



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Save gydančio tinklo sistemos (FLIR) įtaka SAIDI SAIFI rodikliams skirstomajame tinkle

Magistro baigiamasis projektas

Ruslanas Kryžanauskas

Projekto autorius

Doc. Almantas Bandza

Vadovas

Dokt. Jonas Vaičys

Mokslinis konsultantas

Kaunas, 2023



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Save gydančio tinklo sistemos (FLIR) įtaka SAIDI SAIFI rodikliams skirstomajame tinkle

Magistro baigiamasis projektas

Elektros energetikos inžinerija (6211EX010)

Ruslanas Kryžanauskas

Projekto autorius

Doc. Almantas Bandza

Vadovas

Dokt. Jonas Vaičys

Mokslinis konsultantas

Doc. Gytis Svinkūnas

Recenzentas

Kaunas, 2023



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Ruslanas Kryžanauskas

Save gydančio tinklo sistemos (FLIR) įtaka SAIDI SAIFI rodikliams skirstomajame tinkle

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Ruslanas Kryžanauskas

Patvirtinta elektroniniu būdu

Kryžanauskas, Ruslanas. Save gydančio tinklo sistemos (FLIR) įtaka SAIDI SAIFI rodikliams skirstomajame tinkle. Magistro baigiamasis projektas / vadovas doc. dr. Almantas Bandza, konsultantas dokt. Jonas Vaičys; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

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

Reikšminiai žodžiai: dirbtinis intelektas, save gydantis tinklas, SAIDI, SAIFI, skirstomasis tinklas.

Kaunas, 2023. 50 p.

Santrauka

Šiame darbe yra nagrinėjamas save gydantis tinklas, jo veikimo principai. Nustatomi SAIDI SAIFI rodikliai linijose prieš įdiegiant save gydantį tinklą ir po jo įdiegimo.

Pagrindinių kintamųjų inicijuojančių save gydančio tinklo veikimą atrikimui atlikta 10 metų laikotarpio istorinių oro sąlygų duomenų analizė, 1,5 metų laikotarpio skirstomojo tinklo gedimų analizė, 1,5 metų laikotarpio save gydančio tinklo veikimų analizė. SAIDI SAIFI rodiklių prognozei pritaikyti tiesinės regresijos, paprastojo neuroninio tinklo ir sudėtingojo neuroninio tinklo dirbtinio intelekto metodai. Geriausiai prognozuojamajam modeliui atliktas hiperparametrų optimizavimas.

Atlikus tyrimą nustatyta, kad save gydančio tinklo diegimas skirstomajame tinkle turi teigiamą poveikį SAIDI rodikliams, nes žymiai sutrumpėja atjungtų vartotojų kiekis bei laikas linijose, kuriose jis yra įdiegtas.

Kryžanauskas, Ruslanas. Impact of Self-Healing Network System (FLIR) over SAIDI SAIFI Indicators in Distribution Network. Master's Final Degree Project / supervisor assoc. prof. dr Almantas Bandza, consultant lect. Jonas Vaičys; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

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

Keywords: self healing: artificial intelligence, self healing network, SAIDI SAIFI, distribution network.

Kaunas, 2023. 54 p.

Summary

This project analyses a self-healing network, its operating principles. SAIDI and SAIFI indices are determined on the lines before and after the implementation of the self-healing network.

An analysis of historical weather data over a 10-year period, analysis of distribution network failures over a 1.5-year period, and analysis of the operations of the self-healing network over a 1.5-year period that trigger the main variables for recovery were performed. Linear regression, simple neural network, and complex neural network artificial intelligence methods were used to predict the SAIDI and SAIFI indices. Hyperparameter optimization was performed for the best predictive model.

The research revealed that the installation of a self-healing network in the distribution grid positively impacts SAIDI indices, as it significantly reduces the number and duration of customer outages on the lines where it is installed.

