



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

**Dirbtinio intelekto pritaikymas
hibridinės elektros energetikos sistemos valdyme**

Baigiamasis magistro projektas

Jonas Vaičys

Projekto autorius

Prof. Saulius Gudžius

Vadovas

Kaunas, 2020



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

**Dirbtinio intelekto pritaikymas
hibridinės elektros energetikos sistemos valdyme**

Baigiamasis magistro projektas

Elektros energetikos inžinerija (6211EX010)

Jonas Vaičys

Projekto autorius

Prof. Saulius Gudžius

Vadovas

Prof. Antanas Verikas

Recenzentas

Kaunas, 2020



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Jonas Vaičys

Dirbtinio intelekto pritaikymas hibridinės elektros energetikos sistemos valdyme

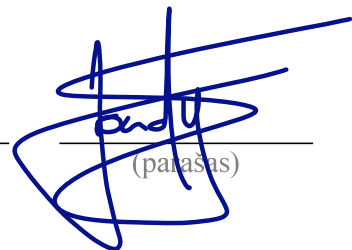
Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Jono Vaičio, baigiamasis projektas tema „Dirbtinio intelekto pritaikymas hibridinės elektros energetikos sistemos valdyme“ 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.

Jonas Vaičys

(vardą ir pavardę įrašyti ranka)



(parašas)

Vaičys, Jonas. Dirbtinio intelekto pritaikymas hibridinės elektros energetikos sistemos valdyme. Magistro baigiamasis projektas / vadovas prof. dr. Saulius Gudžius; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): studijų kryptis – elektros inžinerija, krypčių grupė – inžinerijos mokslai.

Reikšminiai žodžiai: dirbtinis intelektas, hibridinė sistema, saulės elektrinės valdymas, hidroakumuliacinės elektrinės valdymas, elektros energijos rinka, duomenų analizė.

Kaunas, 2020. 48 p.

Santrauka

Šiame darbe nagrinėjama dirbtinio intelekto pritaikymo galimybė valdyti hibridinę elektros energetikos sistemą, susidedančią iš (plūduriojančios) saulės elektrinės ir hidroakumuliacinės elektrinės. Ši sistema valdoma prognozuojant saulės elektrinės generuojamą energiją ir optimizuojant hibridinės sistemos darbo grafiką maksimizuojant pajamas, įvertinant „dienos prieš“ ir balansavimo kainas bei saulės elektrinės ir Baltijos elektros energetikos sistemos disbalanso kiekį.

Išorinių kintamųjų atrinkimui, atlikta vienerių metų valandinių meteorologinių duomenų analizė. Saulės elektrinės generuojamos energijos prognozei pritaikyti tiesinės regresijos, netiesinės regresijos, dirbtinio neuroninio tinklo, atraminių vektorių mašinų, atsitiktinių miškų ir modelių ansamblių dirbtinio intelekto metodai. Netipinių proporcijų hibridinei sistemai (energijos kaupiklis ženkliai didesnis už energijos generacijos šaltinį) suoptimizuotas hidroakumuliacinės elektrinės kiekvienos metų savaitės grafikas ir, atsižvelgiant į jį, kiekvienam iš sukurtų prognozavimo modelių parinkta optimali disbalanso valdymo strategija.

Atlikus tyrimą nustatyta, kad valdymo strategija, sukurta pagal empirinio modelio prognozavimo rezultatus, atneša mažesnes pajamas nei pagal bet kurio iš nagrinėtų dirbtinio intelekto modelių. Taip pat nustatyta, kad valdymo strategija, sukurta pagal tikslesnio dirbtinio intelekto modelio prognozavimo rezultatus, nebūtinai atneša didesnes pajamas.

Vaičys, Jonas. Artificial Intelligence Application in Hybrid Power System Management. Master's Final Degree Project / supervisor prof. dr. Saulius Gudžius; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): power engineering, engineering science.

Keywords: artificial intelligence, hybrid system, solar power plant management, hydro pumped storage power plant management, power market, data analysis.

Kaunas, 2020. 48.

Summary

This project analyses the application of artificial intelligence in a hybrid power system, which consists of a (floating) photovoltaic power plant and a hydro pumped storage power plant. The hybrid power system is managed by forecasting the generation of a solar power plant and optimising the bidding strategy of a hybrid power system by maximising the revenue, taking into account the day ahead market and the imbalance prices, solar power plant and Baltic power system imbalance volumes.

The analysis of one year hourly meteorological data was performed to select relevant features. Linear regression, nonlinear regression, artificial neural network, support vector machines, random forest and ensemble methods were applied to forecast the generation of the solar power plant. Due to the fact that the installed capacity of the energy storage is larger than the capacity of the generating unit in this hybrid power system, hourly operating schedule of the hydro pump storage power plant was optimised for each week in the year, and by taking it into the consideration, the optimal imbalance management strategy of each forecasting model was developed.

The results indicate that the management strategy, developed based on the results of the empirical forecasting model, accounts for lower revenue than any of the artificial intelligence forecasting models analysed. It was also found that the management strategy, developed based on the results of the most accurate artificial intelligence forecasting model, does not necessarily provide the highest revenue.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Santrumpų sąrašas	9
Įvadas	10
1. Dirbtinio intelekto metodų pritaikymo elektros energetikos sistemoje apžvalga	11
1.1. Dirbtinis neuroninis tinklas	12
1.2. Daugiasluoksnis perceptronas.....	13
1.3. Ekstremalus mašinių mokymas ir kitos neuroninių tinklų modifikacijos	15
1.4. Atraminių vektorių mašinos	15
1.5. Bangelių neuroninis tinklas	16
1.6. Adaptyvi neuroninė–neraiškioji išvedimo sistema	17
1.7. Sprendimų medžiai.....	18
1.8. Gilusis mokymas.....	19
1.9. Įvairių metodų ansambliai	20
2. Problemos formulavimas	22
3. Metodika	23
3.1. Empirinis SE generuojamos energijos modelis	24
3.2. Dirbtinio intelekto modeliai saulės elektrinės generuojamai energijai prognozuoti	25
3.2.1. Regresija	25
3.2.2. Dirbtinis neuroninis tinklas.....	26
3.2.3. Atraminių vektorių mašinos	27
3.2.4. Atsitiktiniai miškai	28
3.3. Modelių vertinimas	29
3.4. Hibridinės sistemos optimizacijos uždavinys maksimizuojant pajamas.....	30
3.4.1. Prielaidos	30
3.4.2. Kruonio hidroakumuliacinės elektrinės savaitės darbo grafiko optimizacijos uždavinys	32
3.4.3. Saulės elektrinės dienos balansavimo optimizacijos uždavinys	33
4. Rezultatai	34
4.1. ASI sistemos – SE generacijos modelio sudarymo rezultatai	34
4.2. „Meteoblue“ – SE generacijos prognozės modelio sudarymo rezultatai	36
4.3. Disbalanso kainos modelio sudarymo rezultatai.....	39
4.4. Hibridinės elektros energetikos sistemos optimizavimo rezultatai.....	41
Išvados	44
Literatūros sąrašas	45
Informacijos šaltinių sąrašas	48
Priedai	49
1 priedas. „Meteoblue“ duomenų koreliacinė matrica.....	49
2 priedas. Saulės elektrinės generuojamos energijos modelių apmokymo kreivės	50
3 priedas. KHAE savaitės horizonto optimizacijos rezultatai	54
4 priedas. Disbalanso kainos modelių mokymosi kreivės.....	79

Lentelių sąrašas

1.1 lentelė. Svarbūs DNT modelių pritaikymai elektros energetikos srityje.....	12
1.2 lentelė. Svarbūs DSP modelių pritaikymai elektros energetikos srityje.....	13
1.3 lentelė. Svarbūs EMM modelių pritaikymai elektros energetikos srityje.....	15
1.4 lentelė. Svarbūs AVM modelių pritaikymai elektros energetikos srityje.....	16
1.5 lentelė. Svarbūs BNN modelių pritaikymai elektros energetikos srityje.....	17
1.6 lentelė. Svarbūs ANNIS modelių pritaikymai elektros energetikos srityje	18
1.7 lentelė. Svarbūs SM modelių pritaikymai elektros energetikos srityje	19
1.8 lentelė. Svarbūs GNT modelių pritaikymai elektros energetikos srityje	20
1.9 lentelė. Svarbūs modelių ansamblių pritaikymai elektros energetikos srityje	21
3.1 lentelė. Viešai prieinami duomenys apie KHAE.....	30

Paveikslų sąrašas

1.1 pav.	Mokslinių straipsnių, susijusių su MM pritaikymu EES kiekis [10]	11
3.1 pav.	SE dalies nuotrauka ir vaizdas iš „Meteonorm“ programinės įrangos.....	23
3.2 pav.	ASI sistemos nuotrauka.....	23
3.3 pav.	Perceptrono matematinis modelis	26
3.4 pav.	AVM duomenų transformavimas į daugiamatę požymių erdvę.....	27
3.5 pav.	Atsitiktinių miškų principinė schema [60]	28
3.6 pav.	Statistinių modelių paklaidų priklausomybė nuo epochų skaičiaus.....	29
3.7 pav.	KHAE VB vandens lygio kitimo priklausomybė nuo KHAE darbo režimo.....	31
3.8 pav.	Blokinė SE balansavimo optimizavimo schema.....	33
4.1 pav.	Duomenų sklaidos diagramos ir histogramos.....	34
4.2 pav.	Saulės priklausomybė nuo apšvietos, klaidų šalinimas ir tiesinė aproksimacija.....	35
4.3 pav.	ASI – SE modelių determinacijos koeficientai.....	35
4.4 pav.	„Meteoblue“ duomenų koreliacinė matrica	36
4.5 pav.	„Meteoblue“ – SE modelių svarbiausių nepriklausomų kintamųjų atrinkimas.....	37
4.6 pav.	„Meteoblue“ – SE modelių ansamblio apmokymo kreivė	37
4.7 pav.	„Meteoblue“ – SE modelių determinacijos koeficientai	38
4.8 pav.	„Meteoblue“ – SE modelių rezultatų koreliacinė matrica	38
4.9 pav.	Disbalanso kainos priklausomybė nuo disbalanso kiekio tiesinė aproksimacija.....	39
4.10 pav.	Disbalanso kainos DNT(5,10,10,1) modelio apmokymo kreivė	39
4.11 pav.	Disbalanso kainos modelių determinacijos koeficientai	40
4.12 pav.	Vienos savaitės faktiniai ir apskaičiuoti disbalanso kiekiai ir kainos	40
4.13 pav.	Metinės HEES pajamos ir sistemingosios „Meteoblue“ – SE modelių paklaidos.....	41
4.14 pav.	KHAE vienos savaitės grafiko optimizacijos rezultatai.....	41
4.15 pav.	Atskirų HEES elementų metų vidutinės aktyviosios galios kiekvieną paros valandą	42
4.16 pav.	Disbalanso ir vidutinės „dienos prieš“ kainos	42
4.17 pav.	HEES optimizavimo pagal skirtingų DI modelių prognozes rezultatai	43
4.18 pav.	Skirtingų HEES valdymo modelių palyginimas	43

Santrumpų sąrašas

Santrumpos:

AEI – atsinaujinantys energijos ištekliai

AM – atsitiktiniai miškai

AVM – atraminių vektorių mašinos

DI – dirbtinis intelektas

DNT – dirbtinis neuroninis tinklas

EES – elektros energetikos sistema

HEES – hibridinė elektros energetikos sistema

KHAE – Kruonio hidroakumuliacinė elektrinė

KTU – Kauno technologijos universitetas

MM – mašininis mokymasis

SE – saulės elektrinė

VB – viršutinis baseinas

Ivadas

Pagrindinė, o kartu ir pati sudėtingiausia dirbtinė sistema, elektros energijos sistema, išgyvena revoliucinius pokyčius. Galima išskirti tris pagrindines kryptis, kuriose pokyčiai šiuo metu vyksta sparčiausiai [1]:

- didėjanti elektros energijos gamybos dalis iš atsinaujinančius energijos išteklius vartojančių elektrinių;
- elektros energijos gamybos decentralizavimas, nukreiptas į vis daugiau vartotojų, kurie ne tik vartoja energiją, bet ir ją gamina bei kaupia.
- elektros energetikos sistemos skaitmenizavimas, didinantis sistemos lankstumą ir būtinas išmaniųjų tinklų idėjos tobulinimui;

Siekiant sėkmingai įgyvendinti šiuos pokyčius ir sukurti švarią, mažai anglies dioksido į aplinką išskiriančią, saugią ir efektyvią elektros energetikos sistemą, turi būti naudojamos pažangiausios priemonės. Dėl priėjimo prie didelių duomenų, greitesnių kompiuterių bei patobulėjusių mašininio mokymo metodų, viena perspektyviausių, sparčiai besivystančių tokių priemonių galėtų būti dirbtinis intelektas [2]. Dirbtinio intelekto metodai pasižymi tuo, kad gali būti taikomi net ir tada, kai nėra tiesioginio matematinio ryšio tarp priežasties ir pasekmės [3]. Dirbtinio intelekto metodai taip pat yra pranašesni už daugelį griežtų analitinių modelių, nes gali būti naudojami tiek kokybiniai, tiek kiekybiniai duomenys [4].


Atsinaujinančių energijos šaltinių skatinimas sukuriant išskirtines sąlygas liberalizuotose energijos rinkose pastaraisiais metais sukūrė atsinaujinančios energijos technologijos proveržį. Siekiant, kad atsinaujinančios energijos technologijos ir toliau didintų savo rinkos dalį, jos turi ne tik vystytis kartu su iškastinio kuro technologijomis, bet ir veikti pagal tas pačias griežtas elektros rinkų taisykles, kaip ir tradicinės elektrinės [5]. Elektrinės turi pranešti apie savo gamybą dieną ar keletą valandų prieš, o už plano nesilaikymą joms gresia baudos, todėl atsinaujinančius energijos išteklius vartojančioms elektrinėms ypač aktualus tikslus generuojamos energijos prognozavimo uždavinys bei energijos kaupimo technologijos [6].

Šio baigiamojo projekto tikslas – pritaikyti ir palyginti įvairius dirbtinio intelekto metodus hibridinės elektros energetikos sistemos valdyme. Šiam tikslui pasiekti, darbas suskaidomas į 4 užduotis:

1. išanalizuoti dirbtinio intelekto metodų taikymą sprendžiant įvairius elektros energetikos sistemos uždavinius;
2. surinkti, išanalizuoti ir identifikuoti reikiamus duomenis modeliams kurti;
3. pritaikyti įvairius dirbtinio intelekto metodus saulės elektrinės gamybai prognozuoti;
4. palyginti modelius atliekant vienerių metų hibridinės elektros energetikos sistemos (saulės elektrinės ir energijos kaupiklio) optimizacinį uždavinį maksimizuojant pajamas.

1. Dirbtinio intelekto metodų pritaikymo elektros energetikos sistemoje apžvalga

Mašininis mokymas (toliau – MM) yra dirbtinio intelekto (toliau – DI) šaka, taikoma ir duodanti gerus rezultatus klasifikavimo, regresijos, optimizavimo ir kituose uždaviniuose, susijusiuose su daugiamačiais duomenimis [7]. Siekiant išgauti žinias iš didelių duomenų bazių, MM algoritmai mokosi iš ankstesnių skaičiavimų, kad pateiktų patikimus, pakartojamus sprendimus ir rezultatus [8,9]. 1.1 pav. pateiktas mokslinių straipsnių (toliau – straipsnių), susijusių su MM metodų pritaikymu energetikos srityje, augimas nuo 2000 iki 2019 m. pagal [10]. Pastebimas eksponentinis augimas, kurį daugiausia lėmė išmaniųjų tinklų bei daiktų interneto atsiradimas. Nors didžioji dalis šių straipsnių apie MM pritaikymą prognozuojant elektros energijos suvartojimą ir atsinaujinančios energijos išteklius (toliau – AEI) naudojančių elektrinių gamybą, tačiau yra straipsnių ir apie MM pritaikymą pakeičiant daug skaičiavimo resursų reikalaujančius matematinius modelius gedimų diagnostikoje ar priimant sprendimą dėl investicijų kritinėje infrastruktūroje. Nuolatinis literatūros augimas taip pat patvirtinta didelį DI metodų pritaikymo potencialą elektros energetikos sistemose (toliau – EES).



1.1 pav. Mokslinių straipsnių, susijusių su MM pritaikymu EES kiekis [10]

Nors MM modelių yra įvairių, EES galima išskirti 9 daugiausiai taikomus metodus: dirbtinis neuroninis tinklas (angl. *Artificial Neural Network*), daugiasluoksnis perceptronas (angl. *Multilayer Perceptron*), ekstremalus mašinų mokymas (angl. *Extreme Learning Machines*), atraminių vektorių mašinos (angl. *Support Vector Machines*), bangelių neuroninis tinklas (angl. *Wavelet Neural Network*), adaptyvi neuroninė–neraiškioji išvedimo sistema (angl. *Adaptive Neuro-Fuzzy Inference System*), sprendimų medžiai (angl. *Decision Trees*), gilusis mokymas (angl. *Deep Learning*) ir įvairių metodų ansamblis (angl. *Ensemble Models*).

Toliau apžvelgiama kiekvieno iš prieš tai paminėto metodo pritaikymas EES per pastaruosius 5 metus. Atsižvelgiant į 1.1 pav. kasmetinę parašytų straipsnių tendenciją, galima daryti prielaidą, kad šio baigiamojo projekto pristatymo metu yra atsiradę jau šimtai naujų straipsnių apie tikslesnius modelius ir naujas pritaikymo galimybes.

1.1. Dirbtinis neuroninis tinklas

Pirmasis elementarus dirbtinis neuroninis tinklas (toliau – DNT) buvo sukurtas 1943 m., panaudojant elektros grandines. DNT gali būti naudojami klasifikavimo, regresijos ar taškų aproksimacijos (angl. *curve fitting*) uždaviniams spręsti. Pagrindinis DNT modelių pranašumas yra jų paprastumas sprendžiant daugiamačių kintamųjų uždavinius. Vietoj sudėtingų taisyklių, DNT gali būti išmokyti išgauti svarbią informaciją iš pavyzdžių [10]. Be to, dėl atsparumo triukšmams jie sėkmingai gali būti naudojami duomenims iš EES. 1.1 lentelėje pateikti straipsniai, kuriuose DNT buvo sėkmingai pritaikyti EES.

