RMSE | 6 | 4 | 2 | 7 | 1 | 5 | 3 |
| | Standartizavimas | FNN10 | MAE | 4 | 7 | 5 | 3 | 1 | 6 | 2 |
| | | | RMSE | 6 | 7 | 4 | 1 | 3 | 5 | 2 |
| | | FNN40 | MAE | 4 | 7 | 6 | 3 | 1 | 5 | 2 |
| | | | RMSE | 5 | 7 | 3 | 2 | 1 | 4 | 6 |
| 18 akumuliatorius | Min-max normalizavimas | FNN10 | MAE | 6 | 3 | 7 | 1 | 4 | 5 | 2 |
| | | | RMSE | 7 | 2 | 6 | 1 | 5 | 4 | 3 |
| | | FNN40 | MAE | 6 | 5 | 7 | 1 | 3 | 4 | 2 |
| | | | RMSE | 7 | 3 | 6 | 2 | 4 | 5 | 1 |
| | Standartizavimas | FNN10 | MAE | 5 | 4 | 6 | 1 | 7 | 3 | 2 |
| | | | RMSE | 6 | 2 | 7 | 1 | 5 | 3 | 4 |
| | | FNN40 | MAE | 5 | 6 | 7 | 1 | 3 | 2 | 4 |
| | | | RMSE | 5 | 4 | 7 | 3 | 1 | 2 | 6 |
| Suma | | | | 164 | 158 | 126 | 119 | 78 | 136 | 115 |

Duomenų paruošimo geresnio metodo radimo rangų lentelė

| Akumuliatorius | Duomenų paruošimo metodas | Neuroninis tinklas | Paklaida | I | V | t | I, V | I, t | V, t | I, V, t | Suma |
|----------------------|---------------------------|--------------------|----------|---|---|---|------|------|------|---------|------|
| 5 akumuliatorius | Min-max normalizavimas | FNN10 | MAE | 2 | 1 | 1 | 1 | 2 | 1 | 1 | 37 |
| | | | RMSE | 2 | 1 | 1 | 1 | 1 | 1 | 1 | |
| | | FNN40 | MAE | 2 | 2 | 1 | 1 | 1 | 2 | 1 | |
| | | | RMSE | 2 | 2 | 1 | 1 | 2 | 1 | 1 | |
| | Standartizavimas | FNN10 | MAE | 1 | 2 | 2 | 2 | 1 | 2 | 2 | 47 |
| | | | RMSE | 1 | 2 | 2 | 2 | 2 | 2 | 2 | |
| FNN40 | | MAE | 1 | 1 | 2 | 2 | 2 | 1 | 2 | | |
| | | RMSE | 1 | 1 | 2 | 2 | 1 | 2 | 2 | | |
| 6 akumuliatorius | Min-max normalizavimas | FNN10 | MAE | 1 | 1 | 1 | 1 | 2 | 2 | 1 | 34 |
| | | | RMSE | 1 | 1 | 1 | 1 | 1 | 2 | 1 | |
| | | FNN40 | MAE | 1 | 1 | 2 | 1 | 1 | 1 | 1 | |
| | | | RMSE | 1 | 1 | 2 | 1 | 1 | 2 | 1 | |
| | Standartizavimas | FNN10 | MAE | 2 | 2 | 2 | 2 | 1 | 1 | 2 | 50 |
| | | | RMSE | 2 | 2 | 2 | 2 | 2 | 1 | 2 | |
| FNN40 | | MAE | 2 | 2 | 1 | 2 | 2 | 2 | 2 | | |
| | | RMSE | 2 | 2 | 1 | 2 | 2 | 1 | 2 | | |
| 7 akumuliatorius | Min-max normalizavimas | FNN10 | MAE | 2 | 1 | 1 | 2 | 2 | 1 | 2 | 40 |
| | | | RMSE | 1 | 1 | 2 | 2 | 1 | 1 | 1 | |
| | | FNN40 | MAE | 2 | 1 | 1 | 2 | 1 | 2 | 2 | |
| | | | RMSE | 2 | 1 | 1 | 2 | 1 | 1 | 1 | |
| | Standartizavimas | FNN10 | MAE | 1 | 2 | 2 | 1 | 1 | 2 | 1 | 44 |
| | | | RMSE | 2 | 2 | 1 | 1 | 2 | 2 | 2 | |
| FNN40 | | MAE | 1 | 2 | 2 | 1 | 2 | 1 | 1 | | |
| | | RMSE | 1 | 2 | 2 | 1 | 2 | 2 | 2 | | |
| 18 akumuliatorius | Min-max normalizavimas | FNN10 | MAE | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 32 |
| | | | RMSE | 1 | 1 | 1 | 1 | 1 | 1 | 1 | |
| | | FNN40 | MAE | 2 | 1 | 1 | 1 | 1 | 2 | 1 | |
| | | | RMSE | 2 | 1 | 1 | 1 | 2 | 1 | 1 | |
| | Standartizavimas | FNN10 | MAE | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 52 |
| | | | RMSE | 2 | 2 | 2 | 2 | 2 | 2 | 2 | |
| FNN40 | | MAE | 1 | 2 | 2 | 2 | 2 | 1 | 2 | | |
| | | RMSE | 1 | 2 | 2 | 2 | 1 | 2 | 2 | | |