Turinys

Santrumpų ir terminų sąrašas	10
Įvadas.....	12
1. Apžvalginė dalis.....	13
1.1. SCADA ir ADMS.....	13
1.2. Save gydantis tinklas	15
1.2.1. Veikimo algoritmas	15
1.2.2. Scenarijai	18
1.3. SAIDI ir SAIFI rodikliai	20
2. Literatūros analizė.....	21
2.1. FLISR+DER.....	21
2.2. FLISR įtaka SAIDI CAIFI, Iranas.....	21
2.3. FLISR įtaka SAIDI ir AENSI, Egiptas.....	22
2.4. FLISR įtaka SAIDI ir SAIFI, Kanada	23
2.5. Gedimų nustatymas skirstomajame tinkle esant remiantis grafų teorija ir giliuoju mokymui, Kinija	24
2.6. Apibendrinimas	26
2.7. Aktualumas Lietuvoje	26
3. Problemos formulavimas	28
4. Metodika.....	29
4.1. Dirbtinio intelekto modeliai skirstomojo tinklo rodikliams prognozuoti.....	29
4.2. Tiesinės regresijos modelis.....	29
4.3. Paprastojo neuroninio tinklo modelis (MLP)	31
4.4. Sudėtingojo neuroninio tinklo modelis (DNN)	31
4.5. Modelių hiperparametrai	32
4.6. Modelių vertinimas.....	33
4.7. Modelių apmokymo strategija.....	34
4.8. Duomenų analizė	36
4.8.1. Duomenų paruošimas, restruktūrizavimas	36
4.8.2. Skirstomojo tinklo gedimų ir FLIR suveikimų SAIDI SAIFI rodiklių analizė.....	36
4.8.3. Orų istorinių duomenų analizė	37
4.8.4. Hierarchinis klasterizavimas	41
4.8.5. Duomenų rinkinio sudarymas.....	42
4.8.6. Kintamųjų atranka	43
5. Rezultatai.....	46
5.1. Atjungtų vartotojų skaičiaus prognozavimo modelių rezultatai.....	46
5.2. FLIR veikimo laiko prognozavimo modelių rezultatai	47
5.3. Prijungtų vartotojų prognozavimo modelių rezultatai.....	48
5.4. Modelių optimizavimas	49
5.4.1. Modelių su kryžminio patikrinimo 10 foldų hiperparametru rezultatai	50
5.5. Modelių optimizavimas pagal likusius hiperparametrus	50
5.6. Rodiklių prognozė	51

6. SGT įtakos SAIDI SAIFI rodikliams vertinimas	52
Išvados	53
Literatūros sąrašas	54
Informacijos šaltinių sąrašas	56
Priedai.....	57
1 priedas. Duomenų kintamųjų suvestinė.....	57
2 priedas. Atjungtų vartotojų skaičiaus prognozavimo modelių rezultatų grafikai.....	59
3 priedas. FLIR veikimo trukmės prognozavimo modelių rezultatų grafikai	60
4 priedas. Prijungtų vartotojų skaičiaus prognozavimo modelių rezultatų grafikai	61
5 priedas. Atjungtų vartotojų skaičiaus prognozavimo modelių rezultatų grafikai (10 foldų).....	62
6 priedas. FLIR veikimo laiko prognozavimo modelių rezultatų grafikai (10 foldų)	64
7 priedas. Prijungtų vartotojų prognozavimo modelių rezultatų grafikai (10 foldų).....	66
8 priedas Optimizuotų modelių testavimo grafikai ir diagramos (atjungtų vartotojų skaičius)	68
9 priedas Optimizuotų modelių testavimo grafikai ir diagramos (FLIR suveikimo laikas).....	69
10 pr. Optimizuotų modelių testavimo grafikai ir diagramos (FLIR prijungtų vartotojų skaičius) ..	70

1 lentelė	Skirstomojo tinklo patikimumo rodikliai	22
2 lentelė	Modelio testavimo rezultatai	25
3 lentelė	Modelių testavimo rezultatai	46
4 lentelė	Modelių testavimo rezultatai	47
5 lentelė	Modelių testavimo rezultatai	48
6 lentelė	Modelių testavimo rezultatai (kryžminis patikrinimas su 10 foldų)	50
7 lentelė	Geriausiai hiperparametrai	51
8 lentelė	Modelių rezultatai.....	51
9 lentelė	Proгноzių ir faktinių reikšmių palyginimas	51