1.1 lentelė. Svarbūs DNT modelių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
Paucar ir Rider (2020) [11]	„Electric Power Systems Research“	Galios srautų (angl. <i>power flow</i>) uždavinio sprendimas
Abbas et al. (2018) [12]	„Electronics (Switzerland)“	Instaliuojamo AEI naudojančių elektrinių kiekio optimizacija
Anwar et al. (2017) [13]	„IEEE Transactions on Power Systems“	Hibridinės elektros energetikos sistemos (toliau – HEES) elektros energijos gamybos planavimas
Chatziagorakis et al. (2016) [14]	„Neural Computing and Applications“	Valandos ir paros horizonto vėjo greičio ir saulės apšvietos prognozavimas

Siekdami išnaudoti DNT greitį, Paucar ir Rider [11] pritaikė DNT gerai žinomo EES galios srautų uždavinio sprendimui. Matematinį galios srautų modelį sudaro netiesinių algebrinių lygčių sistema, įprastai sprendžiama Niutono – Raphsono metodu arba jo modifikacijomis. Įtampos amplitudei ir kampams apskaičiuoti, DNT buvo apmokomi antrosios eilės Levenbergo Marquardto metodu. Siūloma DNT metodika buvo išbandyta naudojant IEEE–30 magistralinių linijų sistemą. Iš 583 nagrinėtų skirtingų režimų, įskaitant ir skirtingas avarijas, 351 režimas atsitiktinai parinktas modelio apmokymui ir 232 – testavimui. Iš testavimo rezultatų gauta, kad maksimali įtampos paklaida buvo 0,124 %, o vidutinė paklaida – mažesnė nei 0,004 %.

Abbas ir kt. [12] panaudojo genetinį algoritmą (GA), kad optimizuotų integruojamų į EES atsinaujinančios energijos išteklių kiekį. Šis tyrimas įvertino ekonominę AEI naudojančių elektrinių su energijos kaupimo sistemomis įdiegimo į elektros tinklą galimybę. DNT buvo naudojamas testuoti numatomą apkrovos modelį. Neapibrėžtumas, susijęs su AEI naudojančių elektrinių gamyba buvo nagrinėjamas naudojant tikimybinis metodus. Tada optimizacinis uždavinys buvo sprendžiamas panaudojant genetinius algoritmus. Pasiūlyto modelio patikimumas buvo patikrintas pritaikius jį viename vakarinės Kinijos regione. Lyginant su baziniu scenarijumi, investavus tą pačią sumą pinigų, optimizacinio modelio pasiūlyto scenarijaus atveju, švarios energijos suvartojimas išaugo daugiau nei dvigubai, dėl to išmetamas CO₂ kiekis sumažėjo nuo maždaug 109 mln. t. iki 38 mln. t.

Anwar ir kt. [13] pristatė naują energijos gamybos planavimo ir galios išlyginimo strategiją hibridinei jūros srovės ir jūrinės vėjo elektrinės sistemai. Išnaudodami jūrų srovės nuspėjamumą, autoriai šiame tyrime pasiūlė naują strategiją vėjo nepastovumo poveikį sušvelninti HEES energijos gamybai. Pasiūlytą modelį taip pat galima panaudoti optimalaus šios HEES dydžiui nustatyti. Darbe buvo sukurtas DNT modelis vėjo greičiui prognozuoti, o jūros srovės modeliuojamos panaudojant

harmoninės analizės metodą. Modelio rezultatai parodė, kad, naudojant šią metodiką galima sumažinti AEI naudojančių elektrinių galios svyravimus ir tikėtis atsiperkamumo per 1,62 m.

Chatziagorakis ir kt. [14] tyrė hibridinių AEI naudojančių elektrinių sistemų valdymą, panaudodamas grįžtamojo ryšio (rekurentinius) neuroninius tinklus meteorologinėms sąlygoms prognozuoti. Buvo sukurtas prognozavimo modelis, skirtas saulės apšvietos bei vėjo greičio prognozavimui valandos ir dienos horizontui. Modeliavimo rezultatai parodė, kad rekurentinių neuroninių tinklų modelis gali pateikti tenkinančias meteorologines prognozes, kurių tikslumas kinta ribose tarp 0,93 ir 0,99, todėl prognozės toliau gali būti gana saugiam AEI naudojančių elektrinių generuojamos energijos prognozavimui. Be to, šis metodas yra tinkamas taikyti įrangoje su nedidele apskaičiavimo galia, nes rezultatai gaunami per kelias sekundes.

1.2. Daugiasluoksnis perceptronas

Daugiasluoksnis perceptronas (DSP) yra pažangi DNT versija, plačiai taikoma inžineriniams uždaviniams. Jis pasižymi tuo, kad yra tik tiesioginio sklidimo (angl. *feedforward*) neuroninis tinklas, o jo apmokymui naudojamas prižiūrimo (angl. *supervised*) ir atgalinio sklidimo (angl. *back-propagation*) mokymosi metodas [15–17]. 1.2 lentelėje pateikti straipsniai, kuriuose DSP buvo sėkmingai pritaikyti EES.

1.2 lentelė. Svarbūs DSP modelių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
Chahkoutahiet al. (2017) [18]	„Energy“	Elektros energijos poreikio prognozavimas
Kazemet al. (2017) [19]	„Energy Conversion and Management“	Saulės elektrinės (toliau – SE) galios prognozavimas
Loutfi et al. (2017) [20]	„International Journal of Renewable Energy Research“	Valandinis saulės apšvietos prognozavimas
Shimray et al. (2017) [21]	„Computational Intelligence and Neuroscience“	Skirtingų potencialių elektrinių projektų reitingavimas
Ahmed et al. (2015) [22]	„Solar Energy“	Dienos horizonto valandinis saulės apšvietos prognozavimas

Chahkoutahi ir kt. [18] pristatė hibridinį modelį, susidedantį iš DSP, SARIMA ir ANNIS metodų, elektros energijos poreikiui prognozuoti. Pagrindinė tiriamo modelio idėja yra išnaudoti šių atskirų modelių pranašumus optimizuojant sudėtingas sistemas. Tyrimo rezultatai rodo, kad panaudojant pristatytą hibridinį modelį galima pasiekti tikslesnį elektros energijos poreikio prognozavimą, nei atskirų jo komponentų ar net kai kurių kitų taikomų hibridinių modelių. Pasiūlytas metodas galėtų pagerinti prognozavimo tikslumą 51,4%, 33,18%, 31,10% ir 12,8%, lyginant su atskirais SARIMA, DSP, ANNIS ir genetinio algoritmo modeliais, atitinkamai.

Kazem ir kt. [19] suprojektavo ir įdiegė fotovoltinę SE elektros energijai gaminti. Elektrinės gamyba buvo matuojama vienerius metus. SE gamyba buvo modeliuojama ir prognozuojama panaudojant saviorganizuojančius neuroninius tinklus (angl. *Self-Organizing Feature Maps*), tiesioginio sklidimo neuroninius tinklus (angl. *feedforward neural network*), AVM ir DSP. Modelio įėjimo kintamieji – aplinkos temperatūra ir saulės apšvieta, o išvesties kintamieji – fotovoltinio modulio srovė ir įtampa. Kiekvieno modelio išvestys buvo palygintos su išmatuotomis vertėmis, naudojant

RMSE koeficientą. Iš tyrimo rezultatų nustatyta, kad saviorganizuojančių neuroninių tinklų modelis apmokymo žingsnyje turėjo mažiausią vidutinę kvadrato paklaidą (0,0638), o DSP, tiesioginio skleidimo neuroninių tinklų ir AVM, atitinkamai, 0,0645, 0,00658 ir 0,0693. Didžiausią tikslumą turėjo tiesioginio skleidimo neuroninių tinklų modelis (80,28 %), o DSP, saviorganizuojančių neuroninių tinklų ir AVM, atitinkamai, 78,55%, 78,55% ir 77,1%.

Loutfi ir kt. [20] palygino du modelius, DSP ir netiesinį autoregresinį neuroninį tinklą su išoriniais kintamaisiais (NARX), atlikdami valandines saulės apšvietos prognozes. Autoriai tyrė įvairias neuroninio tinklo architektūras. Buvo nustatyta, kad NARX modelis su penkiais jėgimo kintamaisiais ir 10 neuronų paslėptame sluoksnyje yra tiksliausias. Šio modelio keturi kintamieji yra meteorologinės sąlygos – temperatūra, santykinė drėgmė, slėgis, vėjo greitis, o penktasis – apskaičiuota saulės spinduliuotė. Šio NARX modelio determinacijos koeficientas (R^2) lygus 0,95, o geriausio DSP – 0,88. Buvo palygintos ir modelių normalizuotos šaknies vidurkio kvadrato paklaidos (angl. *normalized root mean square error*):

$$nRMSE = \frac{\sqrt{\frac{1}{N} \times \sum_{i=1}^N (\hat{y}(i) - y(i))^2}}{\bar{y}} \quad (1)$$

čia N – stebėjimų skaičius, \hat{y} – prognozuojamos vertės, y – išmatuotos vertės, o \bar{y} – išmatuotų verčių vidurkis. Pasiūlyto NARX modelio normalizuota šaknies vidurkio kvadrato paklaida lygi 15,1 %, o geriausio DSP – 23,31 %.

Shimray ir kt. [21] pritaikė DSP ir GA tiriant hidroelektrinėm tinkamų vietovių įrengimą, kuris reikalauja didelių finansinių investicijų, didelės darbo jėgos ir turi daug laiko apribojimų. Tyrimo tikslas – sukurti modelį, rūšiuojantį hidroelektrinėm tinkamas vietas pagal įrengimo paprastumą panaudojant tokius kintamuosius, kaip oro kokybė, vandens kokybė, energijos tiekimo kaina, ekologinis poveikis, natūralus pavojus ir projekto trukmė. Šiame straipsnyje buvo įvertinta keletas galimų hidroelektrinių vietų Indijoje. Iš tiriamo MLP–GA modelio rezultatų galima teigti, kad modelis susitvarko tiek su kiekybiniais, tiek su kokybiniais požymiais ir gali tiksliai nustatyti potencialias hidroelektrinių įrengimo vietas.

Ahmed ir kt. [22] atliko valandinės saulės apšvietos prognozavimo tyrimą 24 val. horizontui. Šiame darbe buvo kuriami keli skirtingi prognozavimo modeliai, ypatingą dėmesį skiriant NARX. Prognozavimo modelių apmokymui ir testavimui buvo naudojamos valandinio žingsnio laiko eilutės. DSP, NARX, ARMA ir naivūs metodai buvo palyginti naudojant šaknies vidurkio kvadrato paklaidą (angl. *root mean square error*):

$$RMSE = \sqrt{\frac{1}{N} \times \sum_{i=1}^N (\hat{y}(i) - y(i))^2} \quad (2)$$

Rezultatai parodė, kad NARX metodo, kurio RMSE vertė buvo mažiausia, tikslumas buvo apie 49%, 22% ir 52% didesnis nei DSP, ARMA ir patvarumo metodai, atitinkamai.

1.3. Ekstremalus mašinų mokymas ir kitos neuroninių tinklų modifikacijos

Ekstremalus mašinų mokymo metodas (EMM) yra dar viena neuroninių tinklų versija. Pagrindinis skirtumas tarp EMM ir DNT yra apmokymo trukmė, kadangi EMM neturi gradientinio nusileidimo (angl. *gradient descent*) klaidos reikšmės minimizavimo metodo ir dalis tinklo parametrų inicializuojami atsitiktinėmis reikšmėmis. 1.3 lentelėje pateikti straipsniai, kuriuose EMM buvo sėkmingai pritaikyti EES.

1.3 lentelė. Svarbūs EMM modelių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
Li, Q et al. (2018) [23]	„Applied Energy“	SE gamybos prognozavimas
Premalatha ir Valan Arasu (2016) [24]	„Journal of Applied Research and Technology“	Vidutinis mėnesinis apšvietos prognozavimas
Bagnasco et al. (2015) [25]	„Energy and Buildings“	Pastato elektros suvartojimo prognozavimas

Li ir kt. [23] pristatė kelių grupių būsenos tinklo modelių tiesiogiai prognozuoti PV elektros energijos gamybą. Pritaikius duomenų gavybos metodus, buvo tiriamos išmatuotos ir apskaičiuotos SE gamybos charakteristikos, tokios kaip stacionarumas, sezoniškumas ir sudėtingumas. Modeliavimo rezultatai parodė, kad pateiktas kelių grupių būsenos tinklo modelis gali tiksliai numatyti SE generuojamą energiją valandą į priekį. Vienos dienos prognozės koreliacijos koeficientas 91–98% debesuotoms dienoms ir 99% – saulėtoms dienoms.

Premalatha ir Valan Arasu [24] panaudojo DNT modelius saulės apšvietos prognozavimui. Pagrindinis šio tyrimo tikslas buvo sukurti DNT modelį tiksliam saulės apšvietos numatymui. Straipsnyje nagrinėjami du skirtingi DNT modeliai, pagrįsti keturiais algoritmais. Pastaruosius 10 metų meteorologiniai duomenys buvo renkami iš penkių skirtingų vietų Indijoje, kad būtų galima apmokyti modelius. Geriausio EMM algoritmo nustatymo kriterijai buvo minimali vidutinė absoliuti paklaida, šaknies vidurkio kvadratinė paklaida ir didžiausias tiesinės koreliacijos koeficientas, kurių vertės, atitinkamai, 3,028, 3,646 ir 0,927.

Bagnasco ir kt. [25] pateikė elektros energijos suvartojimo prognozės (apkrovos prognozavimo modelio) ligininę tyrimą. Nagrinėjamas DNT modelis apmokomas atgalinio sklidimo metodu, o įėjimo kintamieji apima apkrovas, paros laiką, duomenis apie dienos tipą (pvz., savaitės dieną ar atostogas) ir meteorologinius duomenis. Siūlomą prognozės algoritmą galima lengvai integruoti į pastatų valdymo sistemų realaus laiko stebėjimo sistemą.

1.4. Atraminių vektorių mašinos

Pagrindinė atraminių vektorių mašinų (toliau – AVM) metodo savybė – n -matės įeities erdvės atvaizdavimas kitoje (paprastai aukštesnio laipsnio) erdvėje, kurioje formuojama tiesinė skiriamoji hiperplokštuma [26]. Dėl savybės apibendrinti ir lokalaus minimo išvengimo, AVM dažnai pralenkia kitus metodus bruožų atpažinimo (angl. *pattern recognition*), klasifikavimo ir regresijos uždaviniuose. 1.4 lentelėje pateikti straipsniai, kuriuose AVM buvo sėkmingai pritaikyti EES.

1.4 lentelė. Svarbūs AVM modelių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
Ma et al. (2017) [27]	„IEEE Transactions on Circuits and Systems I: Regular Papers“	Saulės apšvietos lygių įvertinimas pagal fotovoltinės elektrinės charakteristikas
Özdemir et al. (2016) [28]	„Neural Network World“	Harmonikų įvertinimas nustatant galios kokybę
Arikan et al. (2013) [29]	„International Review of Electrical Engineering“	Elektros energijos kokybės sutrikimų klasifikacija

Ma ir kt. [27] sukūrė jautrų jutiklį (lauko palaikymo vektoriaus regresiją), kad padidintų saulės apšvietos lygių įvertinimo tikslumą pagal SE parametrus. Jautrusis jutiklis rinko įeities duomenis į kelias grupes pagal aplinkos temperatūrą. Pristatytas jautrusis jutiklis gali būti įrengiamas SE modulyje, srovės jutiklyje arba termometre. Tyrimas buvo patvirtintas eksperimentiniu prototipu ir modeliavimu, naudojant išmatuotas lauko sąlygas. 12 paveiksle pateiktos tyrimo RMSE vertės.

Özdemir ir kt. [28] tyrė AVM panaudojimą harmonikų iškraipymų įvertinimui. Buvo tiriamas energijos skirstomasis tinklas, o prognozuojami rezultatai buvo palyginti su realiais duomenimis. Pateiktas metodas buvo palygintas su DNT ir tiesinės regresijos metodais. Testavimo rezultatai parodė, kad DNT gali būti panaudoti suminiam harmonikų iškraipymų lygiui įvertinti skirstomajame tinkle.

Arikan ir kt. [29] atliko elektros energijos kokybės sutrikimų klasifikavimo tyrimą, panaudodami DNT. Šiame darbe buvo sukurtas modelis, skirtas atskirti aukštos kokybės elektros energiją (sinusoidę) ir penkis skirtingus elektros energijos kokybės sutrikimus: įtampos sumažėjimą, padidėjimą, mirgėjimą, įvairių eilių harmonikas bei pereinamuosius procesus, įėjimo duomenims iš pradžių atliekant bangelių transformaciją (angl. *wavelet transform*). Siūlomas metodo efektyvumas buvo patikrintas, panaudojant sintetinius duomenis, gautus iš matematinio modelio ir realių matavimų. Buvo palyginti AVM, DNT ir naiviojo Bayes'o klasifikatorius. Pastebėta, kad DNT rezultatai buvo geriausi tiek naudojant sintetinius duomenis, tiek ir realius matavimus.

1.5. Bangelių neuroninis tinklas

Bangelių neuroninis tinklas (BNN) yra dar viena neuroninių tinklų atšaka, kuri išnaudoja bangelių analizės (angl. *wavelet analysis*) ir neuroninių tinklų atskirų metodų pranašumus. Bangelių analizė yra vertingas įrankis analizuoti įvairias laiko eilutes ir jau buvo sėkmingai naudojamas vaizdo apdorojimui, signalo triukšmo mažinimui, tankio įvertinimui, signalo ir vaizdo glaudinimui bei laiko skalės dekompozicijai [30]. Bangelių analizė matematikoje dažnai laikoma „mikroskopu“ [31] ir yra galinga priemonė netiesiškumui vaizduoti [32]. Pagrindinis bangelių analizės trūkumas yra tas, kad dėl reikalingų didelių skaičiavimo resursų, ji yra ribota daugiamačių įeities duomenų analizei. 1.5 lentelėje pateikti straipsniai, kuriuose BNN buvo sėkmingai pritaikyti EES.