Efektingesnio neuroninio tinklo nustatymo rangų lentelė

| Akumulatorius | Duomenų paruošimo metodas | Neuroninis tinklas | Paklaida | I | V | t | I, V | I, t | V, t | I, V, t | Suma |
|----------------------------|---------------------------|--------------------|----------|---|---|---|------|------|------|-----------|-----------|
| 5 akumulatorius | Min-max normalizavimas | FNN10 | MAE | 2 | 1 | 1 | 1 | 1 | 1 | 1 | 16 |
| | | | RMSE | 1 | 1 | 1 | 2 | 1 | 1 | 1 | |
| | | FNN40 | MAE | 1 | 2 | 2 | 2 | 2 | 2 | 2 | 26 |
| | | | RMSE | 2 | 2 | 2 | 1 | 2 | 2 | 2 | |
| | Standartizavimas | FNN10 | MAE | 1 | 2 | 1 | 1 | 1 | 0 | 1 | 15 |
| | | | RMSE | 1 | 1 | 1 | 1 | 1 | 2 | 1 | |
| FNN40 | | MAE | 2 | 1 | 2 | 2 | 2 | 0 | 2 | 24 | |
| | | RMSE | 2 | 2 | 2 | 2 | 2 | 1 | 2 | | |
| 6 akumulatorius | Min-max normalizavimas | FNN10 | MAE | 1 | 1 | 1 | 2 | 2 | 2 | 1 | 19 |
| | | | RMSE | 1 | 1 | 1 | 2 | 2 | 1 | 1 | |
| | | FNN40 | MAE | 2 | 2 | 2 | 1 | 1 | 1 | 2 | 23 |
| | | | RMSE | 2 | 2 | 2 | 1 | 1 | 2 | 2 | |
| | Standartizavimas | FNN10 | MAE | 1 | 2 | 1 | 1 | 1 | 1 | 2 | 17 |
| | | | RMSE | 1 | 1 | 1 | 1 | 1 | 1 | 2 | |
| FNN40 | | MAE | 2 | 1 | 2 | 2 | 2 | 2 | 1 | 25 | |
| | | RMSE | 2 | 2 | 2 | 2 | 2 | 2 | 1 | | |
| 7 akumulatorius | Min-max normalizavimas | FNN10 | MAE | 1 | 2 | 0 | 1 | 1 | 1 | 1 | 16 |
| | | | RMSE | 1 | 2 | 2 | 1 | 1 | 1 | 1 | |
| | | FNN40 | MAE | 2 | 1 | 0 | 2 | 2 | 2 | 2 | 23 |
| | | | RMSE | 2 | 1 | 1 | 2 | 2 | 2 | 2 | |
| | Standartizavimas | FNN10 | MAE | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 14 |
| | | | RMSE | 1 | 1 | 1 | 1 | 1 | 1 | 1 | |
| FNN40 | | MAE | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 28 | |
| | | RMSE | 2 | 2 | 2 | 2 | 2 | 2 | 2 | | |
| 18 akumulatorius | Min-max normalizavimas | FNN10 | MAE | 0 | 1 | 1 | 1 | 2 | 1 | 1 | 15 |
| | | | RMSE | 1 | 1 | 1 | 1 | 2 | 1 | 1 | |
| | | FNN40 | MAE | 0 | 2 | 2 | 2 | 1 | 2 | 2 | 24 |
| | | | RMSE | 2 | 2 | 2 | 2 | 1 | 2 | 2 | |
| | Standartizavimas | FNN10 | MAE | 2 | 2 | 1 | 1 | 2 | 2 | 1 | 20 |
| | | | RMSE | 2 | 1 | 1 | 1 | 2 | 1 | 1 | |
| FNN40 | | MAE | 1 | 1 | 2 | 2 | 1 | 1 | 2 | 22 | |
| | | RMSE | 1 | 2 | 2 | 2 | 1 | 2 | 2 | | |