1 pav. SCADA sistema	13
2 pav. ADMS sistema [1].....	14
3 pav. Save gydančio tinklo veikimo ciklas [2]	15
4 pav. Save gydančio tinklo veikimo algoritmas [3].....	16
5 pav. Save gydančio tinklo (FLIR) veikimo algoritmas	17
6 pav. Gedimo scenarijus 01	18
7 pav. Schema po save gydančio tinklo programos veikimo	18
8 pav. Gedimo scenarijus 02	19
9 pav. Schema po save gydančio tinklo veikimo	19
10 pav. SAIDI SAIFI palyginimas 2020 ir 2021 metų [5].....	20
11 pav. Simuliacija FLISR+DER integracija. spalvos žymi skirtingų pastočių žymėjimą. a) pažymėta gedimo vieta; b) dėl gedimo izoliuotas ruožas (pilka) c) minimizuotas izoliuotas ruožas ir prijungtas DER , išvestas dalis vartotojų į salos režimą [6]	21
12 pav. Simuliaciją rezultatai pagal EE nutraukimo trukmę. [7].....	22
13 pav. Testuojama skirstomojo tinklo schema. [8]	22
14 pav. Rezultatai po Monte Carlo simuliacijos [8]	23
15 pav. Mini skirstomojo tinklo modelis [9].....	23
16 pav. Schematinė diagrama skirstomojo tinklo su 2VG technologija [23]	24
17 pav. Tinklo dalis atvaizduota pagal grafų teoriją	24
18 pav. Modelio struktūra	25
19 pav. Automatizacijos palyginimas, sudaryta pagal šaltinius [10], [12]	26
20 pav. Duomenų rinkinio sudarymo schema.....	29
21 pav. Kryžminio patikrinimo schema.....	35
22 pav. FLIR suveikimų ir likusių gedimų palyginamoji diagrama	37
23 pav. Metinių kritulių kiekio pagal metus diagrama	38
24 pav. Vidutinio vėjo ir gūsių greičio diagrama pagal metus	39
25 pav. Vidutinė metinė temperatūra pagal metus.....	39
26 pav. Smuiko grafikas temperatūros duomenų simetriškumui nustatyti	40
27 pav. Smuiko grafikas temperatūros duomenų simetriškumui nustatyti	40
28 pav. Orų istorinių duomenų klasterizavimas.....	41
29 pav. Duomenų rinkinio sudarymo schema.....	43
30 pav. Duomenų rinkinio koreliacijos matrica.....	44
31 pav. Porinių diagramų rinkinys	45
32 pav. Tikros ir prognozuojamos reikšmės diagrama	46
33 pav. Tikros ir prognozuojamos reikšmės diagrama	47
34 pav. Tikros ir prognozuojamos reikšmės diagrama	48

Santrumpų ir terminų sąrašas

Santrumpos:

SGT – save gydantis tinklas

DI – dirbtinis intelektas

FLIR (angl. *Fault location isolation restoraton*) – save gydančio tinklo sistemos versija.

FLISR (angl. *Fault location isolation system restoration*) - save gydančio tinklo sistemos versija.

DER (angl. *distributed energy resources*) - mažos galios generatoriai, kurie naudojami lokacijoje yra ten elektros vartotojų.

SCADA (angl. *supervisory control and data aquisition*) - realaus laiko informacijos stebėjimo, surinkimo, kaupimo bei apdorojimo kompiuterinė sistema.

TSPĮ – teleinformacijos surinkimo ir perdavimo įrenginys.

ADMS (angl. *advanced data management system*) - programinės įrangos platforma skirstomajam tinklui valdyti, stebėti.

RAA – Relinė apsauga ir automatika.

AKĮ – Automatinis kartotinis įjungimas.

OLJ – Oro linijos jungtuvas.

TJI – Trumpo jungimo indikatorius.

DNN (angl. *deep neural network*) – sudėtingasis neuroninis tinklas.

MLP – paprastais neuroninis tinklas.

ReLu (angl. *Rectified Linear Unit*) – aktyvacijos funkcija mašiniame mokyme.

Terminai:

Save gydantis tinklas – automatinis ADMS programos modulis, kuris vykdo EE atstatymą, bei pažeisto ruožo izoliavimą gedimo atveju.

SAIDI (angl. *System Average Interruption Duration Index*) - sistemos vidutinės nutraukimo trukmės indeksas. Šis indeksas parodo kiek vidutiniškai laiko per ataskaitinį laikotarpį elektros energija nebuvo tiekama vienam klientui. Ataskaitinis laikotarpis dažniausiu atveju yra kalendoriniai metai. SAIDI matuojamas minutėmis klientui (gali būti matuojamas valandomis klientui)

SAIFI (angl. *System Average Interruption Frequency Index*) - sistemos vidutinio nutraukimo dažnio indeksas. Šis indeksas parodo kiek vidutiniškai kartų per ataskaitinį laikotarpį elektros energija buvo nutraukta vienam klientui. Ataskaitinis laikotarpis dažniausiu atveju yra kalendoriniai metai. SAIFI matuojamas kartais klientui.