1.5 lentelė. Svarbūs BNN modelių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
He et al. (2018) [33]	„Applied Energy“	Vėjo greičio prognozavimas sumažinant įėjimo duomenų triukšmo įtaką
Sarshar et al. (2017) [34]	„Energy“	Neapibrėžtumų sumažinimas vėjo gamybos prognozavime
Doucoure et al. (2016) [35]	„Renewable Energy“	AEI laiko eilučių analizė

He ir kt. [33] pasiūlė hibridinį prognozavimo modelį, kurį sudarė trys moduliai: duomenų grupavimas (angl. *clustering*), duomenų pirminis apdorojimas ir prognozavimas. Bangelių analizė buvo naudojama siekiant sumažinti įėjimo duomenų eilutės triukšmo įtaką ir kad būtų pasiektas didesnis stabilumas, išskiriant broožus iš pirminių duomenų. Prognozavimo modulio apmokymo duomenims buvo pasirinktas panašus kelias, siekiant pagerinti prognozavimo tikslumą. Eksperimentiniai duomenys parodė, kad nagrinėjamas modelis pralenkia kitus darbe aptartus prognozavimo modelius.

Sarshar ir kt. [34] pateikė adaptyvią tikimybinę pasikliautinumo intervalo koncepciją, skirtą vėjo greičio atsitiktinumui spręsti. Prognozavimo tikslumui padidinti, bangelių transformacija buvo pritaikyta vėjo elektrinės galios laiko eilutėms, o rezultatai panaudoti apmokyti DNT. Tada buvo apskaičiuoti prognozuojami vėjo elektrinės galios pasikliautinumo lygiai. Siekiant sumažinti prognozavimo klaidų įtaką mikrotinklui ir padidinti prognozavimo lankstumą, buvo panaudota energijos kaupimo sistema. Galiausiai pateiktas algoritmas buvo testuojamas atliekant tipinį mikrotinklo tyrimą. Rezultatai parodė, kad sprendžiant šį uždavinį, nagrinėtas BNN pranašesnis už DNT.

Doucoure ir kt. [35] sukūrė AEI prognozavimo metodiką tam, kad būtų skatinamas tiek izoliuotų, tiek ir prie tinklo prijungtų AEI naudojančių elektrinių įrengimas. Pateiktas metodas buvo sudarytas iš DNT ir bangelių transformacijos. Šiame tyrime buvo analizuojamos kiekvieno įėjimo duomenų komponento prognozės, naudojant Hurst koeficientą. Siekiant užtikrinti prognozių tikslumą ir sumažinti skaičiavimo algoritmo sudėtingumą, panaudojus bangelių transformaciją buvo pašalinti kai kurie komponentai, turintys nykstantai mažą įtaką prognozavimo tikslumui. Rezultatai parodė, kad panaikinus šiuos komponentus, galima išgauti panašų modelio tikslumą, o reikalingus skaičiavimo resursus sumažinti 29 %.

1.6. Adaptyvi neuroninė–neraiškioji išvedimo sistema

Adaptyvi neuroninė–neraiškioji išvedimo sistema (ANNIS) yra modeliavimo metodas, kuriame naudojamas DNT, pagrįstas Takagi – Sugeno neraiškioji išvedimo sistema. Šį metodą sudaro penki pagrindiniai sluoksniai, kurių pagalba išnaudojama neraiškiosios logikos (angl. *Fuzzy Logic*) ir DNT galimybės. Šis metodas laikomas ankstyvąja hibridinio MM metodo forma [36]. 1.6 lentelėje pateikti straipsniai, kuriuose ANNIS buvo sėkmingai pritaikyti EES.

1.6 lentelė. Svarbūs ANNIS modelių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
Abdulwahid et al. (2018) [37]	„Sustainability (Switzerland)“	Apsauginis prietaisas nuo priešingos krypties galios srauto
Kampouropoulos et al. (2018) [38]	„IEEE Transactions on Smart Grid“	Elektrinės galios poreikio prognozavimas ir energijos srautų optimizavimas
Bassam et al. (2017) [39]	„Sustainability (Switzerland)“	Fotovoltinių SE modulių temperatūros nustatymas
Mohammadi et al. (2016) [40]	„Renewable and Sustainable Energy Reviews“	Svarbiausių kintamųjų identifikavimas dienos horizonto saulės apšvietos prognozei

Abdulwahid ir Wang [37] pristatė naują apsaugos metodą, skirtą užkirsti kelią atvirkštiniam energijos srautui. Šis metodas buvo sukurtas su ANNIS ir yra skirtas išmaniesiems tinklams. Tyrimas pristatė patobulintą apsaugos prietaisą, panaudojant naujai sukurtą intelektualią sprendimų palaikymo sistemą (angl. *intelligent decision support system*). Autoriai padarė išvadą, kad pagrindinis šio metodo pranašumas yra tas, kad jis sumažina priešingos krypties galios srauto relės nusistovėjusio režimo svyravimus ir turi galimybę veikti ekstremaliois aplinkos sąlygomis.

Kampouropoulos ir kt. [38] pristatė naują HEES energijos optimizavimo metodą. Šiame tyrime gamyklos energijos poreikiui prognozuoti buvo pritaikyta ANNIS. Gamybos energijos srautui modeliuoti buvo naudojamas genetinis algoritmas. Optimizavimo algoritmo tikslas buvo patenkinti gamyklos energijos poreikį ir sumažinti optimizavimo kriterijus. Siūlomas metodas buvo testuojamas ir patvirtintas SEAT.

Bassam ir kt. [39] sukūrė ANNIS modelį fotovoltinių SE temperatūrai įvertinti. Apmokymo proceso įėjimo duomenis sudarė šie šeši aplinkos kintamieji: vėjo greitis, temperatūra, vėjo kryptis, saulės apšvieta, atmosferos slėgis ir santykinė oro drėgmė ir vienas papildomas kintamasis – SE gamyba. Modelis buvo testuojamas panaudojant eksperimentinius SE duomenis. Modelio rezultatai rodo, kad pateikta metodika gali būti naudojama kaip patikimas modulių temperatūros įvertinimo įrankis.

Mohammadi ir kt. [40] pateikė metodą, skirtą nustatyti pagrindinius dienos horizonto saulės apšvietos prognozavimui reikalingus kintamuosius, naudojant ANNIS atrankos procedūrą. Buvo tiriami trys skirtingi miestai. ANNIS modelis atranko devynis kintamuosius: saulės spinduliuotę, slėgis jūros lygyje, santykinė drėgmė, vandens garų slėgis, mažiausia, vidutinė ir maksimali oro temperatūra, maksimali galima saulės spindėjimo trukmė ir saulės spindėjimo trukmė. Rezultatai parodė, kad skirtingiems nagrinėtiems miestams buvo atrinkti skirtingi optimalūs įeities kintamieji. Šis tyrimas parodė įeities duomenų parinkimo reikšmę prognozuojant saulės apšvieta.

1.7. Sprendimų medžiai

Sprendimų medžiai (SM) skirti spręsti tiek klasifikavimo, tiek ir regresijos uždavinius. Šis metodas panaudodamas sprendimo mazgus, duomenų rinkinį išskaido į segmentus (medžio šakas), o kiekviena šaka baigiasi sprendimų mazgais (medžio lapais). 1.7 lentelėje pateikti straipsniai, kuriuose SM buvo sėkmingai pritaikyti EES.

1.7 lentelė. Svarbūs SM modelių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
Kamali et al. (2017) [41]	„Applied Energy“	Visiško elektros energijos išjungimo (angl. <i>blackout</i>) rizikos prognozavimas EES
Costa et al. (2016) [42]	„Electric Power Systems Research“	Įpareigojimo generuoti (angl. <i>unit commitment</i>) paskirstymo metodas, įvertinantis saugumo reikalavimus kritinėms energetikos infrastruktūroms
Moutis et al. (2016) [43]	„Applied Energy“	Energijos kaupimo planavimas ir energijos valdymas
Ottesen et al. (2016) [44]	„Energy“	Bendrųjų energijos sąnaudų minimizavimas gaminančių vartotojų pastatuose

Kamali ir kt. [41] pristatė naują dviejų pakopų metodą visiško elektros energijos išjungimo elektros energijos tinkle rizikai numatyti. Pirmiausia, išdalintų sistemų ribos buvo nustatytos naudojant mišrių sveikųjų skaičių netiesinį programavimo (angl. *Mixed Integer Nonlinear Programming*) metodą, su kuriuo optimizavo apkrovos praradimo ir galios srautų perskirstymo išlaidas. Antra, buvo atliktas duomenų gavybos metodas, skirtas išdalintų sistemų atsiskyrimo nuo likusio tinklo rizikai numatyti. Buvo išanalizuoti keli scenarijai, tokie kaip darbas salos ir ne salos režime, o paskui panaudojami SM galimo visiško elektros energijos išjungimo prognozavimui.

Costa ir kt. [42] panaudojo SM įpareigojimo generuoti paskirstymui kritinėse energetikos infrastruktūrose (gamtinių dujų ir elektros tinkluose) avarijų atveju. Jų pasiūlytas metodas įvertina galimus saugumo apribojimus įvykius, pavyzdžiui, dujų nuotėkiui ar linijos atsijungimui, ir paskirsto galias optimaliai taip, kad būtų pereita iš nesaugaus darbo režimo vėl į saugų.

Moutis ir kt. [43] pirmieji pristatė SM pritaikymą planuojant energijos kaupimo sistemas mikrotinkluose ir valdant energijos šaltinius taip, kad būtų išlaikomas generuojamos energijos ir planuojamo poreikio mikrotinkle balansas. Pateikta metodika buvo testuojama atliekant jautrumo analizę keliems scenarijams. Šio metodo pagrindu buvo sukurtas valdiklis balanso palaikymui realiu laiku.

Ottesen ir kt. [44] panaudojo SM energijos balansavimui ir planavimui mikrotinkluose. Šio darbo tikslas buvo sumažinti bendruosius kaštus prekiaujant elektros energijos rinkoje, įvertinant tinklo tarifus, balansavimo kainas ir kuro sąnaudas. Darbe buvo įvertinta gaminančių vartotojų pastatų lankstumas modeliuojant jų teikiamus valandinius pasiūlymus. Neapibrėžtų parametrų informacijos struktūra buvo užfiksuota scenarijų medžiuose. Sprendimų priėmimo ir planavimo žingsniams buvo taikoma dviejų pakopų atsitiktinis mišrių skaičių tiesinis programavimas (angl. *Stochastic Mixed-Integer Linear Programming*).

1.8. Gilusis mokymas

DNT su daugiau nei 3 sluoksniais, vadinamas giliuoju neuroniniu tinklu (GNT). Dėl padidėjusio skaičiavimo galios ir didelio duomenų kiekio, gilusis mokymas (GM) taikomas vis dažniau. 1.8 lentelėje pateikti straipsniai, kuriuose GM buvo sėkmingai pritaikytas EES.

1.8 lentelė. Svarbūs GNT modelių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
Chemali et al. (2018) [45]	„Journal of Power Sources“	Energijos kaupiklio įkrovos lygio įvertinimas
Coelho et al. (2017) [46]	„Applied Energy“	Elektros poreikio namų ūkyje prognozavimas
Kim et al. (2017) [47]	„Computational Intelligence Neuroscience“	Atskirų įrenginių skirstomajame tinkle energijos suvartojimo įvertinimas
Wang et al. (2017) [48]	„Energy Conversion and Management“	SE generuojamos energijos prognozavimas

Chemali ir kt. [45] pristatė GM metodiką, skirtą įvertinti ličio jonų baterijos įkrovos būseną. Modelio apmokymo duomenys buvo sukurti laboratorijoje panaudojant tą patį laiką kintantį įkrovos/iškrovos ciklą prie įvairių aplinkos temperatūrų. Tai leido įvertinti baterijos įkrovos kitimą esant dinaminei apkrovai. Šiuo tyrimu buvo parodytas giliųjų neuroninių tinklų gebėjimas užkoduoti priklausomybes neuroninio tinklo svoriuose realaus laiko uždaviniuose.

Coelho ir kt. [46] pristatė grafikos procesoriaus (angl. *Graphics Processing Unit*) giluminio mokymosi modelį laiko eilučių prognozavimui. Buvo sukurta nauja lygiagreti laiko eilučių mokymosi metodika. Pateikta metodika buvo pritaikyta hibridiniame metaeuristiniame modelyje, skirtam mini/mikrotinklų prognozavimo problemai (namų ūkio elektros energijos poreikiui). Apskaičiuoti rezultatai parodė, kad pateikta grafikos procesoriaus mokymosi metodika yra tiksli ir gali būti panaudota išmaniuosiuose jutikliuose.

Apkrovos netrikdantis stebėjimas (angl. *Nonintrusive Load Monitoring*) – tai įtampos ir srovės pokyčio analizės procesas, kuriuo siekiama išsiaiškinti, kokie prietaisai yra naudojami name ir kokios kiekvieno jų atskirai energijos sąnaudos. Kim ir kt. [47] pasiūlė GM pagrįstą metodą, skirtą apkrovos netrikdančiam stebėjimui. Šiame tyrime buvo pasiūlytas energijos išskaidymas, panaudojant GNT ir grįžtamojo ryšio (rekurentinio) neuroninio tinklo modelį. Šiuo tyrimu buvo parodyta, kad GM gali pagerinti apkrovos identifikavimo efektyvumą.

Wang ir kt. [48] pristatė naują fotovoltinės SE generuojamos energijos prognozavimo metodą, panaudojant bangelių transformaciją ir gilųjį sąsūkų (konvoliucinį) neuroninį tinklą (angl. *Deep Convolutional Neural Network*). Gilus sąsūkų neuroninis tinklas buvo panaudotas išgauti nekintančias struktūras ir netiesinius bruožus, išgaunamus iš kiekvieno dažnio. Tyrimo rezultatai parodė, kad pasiūlyti metodai gali pagerinti prognozavimo tikslumą įvairiais metų laikais ir skirtingais prognozavimo horizontais.

1.9. Įvairių metodų ansambliai

Metodų ansambliuose naudojami keli mokymosi algoritmai, skirti MM ir statistikai, kad būtų pasiektas geresnis modeliavimo rezultatas nei ansamblį sudarančių algoritmų atskirai. Metodų ansamblių geri rezultatai yra tais atvejais, kai ansamblį sudarantys modeliai yra tikslūs bei silpnai koreliuoja tarpusavyje. 1.9 lentelėje pateikti straipsniai, kuriuose įvairių modelių ansambliai buvo sėkmingai pritaikyti EES.

1.9 lentelė. Svarbūs modelių ansamblių pritaikymai elektros energetikos srityje

Autoriai, metai, šaltinis	Mokslinis žurnalas	Pritaikymas
Zhang et al. (2020) [49]	„Future Generation Computer Systems“	Transformatorių gedimų diagnostika
Lee et al. (2020) [50]	„Applied Computing and Informatics“	Saulės apšvietos prognozavimas
Fu (2018) [51]	„Energy“	Pastato vėsinimo sistemos elektros energijos poreikio prognozavimas
Burger ir Moura (2015) [52]	„Energy and Buildings“	Pastato elektros poreikio prognozavimas

Zhang ir kt. [49] pateikė naują transformatoriaus gedimų diagnostikos metodą panaudojant daiktų internetu pagrįstą stebėjimo sistemą ir metodų ansamblį. Stebėjimo sistemą, pagrįstą daiktų interneto technologija, sudarė dvi dalys: duomenų matavimas ir duomenų gavimas. Siūlomas metodų ansamblis, susideda iš gilaus įsitikinimo tinklo (angl. *Deep Belief Network*), sudedamų slopinančiųjų autoenkoderių (angl. *Stacked Denoising Autoencoders*), turinčių skirtingas aktyvavimo funkcijas, ir atraminių vektorių mašinų. Buvo atliktas transformatoriaus gedimų diagnozavimo eksperimentas, kurio diagnozės rezultatai patvirtino, kad suprojektuota stebėjimo sistema gali efektyviai rinkti vibracijos signalus esant net toli nutolus nuo tiriamo transformatoriaus.

Lee ir kt. [50] pritaikė metodų ansamblį iš įvairių meteorologinių duomenų gauti patikimą trumpalaikio horizonto saulės apšvietos prognozę. Metodų ansamblį sudarė įvairios SM variacijos, įskaitant išpūstus medžius (angl. *Boosted Trees*) ir atsitiktinius miškus (angl. *Random Forest*, toliau – AM). Šio ansamblio metodo tikslumas buvo palygintas su kitais jau taikomais prognozavimo metodais – Gauso proceso regresija ir atraminių vektorių mašinomis. Rezultatai parodė, kad metodų ansamblis yra tikslesnis už atskirus metodus. Be to, nors ir duomenys naudojami iš skirtingų vietų, modelių ansamblis pateikia nuoseklią ir patikimą prognozę.

Fu [51] pateikė metodų ansamblį oro kondicionavimo sistemos aušinimo apkrovai prognozuoti. Pateiktas metodas buvo naudojamas deterministiniame aušinimo apkrovos numatymui labai tiksliai. Modelių ansamblis susidėjo iš gilaus įsitikinimo tinklo ir empirinio režimo išskaidymo. Originalios aušinimo apkrovos duomenų eilutės buvo išskaidytos į keletą komponentų. Metodų ansamblis buvo panaudotas siekiant sumažinti neapibrėžtumų, tokių kaip duomenų triukšmas ar atskirų modelių paklaidų įtaką prognozės tikslumui.

Burgeris ir Moura [52] apibendrina elektros energijos poreikio prognozavimą, apmokydami metodų ansamblio modelį. Šį modelį nesunku panaudoti praktikoje dėl to, kad jo apmokymui tereikia nedaug informacijos apie galutinę energijos suvartojimą. Pritaikę šį modelį 32 pastatų (8 komerciniai ir 24 gyvenamieji) elektros energijos poreikių prognozei, buvo atitinkamai gauta 7,5% ir 55,8% vidutinė absoliučioji procentinė paklaida.