Vidutinės MAE ir RMSE paklaidos pagal neuroninio tinklo tipą

| Akumulatorius | Duomenų paruošimo metodas | Neuroninis tinklas | Paklaida | I | V | t | I, V | I, t | V, t | I, V, t |
|--------------------------------------|---------------------------|--------------------|----------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
| 5 akumulatorius | Min-max normalizavimas | FNN10 | MAE | 0,0256 | 0,0188 | 0,0185 | 0,0187 | 0,0174 | 0,0202 | 0,0162 |
| | | | RMSE | 0,0508 | 0,0366 | 0,0285 | 0,0423 | 0,0384 | 0,0444 | 0,0308 |
| | | FNN40 | MAE | 0,0239 | 0,0201 | 0,0214 | 0,0199 | 0,0189 | 0,0217 | 0,0185 |
| | | | RMSE | 0,0599 | 0,0404 | 0,0357 | 0,033 | 0,0462 | 0,0475 | 0,0399 |
| | Standartizavimas | FNN10 | MAE | 0,0226 | 0,0203 | 0,0187 | 0,0217 | 0,017 | 0,0215 | 0,0205 |
| | | | RMSE | 0,0499 | 0,0397 | 0,0294 | 0,0452 | 0,0338 | 0,0505 | 0,0418 |
| | | FNN40 | MAE | 0,0231 | 0,02 | 0,0237 | 0,0262 | 0,0196 | 0,0215 | 0,0222 |
| | | | RMSE | 0,0527 | 0,0399 | 0,0396 | 0,0564 | 0,0407 | 0,0492 | 0,056 |
| 6 akumulatorius | Min-max normalizavimas | FNN10 | MAE | 0,0313 | 0,0399 | 0,0314 | 0,038 | 0,0327 | 0,0367 | 0,0321 |
| | | | RMSE | 0,0614 | 0,0759 | 0,0514 | 0,0682 | 0,0573 | 0,0704 | 0,0714 |
| | | FNN40 | MAE | 0,036 | 0,047 | 0,0392 | 0,0347 | 0,0301 | 0,0349 | 0,0379 |
| | | | RMSE | 0,0755 | 0,0835 | 0,0754 | 0,0669 | 0,0536 | 0,072 | 0,0819 |
| | Standartizavimas | FNN10 | MAE | 0,0342 | 0,0539 | 0,0329 | 0,0426 | 0,0303 | 0,0309 | 0,0429 |
| | | | RMSE | 0,0723 | 0,1092 | 0,054 | 0,0907 | 0,0585 | 0,0569 | 0,1006 |
| | | FNN40 | MAE | 0,0372 | 0,0535 | 0,0387 | 0,0482 | 0,0352 | 0,0354 | 0,042 |
| | | | RMSE | 0,0748 | 0,1127 | 0,0684 | 0,1161 | 0,0691 | 0,0617 | 0,0998 |
| 7 akumulatorius | Min-max normalizavimas | FNN10 | MAE | 0,0179 | 0,0217 | 0,0187 | 0,0189 | 0,0143 | 0,02 | 0,0182 |
| | | | RMSE | 0,0344 | 0,038 | 0,0321 | 0,0441 | 0,0233 | 0,0357 | 0,0274 |
| | | FNN40 | MAE | 0,0249 | 0,0198 | 0,0187 | 0,0222 | 0,016 | 0,0247 | 0,0201 |
| | | | RMSE | 0,0503 | 0,0378 | 0,0312 | 0,0559 | 0,0271 | 0,0418 | 0,0358 |
| | Standartizavimas | FNN10 | MAE | 0,0178 | 0,0259 | 0,019 | 0,0161 | 0,0142 | 0,021 | 0,0144 |
| | | | RMSE | 0,0443 | 0,0541 | 0,0318 | 0,0277 | 0,0303 | 0,0372 | 0,0296 |
| | | FNN40 | MAE | 0,0205 | 0,0334 | 0,0228 | 0,0193 | 0,0161 | 0,0227 | 0,019 |
| | | | RMSE | 0,0448 | 0,0652 | 0,0378 | 0,0351 | 0,0316 | 0,044 | 0,0467 |
| 18 akumulatorius | Min-max normalizavimas | FNN10 | MAE | 0,0326 | 0,0257 | 0,0367 | 0,0196 | 0,0262 | 0,0266 | 0,0223 |
| | | | RMSE | 0,0697 | 0,0425 | 0,0678 | 0,0325 | 0,0513 | 0,0484 | 0,0446 |
| | | FNN40 | MAE | 0,0326 | 0,0304 | 0,0442 | 0,0241 | 0,0258 | 0,0282 | 0,0242 |
| | | | RMSE | 0,0817 | 0,0479 | 0,0814 | 0,0466 | 0,0499 | 0,0555 | 0,0457 |
| | Standartizavimas | FNN10 | MAE | 0,0429 | 0,0338 | 0,0431 | 0,02 | 0,0449 | 0,0285 | 0,0268 |
| | | | RMSE | 0,0847 | 0,0545 | 0,0881 | 0,0343 | 0,0838 | 0,0557 | 0,0612 |
| | | FNN40 | MAE | 0,032 | 0,0336 | 0,0519 | 0,0269 | 0,0278 | 0,0275 | 0,0303 |
| | | | RMSE | 0,0635 | 0,0605 | 0,0997 | 0,0597 | 0,0488 | 0,0569 | 0,0666 |
| Vidutinė MAE paklaida, FNN10 | | | | 0,0269 | 0,0265 | 0,0263 | 0,0238 | 0,0227 | 0,0259 | 0,0222 |
| Vidutinė MAE paklaida, FNN40 | | | | 0,0235 | 0,0235 | 0,0247 | 0,0202 | 0,0182 | 0,0219 | 0,0201 |
| Vidutinė RMSE paklaida, FNN10 | | | | 0,0541 | 0,0483 | 0,0450 | 0,0468 | 0,0426 | 0,0497 | 0,0436 |
| Vidutinė RMSE paklaida, FNN40 | | | | 0,0669 | 0,0524 | 0,0559 | 0,0506 | 0,0442 | 0,0542 | 0,0508 |