CAIDI (angl. *Customer Average Interruption Duration Index*) - yra vidutinio pertraukimo trukmės indeksas, naudojamas elektros tiekimo sektoriuje, kad matuotų elektros tiekimo pertraukimų trukmę vartotojui. Šis indeksas yra vidutinė pertraukimo trukmė per sutrikimą.

AENSI (angl. *Average Energy Not Supplied Index*) - tai matavimas, kuris rodo, kiek energijos vidutiniškai nebuvo tiekama dėl pertraukimų elektros tinklo tiekime. Jis dažnai naudojamas elektros energetikos pramonėje, siekiant išmatuoti ir vertinti elektros tinklo patikimumą ir efektyvumą.

V2G (angl. *vehicle to grid*) - technologija, leidžianti grąžinti energiją iš elektrinių automobilių į elektros tinklą. Tai reiškia, kad elektriniai automobiliai, kurie nėra naudojami ir yra prijungti prie elektros tinklo, gali atiduoti dalį savo akumuliatoriaus energijos atgal į tinklą. Tai gali būti naudinga tinklo balansavimui, ypač per didesnio elektros vartojimo laikotarpius, ir gali padėti sumažinti elektros energijos švaistymą.

GNL (angl. *generalized network learning*) - mašiniame mokyme modelio gebėjimas taikyti išmoktas taisykles naujiems duomenims.

Kryžminis patikrinimas (angl. *cross-validation*) yra statistinis metodas, skirtas vertinti mokymo modelių efektyvumą dažnai naudojamas mašininio mokyme. Šis metodas padeda įvertinti, kaip gerai pasirinktas modelis galėtų generalizuoti naujus anksčiau nematytus duomenis.

Foldas - yra dalis duomenų mašininio mokymo duomenų rinkinyje, naudojama tiek mokymo, tiek testavimo etapuose, siekiant įvertinti modelio efektyvumą ir jo gebėjimą generalizuoti.

Įvadas

Šiuolaikiniame skirstomajame tinkle naudojama daug technologijų tinklo režimams užtikrinti, bei išlaikyti sistemos patikimumą. Stebint paskutiniųjų metų tendencijas akivaizdžiai matyti, kad skirstomojo tinklo patikimumui suteikiam vis daugiau dėmesio, nes elektros energijos (EE) vartojimo svarba paskutiniu metu yra išaugusi. Skirstomojo tinklo tikisi, kad tiekiamą EE visada ir prieinama ir patikima. Tinklo valdymui ir stebėjimui skirstomajame tinkle yra naudojama SCADA sistema, siekiant suderinti nestandartines duomenų bazines, bei įrenginių sąsajas buvo sukurta ADMS sistema. Su ADMS galima efektyviai stebėti tinklą realiu laiku, planuoti ir išplėstinai valdyti tinklo operacijas, bei atstatinėti nutrūkusį EE tiekimą vartotojams, bei gauti prieigą prie istorinių duomenų. EE tiekimo atstatymui po gedimo tinkle dėl įvairių priežasčių ADMS programų paketai turi modulius, kurie vadinami save gydančiu tinklu save gydančių tinklu. Šiame darbe bus plačiau nagrinėja modulis FLIR, FLISR.

FLIR sistemos įtaka SAIDI ir SAIFI rodikliams yra labai svarbi. Kuo mažesni SAIDI ir SAIFI rodikliai, tuo aukštesnis elektros energijos tiekimo patikimumas. Save gydančio tinklo sistemos turi reikšmingą įnašą gerinant skirstomojo tinklo patikimumą EE tiekime [1]. Šių sistemų naudojimas padeda sumažinti laiko, kurio reikia atkurti elektros energijos tiekimą po pažeidimo, automatinis atstatymas yra daug greitesnis nei operatyvinio personalo darbas, o tai leidžia sumažinti gedimo vietos izoliavimo laiką ir pagreitinti atstatymą nepažeistam ruožui. Tai yra ypač svarbu tokiems pramonės sektoriams, kaip sveikatos apsauga, gamyba ir transportas, kuriems reikia nuolatinio ir patikimo elektros energijos tiekimo.

Tikslas

Šio baigiamojo darbo tikslas - įvertinti save gydančio tinklo įtaką SAIDI SAIFI rodikliams skirstomajame tinkle taikant mašininį mokymą.

Darbo uždaviniai

1. išanalizuoti save gydančio tinklo veikimo principus, bei algoritmą;
2. surinkti, išanalizuoti reikiamus duomenis mašininio mokymo modeliams;
3. sudaryti duomenų rinkinį tinkamą mašininiam mokymui;
4. pritaikyti mašininio mokymo modelį atlikti SAIDI SAIFI prognozę.