2. Problemos formulavimas

Atlikus literatūros analizę, galima aiškiai matyti, kad pastaraisiais metais didžiausias susidomėjimas DI algoritmų pritaikymu EES susijęs su atsinaujinančiąja energetika, iš kurių pagrindė – saulės energetika. Buvo sukurti įvairūs, už empirinius pranašesni DI modeliai tiek meteorologinėms sąlygoms (apšvietai, temperatūrai ir kt.), tiek ir tiesiogiai SE generuojamai energijai prognozuoti [14,19,20,22–24,27,40,48,50]. Tarp šių sukurtų modelių vyrauja DNT, tačiau AVM, gilusis mokymas ir modelių ansambliai kitais atvejais davė geresnius rezultatus nei DNT. Sukurtų modelių pritaikymas skirtingose vietovėse parodė, kad nėra ne tik vieno geriausio metodo SE generuojamai energijai prognozuoti, bet nuo vietovės kinta ir reikalingų kintamųjų kiekis bei svarbumas.

HEES, susidedančios iš dviejų ar daugiau AEI naudojančių elektrinių, ypač, plūduriuojančios SE ir hidroelektrinės ar hidroakumuliacinės elektrinės [53–57] sulaukia vis didesnio susidomėjimo. Pagrindinis šios HEES privalumas – pastovi generuojama energija dienos energijos poreikio piko metu ir vandens taupymas toms valandoms, kai saulės mažiau ar visai nėra. Kiti privalumai – mažesni SE prijungimo prie elektros energijos perdavimo tinklo kaštai dėl esamos hidroelektrinės infrastruktūros, efektyvus turimo nenaudojamo ploto išnaudojimas bei mažesnis hidroelektrinės ar hidroakumuliacinės elektrinės viršutinio baseino (toliau – VB) garavimas. Daugumoje literatūroje aptiktų straipsnių ištirtas bendras šios HEES potencialas, tik [55] buvo sumodeliuotas šios HEES darbas detaliau siekiant išlyginti bendrą HEES generuojamą galią.

Taigi, literatūroje galima rasti DI metodų taikymą AEI naudojančių elektrinių generuojamai energijai prognozuoti bei straipsnius, patvirtinančius apie plūduriuojančios saulės elektrinės ir hidroakumuliacinės elektrinės HEES sinergiją, tačiau nėra atlikta pakankamai detalių tyrimų, kaip gauti optimalią tokios HEES naudą. Atsižvelgiant į DI metodų bei HEES potencialą, pirmiausiai šiame darbe sukurti skirtingi vieno iš HEES elementų – SE – generuojamos energijos DI modeliai ir vienas empirinis modelis. Tada iš sukurtų modelių gautos generuojamos energijos prognozės, kartu su faktinėmis elektros energijos rinkos kainomis ir apskaičiuotomis disbalanso rinkos kainomis, panaudotos atliekant vienu metų HEES darbo optimizacinį uždavinį maksimizuojant pajamas. Tokiu būdu palygintas skirtingų DI metodų pritaikomumas šioje HEES įvertinant esamas rinkos sąlygas.

Darbe išnagrinėta HEES susideda iš hipotetinės 200 MWp plūduriuojančios SE ant Kruonio hidroakumuliacinės elektrinės (toliau – KHAE) VB ir KHAE. Dėl netipinių HEES elementų dydžių proporcijų (energijos kaupiklis žymiai didesnis už generacijos šaltinį), literatūroje nerasta metodikos, galinčios įvertinti tokios HEES charakteristikas jos veikimą elektros rinkos sąlygomis. Hipotetinės SE faktiniam ir prognozuojamiems generacijos profiliams iš skirtingų DI metodų sudaryti panaudoti SE, įrengtos ant Kauno technologijos universiteto (toliau – KTU) Elektros ir elektronikos bei Informatikos rūmų, duomenys.

3. Metodika

Ant KTU studentų g. 48 ir 48a pastatų stogų įrengta 379 kWp SE. Šio pastato taško geografinė ilguma – $54,88^\circ$, o platuma – $23,88^\circ$. Fotovoltinių saulės modulių orientacija erdvėje (azimutas) lygus -29° , pasvirimo kampas – 25° , o pati SE įrengta 69 m. virš jūros lygio. 3.1 pav. kairėje pateiktas SE dalies nuotrauka, o dešinėje – programine įranga „Meteonorm“ sumodeliuotas SE skaitmeninis vaizdas. Su šia programine įranga atlikti empiriniai SE generuojamos energijos prognozavimo skaičiavimai.



3.1 pav. SE dalies nuotrauka ir vaizdas iš „Meteonorm“ programinės įrangos

2019 m. lapkričio 2 d. ant KTU priklausančio pastato, esančio Studentų g. 48a, stogo įdiegta ir sukalibruota ASI (All Sky Imager) sistema (žr. 3.2 pav.), kurią sudaro: piranometras ir dangaus stebėjimo kamera. Kameros vaizdų ir meteorologinių matavimų saugojimui paskirta vieta KTU serveryje. Meteorologiniai duomenys apima bendrąją saulės spinduliuotę (E), santykinę oro drėgmę (ϕ) ir aplinkos temperatūrą (T). Kameros vaizdai saugomi kas 15 min. intervalą, o meteorologiniai matavimai – kas 5 s.



3.2 pav. ASI sistemos nuotrauka

3.1. Empirinis SE generuojamos energijos modelis

Valandinės energijos, kritusios į horizontalų paviršių, reikšmės gaunamos iš „Meteonorm“ duomenų bazės. Suminei saulės spinduliuotei apskaičiuoti, šios vertės padauginamos iš suminės spinduliuotės daugiklio, kuris apskaičiuojamas pagal Liu–Jordan modelį:

$$\frac{H_t}{H_g} = \left(1 - \frac{H_d}{H_g}\right) \cdot R_b + \frac{H_d}{H_g} \cdot R_d + R_r \quad (3)$$

čia H_t – valandinis energijos kiekis, tenkantis vienam kvadratiniam metrui ant pasvirusio paviršiaus, H_g – valandinis energijos kiekis, tenkantis vienam kvadratiniam metrui ant horizontalaus paviršiaus, H_d – valandinis išsklaidytosios energijos kiekis, tenkantis vienam kvadratiniam metrui ant horizontalaus paviršiaus, R_b – tiesioginės spinduliuotės koeficientas, R_d – išsklaidytosios spinduliuotės koeficientas, R_r – atspindėtosios spinduliuotės koeficientas. Šie koeficientai apskaičiuojami pagal šias formules:

$$R_b = \frac{\cos\theta}{\cos\theta_z} \quad (4)$$

čia θ – kampas tarp saulės spindulių krypties ir paviršiaus normalės, θ_z – kampas tarp saulės spindulių krypties ir paviršiaus vertikalės.

$$\begin{aligned} \cos\theta &= \sin\phi(\sin\delta \cdot \cos\beta + \cos\delta \cdot \cos\gamma \cdot \cos\omega \cdot \sin\beta) + \\ &+ \cos\phi(\cos\delta \cdot \cos\omega \cdot \cos\beta - \sin\delta \cdot \cos\gamma \cdot \sin\beta) + \cos\delta \cdot \sin\gamma \cdot \sin\omega \cdot \sin\beta \end{aligned} \quad (5)$$

$$\begin{aligned} \cos\theta_z &= \sin\phi \cdot \sin\delta + \cos\phi \cdot \cos\delta \\ &\cdot \cos\omega \end{aligned} \quad (6)$$

čia ϕ – geografinė platumą, δ – deklinacija, γ – azimutas, β – paviršiaus pasvirimo kampas, ω – valandos kampas. Deklinacija ir valandos kampas apskaičiuojami pagal šias formules:

$$\begin{aligned} \delta &= 23,45 \cdot \sin \frac{360(280 + n)}{365} \end{aligned} \quad (7)$$

čia n – metų diena

$$\omega = 15(ST - 12) \quad (8)$$

čia ST – vietovės laikas valandomis 24 valandų sistemoje.

$$R_d = \frac{1 + \cos\beta}{2} \quad (9)$$

$$R_r = \frac{\rho(1 - \cos\beta)}{2} \quad (10)$$

čia ρ – vietovės atspindžių koeficientas (Albedo). Lietuvoje ši reikšmė vidutiniškai lygi 0,2.

3.2. Dirbtinio intelekto modeliai saulės elektrinės generuojamai energijai prognozuoti

Šiame darbe nagrinėjami 4 skirtingi MM metodai: regresija, DNT, AVM ir atsitiktiniai miškai. Panaudojant šiuos 4 metodus apmokyta ir atrinkta po vieną geriausią modelį iš kiekvieno metodo. Toliau trumpai aprašytas kiekvienas iš šių metodų.

3.2.1. Regresija

Regresijos modelis yra statistinis modelis, leidžiantis vieno kintamojo reikšmes prognozuoti pagal kito kintamojo reikšmes. Standartinė tiesinės regresijos modelio matematinė išraiška:

$$y = a + \left(\sum b_i x_i \right) + \varepsilon \quad (11)$$

čia y – priklausomas kintamasis, x_i – i -asis nepriklausomas kintamasis, a – taškas, kuriame tiesė kerta y ašį, b_i – i -ojo nepriklausomo kintamojo krypties koeficientas, su kuriuo modelis turi mažiausią liekanų kvadratų sumą, ε – liekana.

Netiesinės regresijos modeliu aprašoma netiesinė priklausomybė tarp kintamojo X_i reikšmės ir ją atitinkančios Y_i reikšmės. Bendruoju atveju m -osios eilės polinomu išreikštas modelis atrodo taip:

$$y = a_0 + a_1 x + a_2 x^2 + \dots + a_m x^m + \varepsilon \quad (12)$$

Modelį dažnai patogiau išreikšti matricių anotacija:

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} = \begin{bmatrix} 1 & x_1 & x_1^2 & \dots & x_1^m \\ 1 & x_2 & x_2^2 & \dots & x_2^m \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_N & x_N^2 & \dots & x_N^m \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_N \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_N \end{bmatrix} \quad (13)$$

$$\mathbf{y} = \mathbf{Xb} + \mathbf{e} \quad (14)$$

Regresijos koeficientai randami naudojant mažiausių kvadratų metodą, t.y. minimizuojant sumą:

$$S = \sum_{i=0}^n e_i^2 \quad (15)$$

čia:

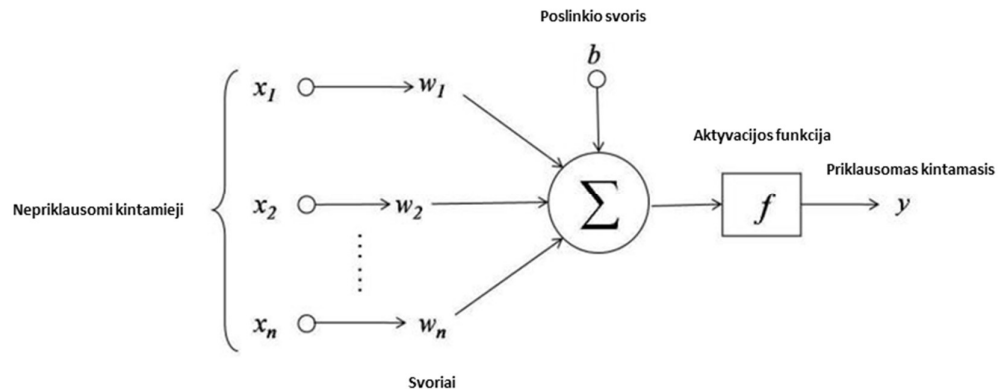
$$e_i = y_i - b_0 - \sum_{i=0}^N b_i x_i \quad (16)$$

Formulė, rasti mažiausių kvadratų regresijos koeficientų įverčius \mathbf{b} , naudojant matricių anotaciją:

$$\mathbf{b} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} \quad (17)$$

3.2.2. Dirbtinis neuroninis tinklas

DNT modelio architektūra gali būti sudaroma iš n įvairių dydžių paslėptų sluoksnių, tačiau įėjties sluoksnis paprastai turi vienu neuronu daugiau nei nepriklausomų kintamųjų kiekis, o išeities – kiek priklausomų kintamųjų. Poslinkio svoris paprastai taikomas ir paslėptuose sluoksniuose tam, kad būtų padidintas neuroninio tinklo sluoksnio lankstumas. 3.3 pav. pateiktas DNT sudarančio vieno perceptrono matematinis modelis.



3.3 pav. Perceptrono matematinis modelis

Perceptronas pirmiausiai atlieka įeičių (x_i), padaugintų iš atitinkamų svorių (w_i), sumavimo funkciją:

$$x = \sum_i^N w_i b_i \quad (18)$$

Tada pritaikoma aktyvacijos funkcija tam, kad modelyje atsirastų netiesiškumo. Dažniausiai naudojama ReLU (angl. *rectified linear unit*), sigmoidė arba hiperbolinio tangento aktyvacijos f–jos:

$$y = \max(0, x) \quad (19)$$

$$S(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} \quad (20)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (21)$$

Paprastai DNT apmokymui naudojamas gradientinis nusileidimas arba jo modifikacijos. Taikant gradientinio nusileidimo metodą, išmokstamų tinklo parametrų atnaujinimas atliekamas kiekvieną epochą apskaičiavus klaidos funkcijos reikšmę su kiekvienu mokymosi aibės elementu. Siekiant sumažinti galimą osciliavimą klaidos paviršiuje ir pagreitinti tinklo apmokymą, galima atsižvelgti į buvusius parametrų atnaujinimo greičius įvedant dar vieną hiperparametrą α . Gradientinio nusileidimo ir gradientinio nusileidimo su pagreičiu atnaujinimo taisyklės:


$$v_{i+1} = \eta \nabla_{\theta} L(\theta), \quad \theta = \theta - v_{i+1} \quad (22)$$

$$v_{i+1} = \alpha v_i + \eta \nabla_{\theta} L(\theta), \quad \theta = \theta - v_{i+1} \quad (23)$$

čia θ – visi išmokstami tinklo parametrai, ∇L – klaidos funkcijos gradientas, η – apmokymo greitis.

3.2.3. Atraminių vektorių mašinos

3.4 pav. atvaizduotas tipinis AVM pavyzdys, kai, panaudojant branduolio funkcijas, duomenys transformuojami į daugiamatę požymių erdvę tam, kad būtų galima spręsti uždavinį su tiesiniu metodu.



3.4 pav. AVM duomenų transformavimas į daugiamatę požymių erdvę

Viena iš galimų AVM išraiškų regresijos uždaviniams, pagal [58]:

$$\min_{\mathbf{w}, b, \xi, \xi^*} = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n \xi_i + C \sum_{i=1}^n \xi_i^*,$$

$$y_i - \mathbf{w}^T \phi(\mathbf{x}_i) - \mathbf{b} \leq \varepsilon + \xi_i,$$

$$-y_i + \mathbf{w}^T \phi(\mathbf{x}_i) + \mathbf{b} \leq \varepsilon + \xi_i^*, \quad \xi_i, \xi_i^* \geq 0, \quad i = 1, \dots, n \quad (24)$$

čia \mathbf{w} – svorių vektorius, $\phi(\mathbf{x}_i)$ – \mathbf{x} atvaizdavimas požymių erdvėje, ξ ir ξ^* – laisvumo kintamieji (angl. *slack variables*), nurodantys modelio apatinį ir viršutinį lygio apribojimą išėjime, b – poslinkis, C – konstanta charakterizuoja funkcijos glotnumas (angl. *flatness*), ε – toleruojamos paklaidos slenkstis.

Dualioji funkcija:

$$\min_{\alpha, \alpha^*} = \frac{1}{2} (\alpha - \alpha^*)^T (\alpha - \alpha^*) \kappa(x_i, x_j) + \varepsilon \sum_{i=1}^l (\alpha + \alpha^*) + \sum_{i=1}^l y_i (\alpha - \alpha^*),$$

$$\sum_{i=1}^l (\alpha - \alpha^*) = 0, \alpha_i \geq 0, \alpha_i^* \leq C, \quad i = 1, \dots, n \quad (25)$$

čia $\kappa(x_i - x_j)$ – atraminis vektorius, o parametrai α ir α^* gaunami atliekant optimizaciją. Poslinkis b apskaičiuojamas taip [59]:

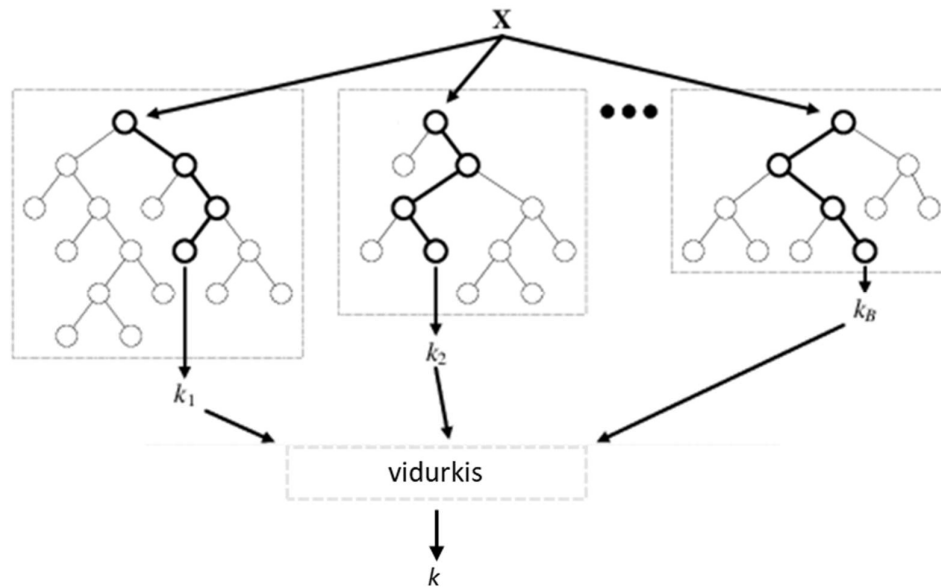
$$b = y_i - \sum_{j=1}^n \alpha_i^* \kappa(x_j, x_i) - \varepsilon, \quad \text{su tokiais } i, \text{ kad } 0 < \alpha_i < C \quad (26)$$

Regresijos lygtis:

$$f(\mathbf{x}) = \sum_{i=1}^n (\alpha^* - \alpha) \kappa(x_j, x_i) + b \quad (27)$$

3.2.4. Atsitiktiniai miškai

Atsitiktiniai miškai priskiriami metodų ansambliams, kadangi juos sudaro sprendimų medžių kolektyvas. 3.5 pav. pateikta modelio principinė schema. Kiekvieno medžio balsas priklauso nuo nepriklausomo atsitiktinio vektoriaus verčių, o modelio išėjimas regresijos uždaviniuose – vidurkis visų medžių balsų.



3.5 pav. Atsitiktinių miškų principinė schema [60]

Atsitiktinių miškų sprendimų medžiai auginami atrinkant svarbiausius bruožus kiekviename mazge, t.y., minimizuojant entropiją arba Gini koeficientą:

$$E = - \sum_j p_j \log_2 p_j \quad (28)$$

$$G = 1 - \sum_j p_j^2 \quad (29)$$

čia p_j – neteisingo pasirinkimo tikimybė.

Šališkumas (angl. *bias*) ir silpna koreliacija yra būtini tikslumui. Tam, kad būtų gautas šališkumas, medžiai auginami iki maksimalaus dydžio netaikant genėjimo, o tam, kad būtų gauta silpna koreliacija, taikomas atsitiktinumas:

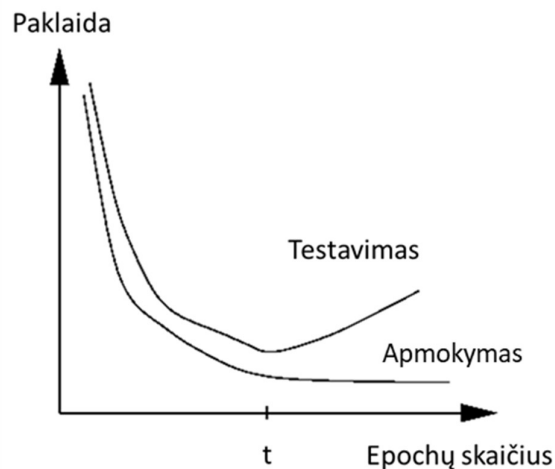
1. Kiekvienas atsitiktinio miško medis auginamas iš savirankos (angl. *bootstrap*) apmokymo imties;
2. Auginant medį, kiekviename mazge atsitiktinai atrenkama n kintamųjų;
3. Kiekviename mazge naudojamas tik vienas iš n kintamasis, duodantis geriausią atskyrimą.

Atsitiktiniai miškai gali būti pritaikomi ir išorinių kintamųjų atrinkimui, panaudojant atsitiktinių išlikimo miškų metodą.

3.3. Modelių vertinimas

Apmokant bet kokį MM algoritmą, apmokymo imtis suskaidoma į nedidelius paketus (angl. *batches*), telpančius vienu metu į skaičiavimo įrenginio operatyvinę atmintį. Apmokymo proceso dalis, kai visi nedideli paketai panaudojami apmokymui lygiai vieną kartą, vadinama epocha. Optimalus apmokymui reikalingų epochų skaičius priklauso nuo daugybės faktorių, įskaitant mašininio mokymo metodus, priklausomų ir nepriklausomų kintamųjų kiekį it kt.

3.6 pav. pateikta tipinė statistinių modelių persimokymo (angl. *overfitting*) problema, kai per didelis epochų skaičius duoda prastesnius rezultatus, nei optimalus. Vienas iš būdų, kaip spręsti šią problemą, yra naudoti ankstyvų stabdymą (angl. *early stopping*) t laiko momentu, kai testavimo paklaida pradeda didėti. Tam, kad būtų įvertinta kita svarbi modelio savybė – apibendrinti, naudojamas kryžminės validacijos metodas. Šio metodo esmė, kad duomenų rinkinys gali būti suskaidomas į atsitiktines, tiek ir į griežtai skirtingas nurodyto dydžio apmokymo ir testavimo imtis n kartų, o modelio įvertinimui naudojami gauti testavimo imčių rezultatai.



3.6 pav. Statistinių modelių paklaidų priklausomybė nuo epochų skaičiaus

Determinacijos koeficientas (R kvadratas) – tai svarbiausia modelio tikimo duomenims metrika, kuri parodo, kaip tiksliai nepriklausomi kintamieji aprašo priklausomąjį kintamąjį. Determinacijos koeficientas lygina skirtumus tarp Y reikšmių, kai atsižvelgiama į regresijos modelį, su skirtumais tarp Y reikšmių, kai į modelį neatsižvelgiama. Jis apskaičiuojamas pagal formulę:

$$R^2 = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y}_i)^2} \quad (30)$$

Apskaičiavus determinacijos koeficientą kiekvienai kryžminės validacijos testavimo imčiai (jų turi būti ne mažiau 7), galima apskaičiuoti dispersiją tarp šių koeficientų. Šis modelio charakteristika naudinga tuo atveju, kai keliems ar daugiau modelių apskaičiuotas determinacijos koeficientas yra panašus. Tokiu atveju pirmumas teikiamas modeliui(-iams) su mažesne dispersija. Dispersija apskaičiuojama pagal formulę:

$$\sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 \quad (31)$$

Sisteminioji paklaida (angl. *mean bias error*) apskaičiuojama siekiant įvertinti ar modelis yra linkęs prognozuoti per dideles ar per mažas priklausomo kintamojo vertes. Ši paklaida itin svarbi AEI naudojančių elektrinių generuojamos energijos prognozavimo uždaviniuose, kadangi disbalanso kainos ženkliai skiriasi priklausomai nuo disbalanso pobūdžio (perteklius ar trūkumas). Sisteminioji paklaida apskaičiuojama pagal formulę:

$$MBE = \frac{1}{N} \times \sum_{i=1}^N (\hat{y}(i) - y(i)) \quad (32)$$

3.4. Hibridinės sistemos optimizacijos uždavinys maksimizuojant pajamas

Kadangi darbe nagrinėjama HEES nėra tipinė, t.y. energijos kaupiklio dydis ženkliai didesnis už energijos gamybos šaltinio galią, optimizacinis uždavinys išskaidomas į 2 dalis. Pirmiausiai, nepriklausomai nuo SE generuojamos energijos prognozės, optimizuojamas Kruonio hidroakumuliacinės elektrinės (toliau – KHAE) savaitinis darbo grafikas. Kitas žingsnis, turint KHAE darbo grafiką, SE ir Baltijos sistemos valandos į priekį disbalanso kiekį bei apskaičiuotą disbalanso kainą, optimizuoti HEES suminį disbalanso dydį.

3.4.1. Prielaidos

- Preliminari planuojamos SE ant KHAE VB instaliuota SE galia – 200 MWp. Tai reiškia, kad valandinė faktinė ir modeliuojama SE ant KTU stogo gamyba turi būti padauginta iš daugiklio k :

$$k = \frac{P_2}{P_1} = \frac{200 \cdot 10^3}{379} = 527,7 \quad (33)$$

čia P_1 – SE ant KTU stogo instaliuota galia (kWp), P_2 – numatoma SE ant KHAE VB instaliuota galia (kWp).

- Numatomos SE ant KHAE VB generacijos profiliui naudojama ant KTU stogo įrengtos SE generacijos profilis, t.y. neatsižvelgiama į naują geografinę lokaciją, galimą išorinį šešėliavimą nuo VB sienų esant mažesniau vandens lygiui, naujos SE tipą, orientaciją, pasvirimo kampą, aušinimą, nuostolius ir kt.

3.1 lentelė. Viešai prieinami duomenys apie KHAE

Parametras	Žymėjimas	Reikšmė	Matavimo vienetas
Agregatų sk.	N	4	vnt.
Agregato maks. galia (gen. rež.)	P_{maks}	225	MW
Agregato maks. galia (siurb. rež.)	P_{min}	225	MW
Naudingas viršutinio baseino tūris	V_{sum}	41	mln. m ³
Maksimalus viršutinio baseino lygis	H_{maks}	153,5	M
Minimalus viršutinio baseino lygis	H_{min}	140	M
Vandens debitas (gen. rež)	Q_{gen}	226	m ³ /s
Vandens debitas (siurb. rež)	Q_{siurb}	189	m ³ /s


Iš 3.1 lentelėje pateiktų duomenų apskaičiuojama, kaip per valandą pakinta VB lygis KHAE dirbant maksimalia galia generatoriaus ir siurblio režimu:

$$H = H_{maks} - H_{min} = 153,5 - 140 = 13,5 \text{ m.} \quad (34)$$

$$k_{gen} = \frac{Q_{gen} \cdot 60 \cdot 60}{41 \cdot 10^6} \cdot H = \frac{226 \cdot 60 \cdot 60}{41 \cdot 10^6} \cdot 13,5 = 0,268 \text{ m.} \quad (35)$$

$$k_{siurb} = \frac{Q_{siurb} \cdot 60 \cdot 60}{41 \cdot 10^6} \cdot H = \frac{189 \cdot 60 \cdot 60}{41 \cdot 10^6} \cdot 13,5 = 0,224 \text{ m.} \quad (36)$$

- Vandens lygio VB pokytis priklauso nuo KHAE darbo režimo. 3.7 pav. pateikta, kad vandens lygio kitimas proporcingai priklauso aktyviosios galios dydžio ir dirbančių agregatų skaičiaus.



3.7 pav. KHAE VB vandens lygio kitimo priklausomybė nuo KHAE darbo režimo

- Dėl avarinio rezervo, teikiamo perdavimo sistemos operatoriui, „dienos prieš“ rinkoje gali dalyvauti 2 KHAE generatoriai ir 4 siurbliai.
- Nevertinama KHAE agregatų pasileidimo trukmė.
- KHAE agregatų galia nepriklauso nuo VB lygio.
- Nevertinamas Nemuno debitas, KHAE žemutinio baseino lygis ir jo apribojimai.
- Nevertinamas KHAE agregato naudingumo koeficientas prie skirtingų darbo režimų.
- KHAE agregatas gali dirbti bet kokia galia ribose tarp 0 ir 225 MW tiek siurblio, tiek ir generatoriaus režimu.
- KHAE agregatai visą valandą dirba pastovia suplanuota galia.
- KHAE agregato pasileidimo kaštai (P_{ST}) – 100 Eur.
- Savaitės horizonto valandinės „dienos prieš“ kainos prognozės neturi paklaidos.
- Nevertinama KHAE įtaka „dienos prieš“ rinkos kainoms.
- Nevertinama galimybė patikslintą SE generuojamos energijos prognozę parduoti į „einamos dienos“ rinką, kadangi šios faktinės kainos nėra skelbiamos.
- Valandos į priekį Baltijos sistemos ir SE disbalanso dydis ir disbalanso kaina neturi paklaidos.

- Kiekviena optimizuojama savaitė prasideda pirmadieniu, 7 val. ryto.
- KHAE VB lygis turi būti maksimalus pirmą ir paskutinę savaitės valandą.
- KHAE balansuoja SE taip, kad VB lygis kiekvienos dienos paskutinę valandą turi būti lygus suplanuotam.
- Paskutinę dienos valandą energija, reikalinga užkrauti trūkstamą vandens kiekį, kad būtų pasiektas suplanuotas VB lygis, nuperkama už faktinę tos valandos disbalanso kainą.
- Nevertinama KHAE galimybė teikti balansavimo paslaugą Baltijos sistemai (be SE).
- Nevertinamos KHAE dvišalės energijos pirkimo sutartys, kadangi šios kainos nėra skelbiamos viešai.

3.4.2. Kruonio hidroakumuliacinės elektrinės savaitės darbo grafiko optimizacijos uždavinys

Sprendžiant šį uždavinį, siekiama maksimizuoti pajamas, gaunamas iš prekybos KHAE galia „dienos prieš“ rinkoje. Kadangi savaitgalį „dienos prieš“ kainos paprastai mažesnės už darbo dienas, optimizavimo horizontas parenkamas – viena savaitė. Optimizacinis uždavinys sprendžiamas panaudojant mišrių kintamųjų tiesinio programavimo (angl. *mixed integer linear programming*) „Gurobi“ optimizavimo paketą. Tikslo funkcija:

$$\max \sum_{t=1}^T [(\beta_{1i} + \beta_{2i} - \beta_{3i} - \beta_{4i} - \beta_{5i} - \beta_{6i}) \cdot P_{DA} - (\eta_{1i} + \eta_{2i} + \eta_{3i} + \eta_{4i} + \eta_{5i} + \eta_{6i}) \cdot P_{ST}] \quad (37)$$

čia β – agregato energijos kiekis (MWh) parduodamas į „dienos prieš“ rinką, P_{DA} – „dienos prieš“ kaina, η – agregato būklė (veikia ar neveikia).

Apribojimai:

- agregato galia turi būti leistinose ribose:

$$0 \leq \beta_i \leq P_{maks} \quad (38)$$

- vandens lygis pradinę ir paskutinę valandą turi būti lygus maksimaliam:

$$h_1 = h_{T+1} = H_{maks} \quad (39)$$

- VB lygis turi būti leistinose ribose:

$$H_{min} \leq H_i \leq H_{maks} \quad (40)$$

- Ketvirtas apribojimas, kad VB lygis kistų proporcingai aktyviosios galios dydžiui, atsižvelgiant į (32) ir (33) lygtį:

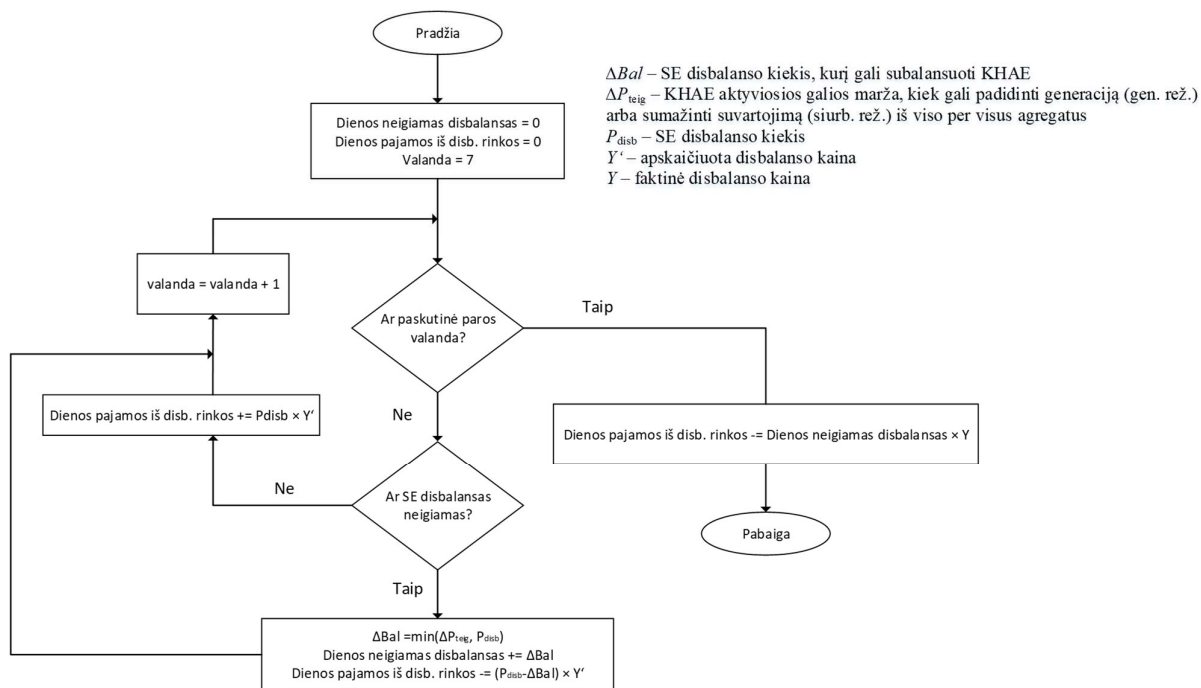
$$h_{T+1} = h_T - (\beta_{1i} + \beta_{2i}) \cdot k_{gen} + (\beta_{3i} + \beta_{4i} + \beta_{5i} + \beta_{6i}) \cdot k_{siurb} \quad (41)$$

- Penktas apribojimas, kad vienu metu negali veikti tas pats agregatas siurblio ir generatoriaus režimu:

$$\eta_1 + \eta_3 < 2, \quad \eta_2 + \eta_4 < 2 \quad (42)$$

3.4.3. Saulės elektrinės dienos balansavimo optimizacijos uždavinys

SE ir Baltijos sistemos tikslus disbalanso kiekis prognozuojamas ateinančiai valandai, todėl, apskaičiavus disbalanso kainą bei įvertinus KHAE galimybę balansuoti SE, kuriamas algoritmas, įvertinantis, kuriomis valandomis apsimoka nukrypti nuo plano, o kuriomis – ne, kad kiekvienos dienos gale KHAE vandens lygis pasiektų suplanuotą. Kadangi paprastai už generuojamos energijos perteklių yra gaunamos pajamos, o už stygių reikia susimokėti, balansuojamos tik tos SE valandos, kai SE generuoja mažiau nei išpareigojusi „dienos prieš“ rinkoje, o KHAE veikia ir turi maržą padidinti generaciją (gen. rež.) arba sumažinti suvartojimą (siurb. rež.). 3.8 pav. pateikta blokinė diagrama, atvaizduojanti optimizacinio algoritmo veikimo principą. Šiuo optimizaciniu algoritmu siekiama maksimizuoti pajamas iš disbalanso rinkos, valdant HEES disbalanso kiekį su KHAE.



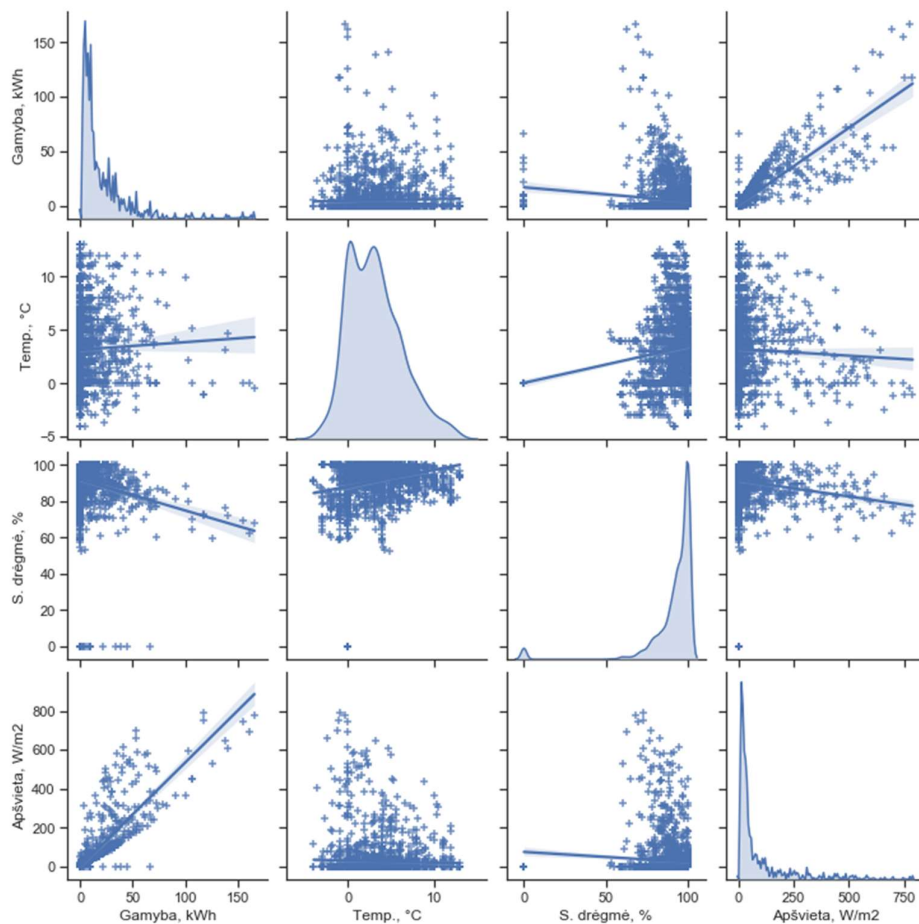
3.8 pav. Blokinė SE balansavimo optimizavimo schema

4. Rezultatai

ASI sistemos kaupiami meteorologiniai duomenys buvo panaudoti ASI sistemos – SE generacijos modeliui sudaryti. Šis modelis skirtas iš faktinių meteorologinių duomenų tame pačiame geografiniame taške apskaičiuoti SE generuojamą energiją. „Meteoblue“ – SE generacijos modelis skirtas prognozuoti dienos horizonto valandinę SE gamybą tam, kad būtų galima prekiauti „dienos prieš“ rinkoje. Disbalanso modelis sudaromas tam, kad būtų galima įverti 200 MW dydžio SE netikslų prognozių įtaką sąlyginai nedidelės Baltijos balansavimo rinkos kainoms, kurios panaudojamos sudarant HEES optimizavimo modelį ir palyginant DI prognozavimo modelius finansine išraiška.


4.1. ASI sistemos – SE generacijos modelio sudarymo rezultatai

ASI sistemos – SE generacijos modeliui sudaryti, naudojamas duomenų rinkinys nuo 2019 m. lapkričio 2 d. iki 2020 m. vasario 11 d., turintis 3 nepriklausomus kintamuosius (apšvieta, temperatūrą ir santykinę drėgmę) iš ASI sistemos bei 2 apskaičiuotus kintamuosius (saulės aukštis ir azimutas). 4.1 pav. pateiktos visų duomenų tarpusavio sklaidos diagramos, o ant diagonalės atvaizduojamos histogramos. Iš 4.1 pav. matyti, kad gamyba, apšvieta ir santykinė drėgmė primena eksponentinį pasiskirstymo dėsnį, o temperatūra – normalųjį. Aiškiai matoma tiesinė priklausomybė tarp apšvieta ir SE gamybos.




4.1 pav. Duomenų sklaidos diagramos ir histogramos

4.2 pav. atvaizduota SE gamybos priklausomybė nuo apšvietos. Iš 4.2 pav. kairėje esančios taškų sklaidos diagramos aiškiai matyti duomenų išskirtys, kai SE gamyba > 0, o apšvieta = 0 (apibraukta raudonai). Išanalizavus šiuos taškus, buvo nustatyta, kad 2019 m. spalio 19 d. ir 20 d. ASI sistema neveikė. To priežastis galėjo būti laikinas maitinimo išjungimas ar problema su kontaktais, taigi šie duomenys pašalinami iš modelio sudarymo. 4.2 pav. dešinėje esančiame grafike atvaizduota tiesinė aproksimacija, pašalinus išskirtis, tačiau taškai yra gan plačiai išsibarstę apie nubrėžtą tiesę. Toks išsibarstymas gali būti susijęs su piranometro ar SE neteisingais matavimais, šešėliavimu arba kitų išorinių įtaka.



4.2 pav. Saulės priklausomybė nuo apšvietos, klaidų šalinimas ir tiesinė aproksimacija

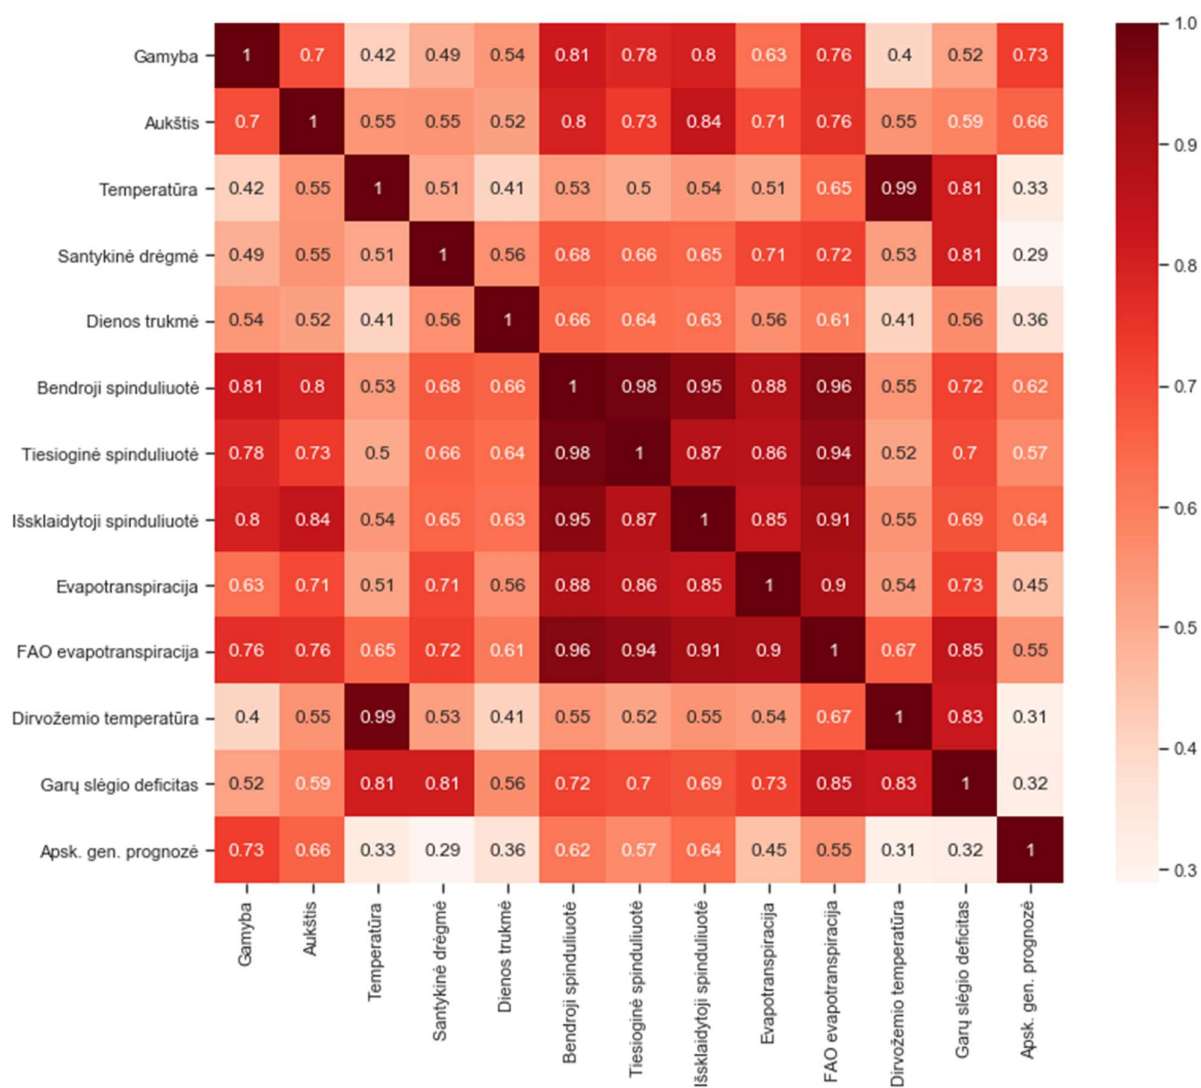
Kadangi apšvieta nepaaiškina visos SE gamybos taškų sklaidos, į modelį įtraukiami po vieną ir kiti nepriklausomi kintamieji. 4.3 pav. atvaizduoti gauti modelių determinacijos koeficientų priklausomybė nuo nepriklausomų kintamųjų kiekio. Čia 1 regresorius – apšvieta, o 5 regresoriai – apšvieta, saulės aukštis, azimutas, temperatūra ir santykinė drėgmė. Aiškiai matyti, kad saulės aukštis ir azimutas padeda paaiškinti dar apie 25% SE gamybos taškų sklaidos. Taip yra todėl, kad modelis sudaromas iš rudens ir žiemos duomenų, kai saulės zenitas žemas, o SE moduliai pastatyti nedideliu atstumu vienas nuo kito ir krenta šešėlis. Iš šio modelio sudarymo gauta labai svarbi išvada, kad negalima prognozuoti SE gamybos tiksliai vien iš meteorologinių matavimų. Likę 5% gali būti paaiškinti matavimų paklaidomis ir valandomis, kai SE dirbo tik su 1 inverteriu ar buvo visiškai išjungta.



4.3 pav. ASI – SE modelių determinacijos koeficientai

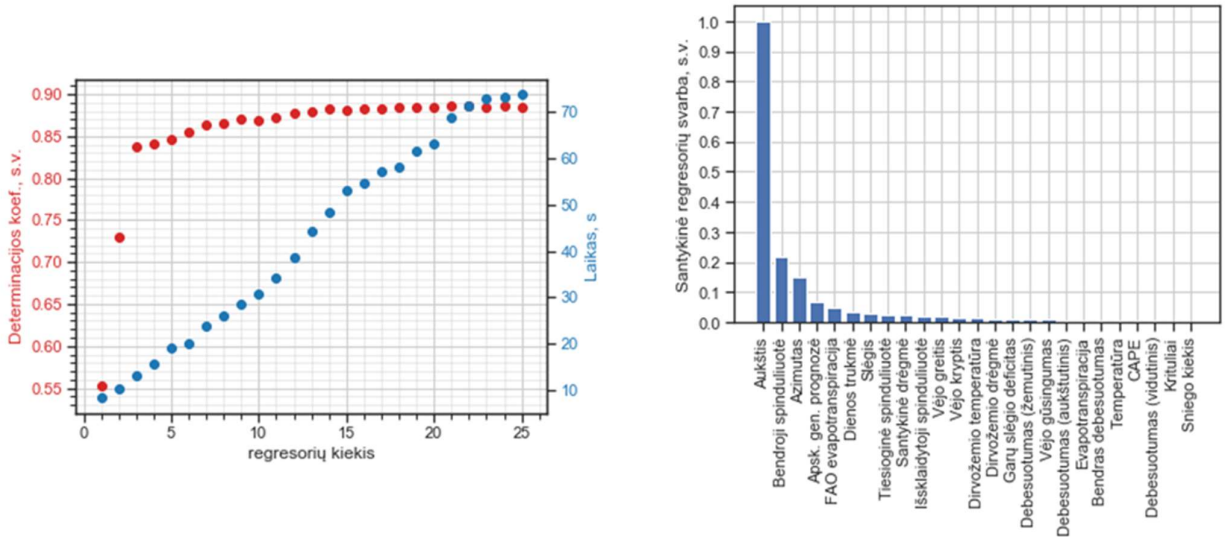
4.2. „Meteoblue“ – SE generacijos prognozės modelio sudarymo rezultatai

„Meteoblue“ – tai šveicarų ir amerikiečių meteorologinių duomenų faktines reikšmes bei kai kurių iš jų (įskaitant saulės spinduliuotę) savaitės horizonto valandines ir smulkesnio žingsnio prognozes bet kokiam geografiniam taške teikianti kompanija. Iš šios duomenų bazės buvo ištraukti visi prieinami duomenys ir sudarytas vienerių metų (nuo 2019 m. iki 2020 m. balandžio 18 d.) duomenų rinkinys. Į duomenų rinkinį įtrauktas ir apskaičiuotas saulės aukštis, azimutas bei empiriniu modeliu apskaičiuota SE gamyba. Kadangi nepriklausomų kintamųjų daug, 4.4 pav. pateikta koreliacinė matrica, tik tų kintamųjų, kurių koreliacija su SE gamyba $> 0,3$, o pilna koreliacinė lentelė pateikta 1 priede. Viena pagrindinių kintamųjų atrankos savybių yra ne tik stipri koreliacija su priklausomu kintamuoju, bet ir silpna koreliacija tarpusavyje. Iš 4.4 pav. matyti, kad kintamieji tarpusavyje taip pat koreliuoja, todėl svarbiausių kintamųjų atrankai panaudojamas atsitiktinių išlikimo miškų modelis, kuris skirtas įvertinti kiekvieno kintamojo santykinę svarbą.



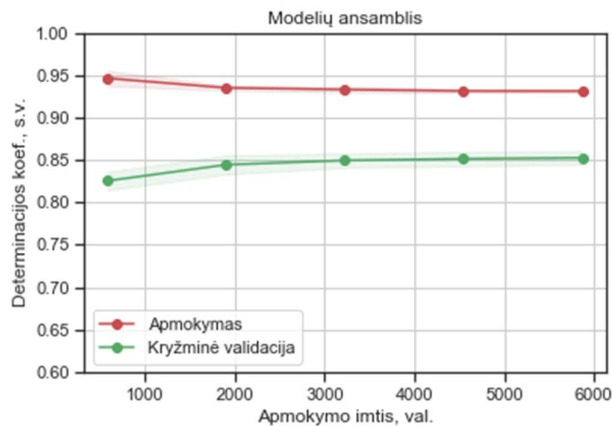
4.4 pav. „Meteoblue“ duomenų koreliacinė matrica

4.5 pav. kairėje pateiktas modelio determinacijos koeficiento bei apmokymo laiko priklausomybė nuo kintamųjų kiekio grafikas. Akivaizdu, kad pirmieji 3 nepriklausomi kintamieji turi didžiausią įtaką modelio tikslumui ir vien su jais galima pasiekti apie 84 % tikslumą. Taip pat matyti, kad paskutiniai 10 kintamieji nereikalingi, kadangi neduoda modeliui papildomo tikslumo. Kokie tai konkrečiai kintamieji, galima pamatyti 4.5 pav. dešinėje, kur atvaizduota kiekvieno nepriklausomo kintamojo santykinė svarba modelyje. Taigi, su 15 regresorių, galima ištrenuoti modelį, kurio tikslumas apie 89 %. Nors skaičiavimo trukmė sąlyginai nedidelė, tačiau MM modelių kūrimui atrenkami tik 3 pagrindiniai kintamieji – bendroji spinduliuotė, saulės aukštis ir azimutas, kadangi pastaruosius galima apskaičiuoti, o bendrosios spinduliuotės prognozės gali būti gaunamos.




4.5 pav. „Meteoblue“ – SE modelių svarbiausių nepriklausomų kintamųjų atrinkimas

4.6 pav. pateiktas geriausio modelio (DNT(4,10,10,1) ir atsitiktinių miškų ansamblio) apmokymo kreivė. Iš grafiko matyti, kad modelio tikslumas nusistovi apie 85 % ties 3000 apmokymo imties dydžiu. Taip pat matyti, kad nors modelis su apmokymo imtimi gali pasiekti ir apie 94 % determinacijos koeficientą, tačiau negali gerai apibendrinti ir išlaikyti tokį tikslumą su nematytais duomenimis iš kryžminės validacijos. Kitų modelių apmokymo kreivės pateiktos 2 priede.




4.6 pav. „Meteoblue“ – SE modelių ansamblio apmokymo kreivė

4.7 pav. pateikta stulpelinė diagrama, su geriausių skirtingų MM determinacijos koeficientais. Atsitiktinių miškų ir DNT modelių ansamblis neduoda žymaus geresnio rezultato, nei atskiras geriausias (DNT (4,10,10,1)) modelis dėl to, kad visi modeliai stipriai koreliuoja tarpusavyje, o iš pagrindinių kriterijų, norint kad modelių ansamblis duotų geresnį rezultatą nei individualūs modeliai – modeliai turi tarpusavyje silpnai koreliuoti. 4.8 pav. pateikta modelių rezultatų koreliacinė matrica.




4.7 pav. „Meteoblue“ – SE modelių determinacijos koeficientai



4.8 pav. „Meteoblue“ – SE modelių rezultatų koreliacinė matrica


4.3. Disbalanso kainos modelio sudarymo rezultatai

4.9 pav. pateikta disbalanso kainos priklausomybės nuo kiekio taškų sklaidos diagrama bei tiesinė aproksimacija. Nors tendencija aiški, kad už neigiamą disbalansą (kai generuojama mažiau nei prognozuota) kaina didesnė nei už perteklių, tačiau taškai yra plačiai išsibarstę apie tiesę, todėl analogiškai, kaip ir 4.2 dalyje, kuriami skirtingi MM modeliai, kad būtų pasiektas didesnis tikslumas nei tiesinės regresijos. Į modelių kūrimą įtraukiami 3 papildomi nepriklausomi kintamieji: savaitės diena, paros valanda bei „dienos prieš“ elektros energijos kaina.




4.9 pav. Disbalanso kainos priklausomybė nuo disbalanso kiekio tiesinė aproksimacija

4.10 pav. pateikta geriausio MM apmokymo kreivė. Šiuo atveju modelių ansamblis davė 2 % prastesnį rezultatą nei atskiras geriausias jį sudarantis modelis. Iš grafiko taip pat matyti, kad didėjant imčiams, kryžminės validacijos determinacijos koeficientas didėja, todėl, tikėtina, kad naudojant didesnę duomenų imtį, būtų galima gauti dar didesnę tikslumą. Modelis gana neblogai apibendrina. Kitų modelių apmokymo kreivės pateiktos 4 priede.




4.10 pav. Disbalanso kainos DNT(5,10,10,1) modelio apmokymo kreivė

4.11 pav. pateikta stulpelinė diagrama, su geriausių skirtingų MM determinacijos koeficientais. Kaip ir prieš tai kurtame SE generacijos prognozės modelyje, DNT su 2 paslėptais sluoksniais duoda geriausių rezultatą. Gautas geriausias modelis pritaikomas visų lyginamų modelių balansavimo kainoms įvertinti.




4.11 pav. Disbalanso kainos modelių determinacijos koeficientai

4.12 pav. pavaizduota pirmoji duomenų rinkinio savaitė, kuri iliustruoja disbalanso kainos modelio prognozes. Viršutiniame paveikslėlyje pateikta faktinis ir apskaičiuotas (prie faktinio pridėtas SE disbalansas) sistemos disbalanso kiekis, o apatiniame – faktinė ir apskaičiuota disbalanso kaina. Ypač atkreipia dėmesį 12 val., kai dėl prastos SE generacijos prognozės Baltijos sistemos disbalansas vietoje teigiamo pasikeitė į neigiamą ir modelis apskaičiavo, kad tą valandą disbalanso kaina būtų pakilusi daugiau nei dvigubai.



4.12 pav. Vienos savaitės faktiniai ir apskaičiuoti disbalanso kiekiai ir kainos


4.13 pav. kairėje pateikta stulpelinė diagrama, atvaizduojanti metines pajamas, gaunamas pritaikius skirtingus SE generuojamos energijos prognozavimo modelius, įvertinant ir neįvertinant naujas disbalanso kainas dėl SE netikslų prognozių. Nors, įvertinus pasikeitusią disbalanso kainą, pajamos, gaunamos taikant įvairius metodus ir sumažėja, tačiau ne visais atvejais vienodai – pajamos, gaunamos iš tikslų modelių (atsitiktiniai miškai ar modelių ansamblis), pasikeičia nežymiai. Iš pirmo žvilgsnio atrodo paradoksalu, kad didžiausias pajamas atneša trečias pagal netikslumą – AVM modelis, kurio tikslumas atsilieka daugiau nei 6 % nuo modelių ansamblio. Be to, jo pajamos nežymiai viršija net teorinį variantą, kai visa SE gamyba suprognozuojama tiksliai ir parduodama „dienos prieš“ rinkoje (juoda tiesė). Dešinėje 4.13 pav. pusėje pateiktos sistemingosios modelių paklaidos, iš kurių matyti, kad AVM modelis yra linkęs prognozuoti mažiau negu faktinė SE generacija. Būna, kad perteklinio disbalanso kainos viršija „dienos prieš“ kainas, ypač dienos metu, todėl tokiomis valandomis didesnes pajamas galima gauti iš balansavimo rinkos.



4.13 pav. Metinės HEES pajamos ir sistemingosios „Meteoblue“ – SE modelių paklaidos

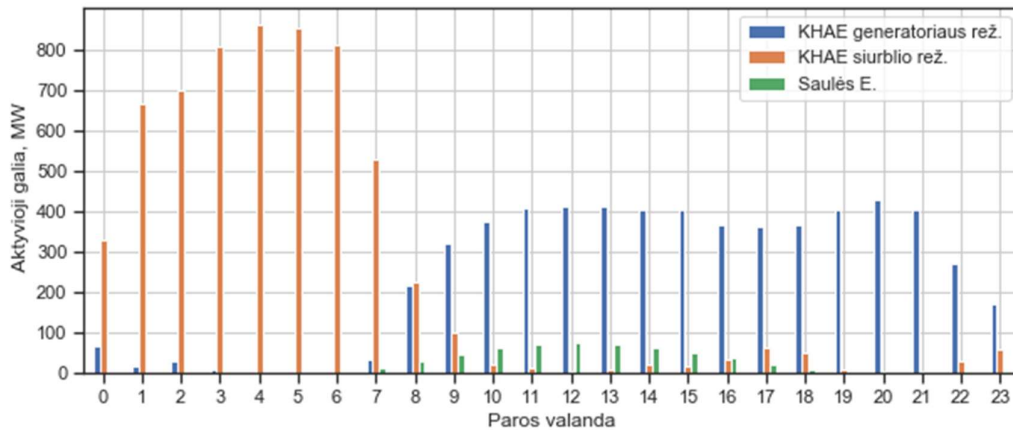
4.4. Hibridinės elektros energetikos sistemos optimizavimo rezultatai

4.14 pav. pateiktas KHAE vandens lygio ir „dienos prieš“ elektros energijos kainos kitimas per pirmąją optimizuojamo periodo savaitę. Iš grafiko matyti, kad kai kaina didesnė – energijos kaupiklis išsikrauna, o kai mažesnė – užsikrauna. Kitų savaitžių grafikai pateikti 3 priede.



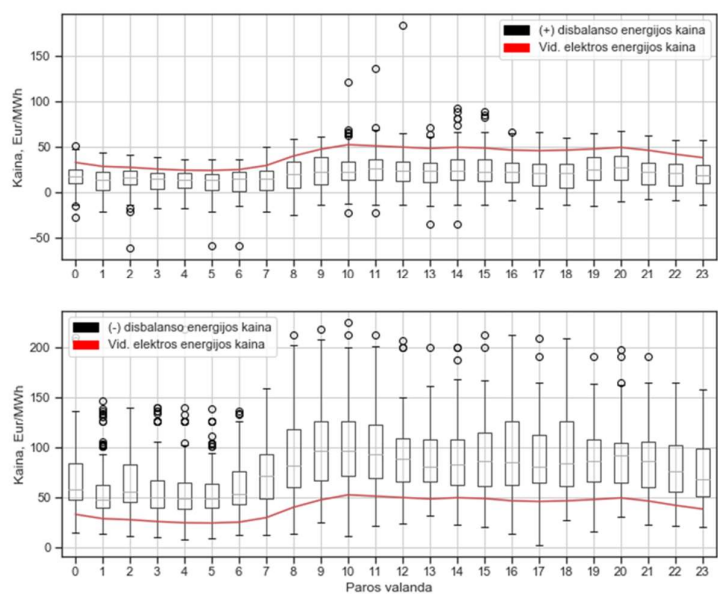
4.14 pav. KHAE vienos savaitės grafiko optimizacijos rezultatai

4.15 pav. pateiktos HEES elementų vidutinės aktyviosios galios kiekvieną paros valandą, jei SE ir KHAE dirbtų atskirai. Čia panaudota faktinė SE generacija ir optimizacinio modelio sumodeliuotas KHAE darbo grafikas. Šis grafikas labai informatyvus, nes iš kiekvieno elemento darbo pobūdžio galima ieškoti strategijų kaip gauti sinergiją tarp šių dviejų labai skirtingų energijos šaltinių. Kadangi šiuo metu rinkoje situacija tokia, kad didžiausios kainos dienos metu, kai saulė šviečia, tai jos kaupti nėra prasmės, todėl kyla klausimas, ar sinergija pasitvirtintų, jei KHAE subalansuotų SE disbalansą, atsirandantį dėl prognozavimo modelių paklaidų.




4.15 pav. Atskirų HEES elementų metų vidutinės aktyviosios galios kiekvieną paros valandą

4.16 pav. pateiktos stačiakampės (angl. *boxplot*) disbalanso kainos diagramos. Viršutinis grafikas atvaizduoja kainą, kai disbalansas yra teigiamas (perteklius), o apatinis – kai neigiamas. Akivaizdu, kad sistemoje esant neigiamam disbalansui kainos žymiai aukštesnės už elektros energijos kainą, kai tuo tarpu, kai teigiamas disbalansas – kainos panašaus dydžio kaip ir „dienos prieš“ elektros energijos kainos. Tai reiškia, kad galima tikėtis sinergijos iš šių energijos šaltinių balansuojant tas valandas, kai SE generuoja mažiau, nei yra įsipareigojusi.




4.16 pav. Disbalanso ir vidutinės „dienos prieš“ kainos

Toliau atliekamas HEES optimizavimas, keičiant KHAE generatoriaus maksimalią galią, prekiaujamą „dienos prieš“ rinkoje nuo 160 iki 225 MW. Kuo labiau ribojama KHAE galia prekyboje „dienos prieš“ rinkoje, tuo didesnė marža lieka balansuojant SE „aukštyn“, tačiau prarandamos pajamos iš „dienos prieš“ rinkos. Iš 4.17 pav. rezultatų matyti, kad AVM modelis ženkliai geresnis už kitus ir pasiekia maksimumą, kai KHAE apribojamas prekybai „dienos rinkai“ iki 216 MW. Natūralu, tikslesni modeliai (atsitiktiniai miškai, modelių ansamblis) pasiekia maksimumą, kai KHAE apribojamas tik per 2 MW.



4.17 pav. HEES optimizavimo pagal skirtingų DI modelių prognozes rezultatai

4.18 pav. pateiktas HEES maksimalios pajamos, naudojant skirtingus SE generuojamos energijos prognozavimo modelius (4.17 pav. kiekvienos kreivės maksimumas) bei pajamos, kurios būtų gautos, jei SE generuojamos energijos prognozė neturėtų paklaidų (pirmas stulpelis). Visgi, dėl balansavimo „aukštyn“ poreikio, AVM modelis, kurio determinacijos koeficientas net 6 % mažesnis už geriausių modelių, atneša didžiausias pajamas ir netgi aplenkia apie pusę milijono eurų per metus kitus geriausius modelius.



4.18 pav. Skirtingų HEES valdymo modelių palyginimas

Išvados

1. Pastaraisiais metais pastebimas eksponentinis sėkmingo dirbtinio intelekto metodų pritaikymo elektros energetikos sistemose augimo greitis, ypač prognozuojant atsinaujinančius energijos išteklius vartojančių elektrinių generaciją.
2. Atlikus duomenų analizę, nustatyta, kad saulės pakilimo aukštis, azimutas ir bendroji apšvieta yra svarbiausi išoriniai kintamieji saulės elektrinės generuojamai energijai prognozuoti, nes jų santykinė svarba modelyje yra didesnė nei 0,1. Apskaičiuota apšvieta, evapotranspiracija, dienos trukmė, slėgis ir kt. meteorologiniai parametrai taip pat didina modelių tikslumą, tačiau jų santykinė svarba modelyje nesiekia 0,1.
3. Šiame darbe buvo panaudoti tiesinės regresijos, netiesinės regresijos, dirbtinių neuroninių tinklų, atraminių vektorių mašinių, atsitiktinių miškų ir modelių ansamblių dirbtinio intelekto algoritmai trijuose skirtinguose uždaviniuose: apskaičiuojant saulės elektrinės faktinę generaciją (ASI – SE generacijos modelis), prognozuojant saulės elektrinės generuojamą energiją („Meteoblue“ – SE generacijos prognozės modelis) ir apskaičiuojant disbalanso kainą.
4. Hibridinei sistemai pritaikius kiekvieną dirbtinio intelekto ir empirinį modelį saulės elektrinės generuojamai energijai prognozuoti, buvo sukurtos optimalios valdymo strategijos, kurios parodė, kad ši hibridinė elektros energetikos sistema turi sinergiją taupant patiriamus kaštus už balansavimą „aukštyn“ dienos metu.
5. Palyginus „Meteoblue“ – SE dirbtinio intelekto modelių rezultatus su empiriniais skaičiavimais, gauta, kad geriausio dirbtinio intelekto metodo prognozavimo sistemingoji paklaida lygi $-0,006\%$, o empirinio modelio – $1,146\%$. Valdymo strategija, sukurta pagal empirinio modelio prognozavimo rezultatus, atneša 57,88 mln. Eur. pajamas per metus, o pagal geriausio dirbtinio intelekto modelio – 59,11 mln. Eur. per metus, kas yra 0,46 mln. Eur. per metus daugiau nei pagal teorinio modelio, neturinčio prognozavimo nuokrypio nuo faktinės generacijos.

Literatūros sąrašas

1. Ajanovic, A., Hiesl, A. ir Reinhard, H. (2020). On the role of storage for electricity in smart energy systems. *Energy*.
2. Liu J. et al. (2018). Artificial Intelligence in the 21st Century.
3. Patterson, D.W. (1998). Introduction to Artificial intelligence & expert system, Naujasis Delis: prentice Hall.
4. Chowdhury, M. ir Sadek, A. W. (2012). Advantages and Limitations of Artificial Intelligence. The National Academies Press.
5. Blazquez, J., Fuentes – Bracamontes, R., Bollino, C. A. ir Nezamuddin, N. (). The renewable energy policy Paradox. *Renewable and Sustainable Energy Reviews*,
6. Martinez – Rico, J. et al. (2020). Forecast Error Sensitivity Analysis for Bidding in Electricity Markets with a Hybrid Renewable Plant Using a Battery Energy Storage System. *Sustainability* , 12 (9).
7. Kuhl, N., Goutier, M., Hirt, R. ir Satzger, G. (2020). Machine Learning in Artificial Intelligence: Towards a Common Understanding.
8. Barrett, D. H. ir Haruna, A. (2020). Artificial intelligence and machine learning for targeted energy storage solutions. *Current opinion in Electrochemistry*, 160-166.
9. Shi, S. et al. (2016). Multi-scale computation methods: Their applications in lithium-ion battery research and development. *Chinese Physical Society and IOP Publishing Ltd*, 1 (25).
10. Mosavi, A., Salimi, M., Faizollahzadeh Ardabili, S., Rabczuk, T., Shamshirband, S., Varkonyi-Koczy, A.R. (2019). State of the Art of Machine Learning Models in Energy Systems, a Systematic Review. *Energies*, 12 (7), 1301.
11. Paucar, V. L. ir Rider, M. J. (2002). Artificial neural networks for solving the power flow problem in electric power systems. *Electric power systems research*, 2 (62), 139-144.
12. Abbas, F. et al. (2018). Optimizing Generation Capacities Incorporating Renewable Energy with Storage Systems Using Genetic Algorithms. *Electronics*.
13. Anwar, M.B., Moursi, M.S. ir Xiao, W. (2017). Novel Power Smoothing and Generation Scheduling Strategies for a Hybrid Wind and Marine Current Turbine System. *IEEE Transactions on Power Systems*, 32, 1315-1326.
14. Chatziagorakis, P., Ziogou, C., Elmasides, C. et al. (2016). Enhancement of hybrid renewable energy systems control with neural networks applied to weather forecasting: the case of Olvio. *Neural Comput & Applic* , 27, 1093–1118.
15. Faizollahzadeh Ardabili, S., Mahmoudi, A. ir Mesri Gundoshmian, T. (2016). Modeling and simulation controlling system of HVAC using fuzzy and predictive (radial basis function, RBF) controllers. *J. Build. Eng.*, 6, 301–308.
16. Karballaezadeh, N., Mohammadzadeh, S.D., Shamshirband, S., Hajikhodaverdikhan, P., Mosavi, A. ir Chau, K.W. (2019). Prediction of remaining service life of pavement using an optimized support vector machine. *Engineering Applications of Computational Fluid Mechanics*, 13, 188–198.
17. Faizollahzadeh Ardabili, S., Najafi, B., Shamshirband, S., Minaei Bidgoli, B., Deo, R.C. Chau, K.-w. (2018). Computational intelligence approach for modeling hydrogen production: A review. *Engineering Applications of Computational Fluid Mechanics*, 12, 438–458.
18. Chahkoutahi, F. ir Khashei, M. (2017). A seasonal direct optimal hybrid model of computational intelligence and soft computing techniques for electricity load forecasting. *Energy* , 140, 988–1004.
19. Kazem, H.A. ir Yousif, J.H. (2017). Comparison of prediction methods of photovoltaic power system production using a measured dataset. *Energy Conversion and Management*, 148, 1070–1081.

20. Loutfi, H., Bernatchou, A. ir Tadili, R. (2017). Generation of Horizontal Hourly Global Solar Radiation From Exogenous Variables Using an Artificial Neural Network in Fes (Morocco). *International Journal of Renewable Energy Research – IJRRER*, 7 (3), 1097–1107.
21. Shimray, B.A., Singh, K., Khelchandra, T. ir Mehta, R. (2017). Ranking of Sites for Installation of Hydropower Plant Using MLP Neural Network Trained with GA: A MADM Approach. *Comput. Intell. Neurosci*,
22. Ahmad, A., Anderson, T. ir Lie, T. (2015). Hourly global solar irradiation forecasting for New Zealand. *Solar Energy*, 122, 1398–1408.
23. Li, Q., Wu, Z. ir Xia, X. (2018). Estimate and characterize PV power at demand-side hybrid system. *Applied Energy*, 218, 66–77.
24. Premalatha, N. ir Valan Arasu, A. (2016). Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms. *J. Appl. Res. Technol*, 14, 206–214.
25. Bagnasco, A., Fresi, F., Saviozzi, M., Silvestro, F. ir Vinci, A. (2015). Electrical consumption forecasting in hospital facilities: An application case. *Energy Buildings*, 103, 261–270.
26. Gholami, R. ir Fakhari, N. (2017). Chapter 27 – Support Vector Machine: Principles, Parameters, and Applications. *Handbook of Neural Computation*, 515-535.
27. Ma, J., Jiang, H., Huang, K., Bi, Z. Ir Man, K. L. (2017). Novel Field-Support Vector Regression-Based Soft Sensor for Accurate Estimation of Solar Irradiance. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 64 (12), 3183-3191.
28. Ozdemir, S. (2016). Harmonic Estimation Based Support Vector Machine for Typical Power Systems. *Neural Network World*, 26, 233-252.
29. Arikan, C. ir Ozdemir, M. (2013). Classification of power quality disturbances at power system frequency and out of power system frequency using support vector machines. *Prz. Elektrotech*, 89, 284–291.
30. Alexandridis, A. K. ir Zapranis, A. D. (2013). Wavelet neural networks: A practical guide. *Neural Networks*, 42, 1-27.
31. He, Q., Wang, J. ir Lu, H. (2018). A hybrid system for short-term wind speed forecasting. *Applied Energy*, 226, 756–771.
32. Sarshar, J., Moosapour, S. S. ir Joorabian, M. (2017). Multi-objective energy management of a micro-grid considering uncertainty in wind power forecasting. *Energy*, 139, 680–693.
33. Doucoure, B., Agbossou, K. ir Cardenas, A. (2016). Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data. *Renewable Energy*, 92, 202–211.
34. Wei-di, C. ir Hans, C. (2008). Effects of stacking fault energy and temperature on the electroplastic effect in FCC metals. Elsevier B. V.
35. Fang, Y. ir Chow, T.W.S. (2006). Wavelets based neural network for function approximation. 3rd International Symposium on Neural Networks. Chengdu
36. Ardabili, S. F., Najafi, B., Ghaebi, H., Shamshirband, S. ir Mostafaeipour, A. (2017). A novel enhanced exergy method in analyzing HVAC system using soft computing approaches: A case study on mushroom growing hall. *Journal of Building Engineering*, 13, 309-318.
37. Hadi Abdulwahid, A. ir Wang, S. (2018). A Novel Method of Protection to Prevent Reverse Power Flow Based on Neuro-Fuzzy Networks for Smart Grid. *Sustainability*, 10(4).
38. Kampouropoulos, K. et al. (2018). Multiobjective Optimization of Multi-Carrier Energy System Using a Combination of ANFIS and Genetic Algorithms. *IEEE Transactions on Smart Grid*, 3 (9).
39. Bassam, A., May Tzuc, O., Escalante Soberanis, M., Ricalde, L. ir Cruz, B. (2017). Temperature estimation for photovoltaic array using an adaptive neuro fuzzy inference system. *Sustainability*, 9(8).
40. Mohammadi, K., Shamshirband, S., Kamsin, A., Lai, P. ir Mansor, Z. (2016). Identifying the most significant input parameters for predicting global solar radiation using an ANFIS selection procedure. *Renew. Sustain. Energy Rev.*, 63, 423–434.


41. Kamali, S. ir Amraee, T. (2017). Blackout prediction in interconnected electric energy systems considering generation re-dispatch and energy curtailment. *Applied Energy*, 187, 50–61.
42. Costa, D.C., Nunes, M.V., Vieira, J.P. ir Bezerra, U.H. (2016). Decision tree-based security dispatch application in integrated electric power and natural-gas networks. *Electr. Power Syst. Res.*, 141, 442–449.
43. Moutis, P., Skarvelis-Kazakos, S. ir Brucoli, M. (2016). Decision tree aided planning and energy balancing of planned community microgrids. *Applied Energy*, 161, 197–205.
44. Ottesen, S.Ø.; Tomasgard, A.; Fleten, S.-E. (2016). Prosumer bidding and scheduling in electricity markets. *Energy*, 94, 828–843.
45. Chemali, E., Kollmeyer, P.J., Preindl, M. ir Emadi, A. (2018). State-of-charge estimation of Li-ion batteries using deep neural networks: A machine learning approach. *J. Power Sources*, 400, 242–255.
46. Coelho, I.M., Coelho, V.N., Luz, E.J.d.S., Ochi, L.S., Guimarães, F.G. ir Rios, E. (2017). A GPU deep learning metaheuristic based model for time series forecasting. *Applied Energy*, 201, 412–418.
47. Kim, J., Le, T.-T.-H. ir Kim, H. (2017). Nonintrusive load monitoring based on advanced deep learning and novel signature. *Comput. Intell. Neurosci.*
48. Wang, H., Yi, H.; Peng, J., Wang, G., Liu, Y., Jiang, H. ir Liu, W. (2017). Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network. *Energy Convers. Manag.*, 153, 409–422.
49. Zhang, C., He, Y., Du, B., Yuan, L., Li, B. ir Jiang, S. (2020). Transformer fault diagnosis method using IoT based monitoring system and ensemble machine learning. *Future Generation Computer Systems*, 108, 533-545.
50. Lee, J., Wang, Wu., Harrou, F. Ir Sun, Y. (2020). Reliable solar irradiance prediction using ensemble learning-based models: A comparative study. *Energy Conversion and Management*, 208.
51. Fu, G. (2018). Deep belief network based ensemble approach for cooling load forecasting of air-conditioning system. *Energy*, 148, 269-282.
52. Burger, E. M. ir Moura, S. J. (2015). Gated ensemble learning method for demand-side electricity load forecasting. *Energy and Buildings*, 109, 23-34.
53. Cazzaniga, R., Rosa-Clot, M., Rosa-Clot, P. ir Tina, G. M. (2019). Integration of PV floating with hydroelectric power plants. *Heliyon*, 5 (6).
54. Farfan, J. ir Breyer, C. (2018). Combining Floating Solar Photovoltaic Power Plants and Hydropower Reservoirs: A Virtual Battery of Great Global Potential. *Energy Procedia*, 155, 403-411.
55. Liu, B. et al. (2020). Optimal power peak shaving using hydropower to complement wind and solar power uncertainty. *Energy Conversion and Management*, 209.
56. Stiubiener, U., et al. (2020). PV power generation on hydro dam's reservoirs in Brazil: A way to improve operational flexibility. *Renewable Energy*, 150, 765-776.
57. Fang, W., Huang, Q., Huang, S., Yang, J., Meng, E. ir Li, Y. (2017). Optimal sizing of utility-scale photovoltaic power generation complementarily operating with hydropower: A case study of the world's largest hydro-photovoltaic plant. *Energy Conversion and Management*, 136, 164-172.
58. V. Vapnik, *The Nature of Statistical Learning*, Springer, New York, 1995
59. Shawe-Taylor, J., Cristianini, N. (2004). *Kernel Methods for Pattern Analysis*, Cambridge University Press, Cambridge, UK.
60. Verikas, A., Gelžinis, A. ir Bačauskienė M. (2011). Mining data with random forests: A survey and results of new tests. *Pattern Recognition*, 44 (2), 330–349.

Informacijos šaltinių sąrašas

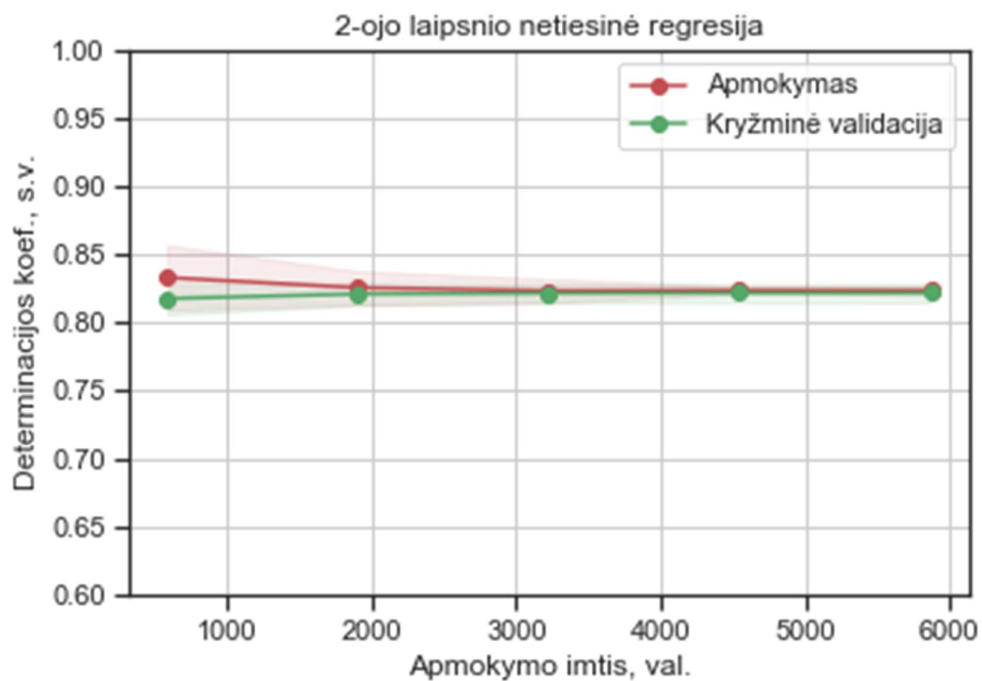
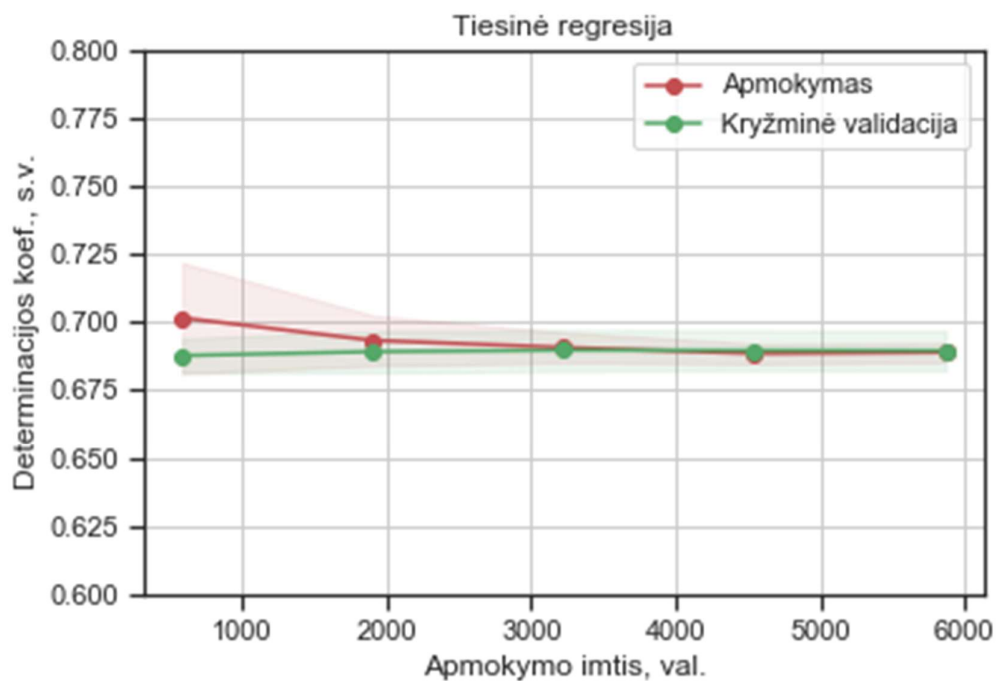
1. <https://meteonorm.com/en/>
2. <https://content.meteoblue.com/nl/access-options/meteoblue-weather-api>
3. <https://www.solaredge.com/>


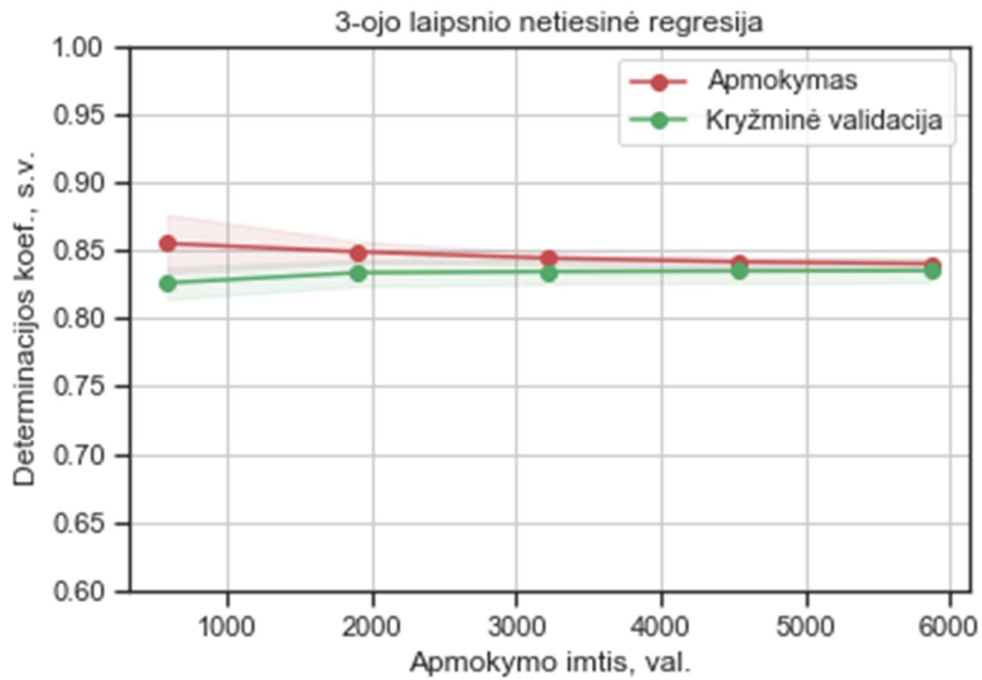
Priedai

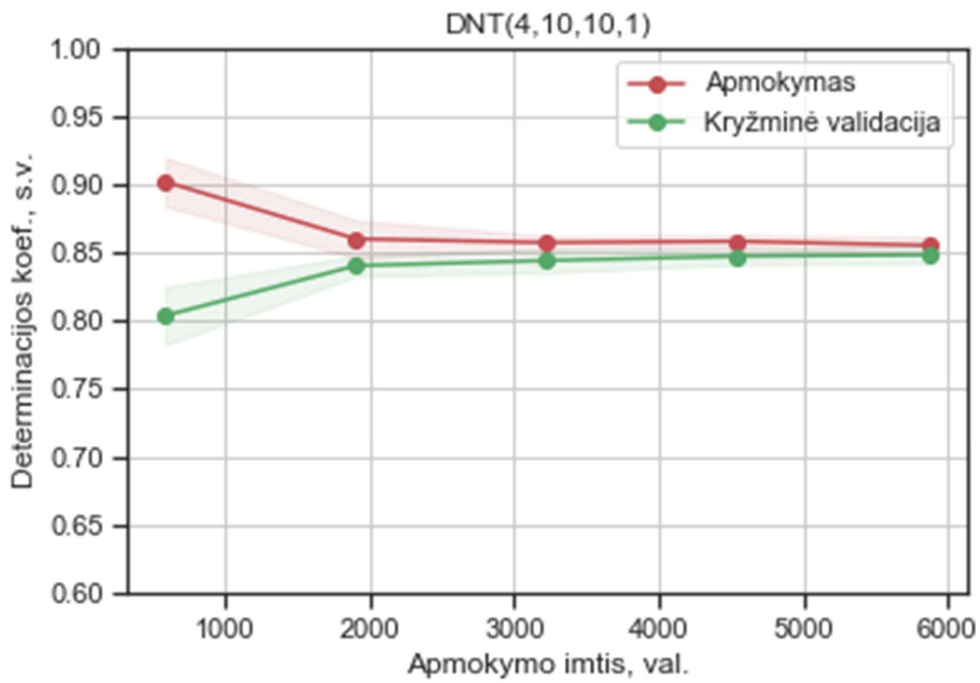

1 priedas. „Meteoblue“ duomenų koreliacinė matrica

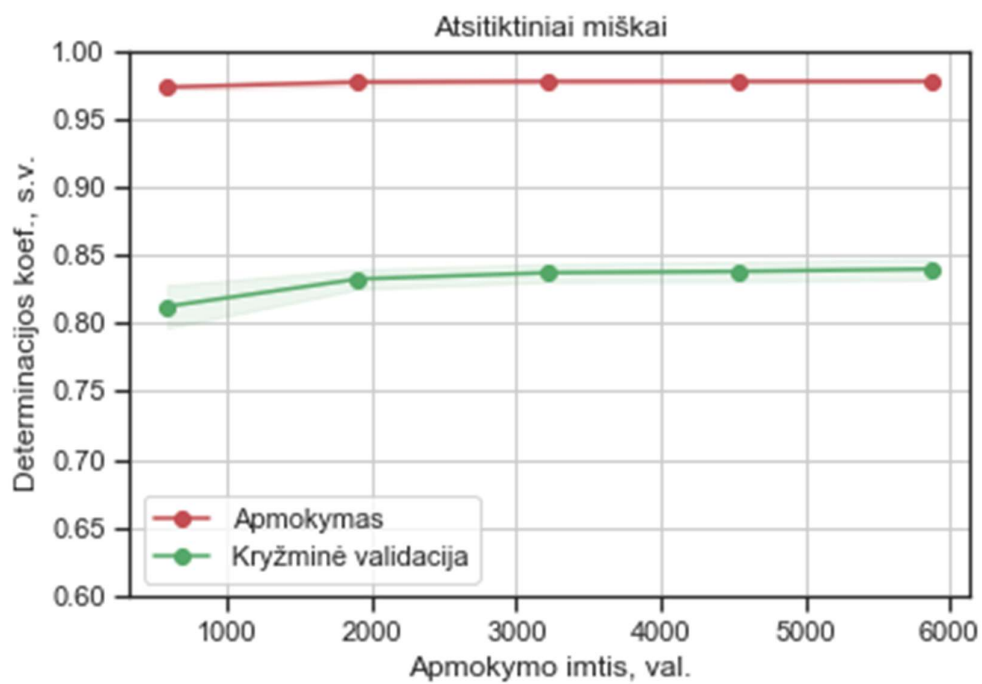



2 priedas. Saulės elektrinės generuojamos energijos modelių apmokymo kreivės



















3 priedas. KHAE savaitės horizonto optimizacijos rezultatai



























































































4 priedas. Disbalanso kainos modelių mokymosi kreivės