1. Apžvalginė dalis

1.1. SCADA ir ADMS


SCADA - realaus laiko informacijos stebėjimo, surinkimo, kaupimo bei apdorojimo kompiuterinė sistema (angl. *Supervisory Control and Data Acquisition System*).

Per duomenų perdavimo tinklus valdomi įvairių energetikos objektų – transformatorių pastočių, skirstyklų, modulinį transformatorinių teleinformacijos surinkimo ir perdavimo įrenginiai (TSPĮ), o surinkta ir perduota informacija atvaizduojama proceso vizualizacijos sistemoje SCADA.

Pagrindiniai SCADA uždaviniai:

- duomenų mainai realiajame laike;
- duomenų apdorojimas realiajame laike;
- patogus duomenų atvaizdavimas;
- duomenų kaupimas ir saugojimas;
- signalizavimas apie gedimus ir pan.;
- ataskaitų apie technologinių procesų eigą formavimas;
- tarptinklinė sąveika tarp TSPĮ ir SCADA.

SCADA programa yra užtikrinamas ryšys su išoriniais įrenginiais, užtikrinama operatyvi ir adekvati dispečerių reakcija, tokiu būdu žalos prevencija yra savalaikė. Ryšys tarp TSPĮ (teleinformacijos surinkimo ir perdavimo įrenginys) nutolusiuose objektuose ir SCADA palaikomas per ryšio serverius, kurie leidžia palaikyti ryšį įvairiais duomenų perdavimo protokolais (IEC 60870-5-101; IEC 60870-5-104; DNP; DNP3) Duomenų priėmimui ir valdymui, technologinės įrangos kontrolei, nutolusiuose elektros tinklo objektuose, naudojama visa eilė įvairių TSPĮ valdiklių.




1 pav. SCADA sistema

ADMS - programinės įrangos platforma. ADMS suteikia galimybes pilnai valdyti, stebėti, automatizuoti skirstymo tinklą. ADMS pagrindinės funkcijos/moduliai:

- volt/var valdymas - reaktyvios galios valdymas/ įtampų valdymas su reaktyvia galia;
- save gydantis tinklas – tinklo gedimo lokalizavimo, izoliavimo ir EE atstatymas;
- adaptyvus galios srautų valdymas;
- vartotojų pranešimų apie gedimus priėmimas ir atvaizdavimas tinklo schemose;
- planinių/neplaninių atjungimų valdymas/planavimas.

Šiuolaikinėse skirstomojo tinklo sistemose ADMS ir SCADA (2 pav.) veikia kartu, taip sudarydami galingą tinklo valdymo sistemą su įvairiomis posistemėmis (moduliais). SCADA daugiau atlieka stebėtojo ir valdytojo vaidmenį, o ADMS yra smegenys, kurie apdirba tinklo informaciją ir pagal tai duoda grįžtamąjį ryšį (automatizuoti veiksmai, sprendiniai, automatinės analizės)[11].



2 pav. ADMS sistema [2]

1.2. Save gydantis tinklas

Save gydantis tinklas yra bendrinis pavadinimas, taip vadinami ADMS sistemų moduliai, kurie atlieka EE atstatymą ir gedimo vietos izoliaciją. Priklausomai nuo naudojamos AMDS sistemos jų modulių pavadinimai gali būti įvairūs (FLIR, APRS, FLISR, MARS, ARA), bet funkciją jų tokia pat.


Pagrindinės funkcijos [12]:

- lokalizuoti gedimo vietą;
- izoliuoti gedimo vietą;
- įvertinti dėl permaitinimo galimybes;
- atstatyti EE nepažeistam ruožui.


Save gydantis tinklas gedimo vietą nustato pagal turimus duomenis iš įrenginių, kurie perduoda TV informaciją (jungtuvai, trumpojo jungimo indikatoriai) prie turimų duomenų iš įrenginių, gali būti panaudoti duomenys apskaičiuoti ADMS sistemoje pvz.: galių srautai, likutinis donorinės linijos pralaidumas.

1.2.1. Veikimo algoritmas


Save gydantis tinklas veikimo metu atlieka tinklo būsenų patikrinimus, bei skaičiavimus, kad galėtų įsivertinti geriausią EE atstatymo strategiją. Labai svarbu, kad ADMS/SCADA sistemoje būtų tiksliai sukonfigūruoti matavimai ir įrenginių būsenų atvaizdavimai, kitų atveju gali būti ir pasekmių sunkesnių, nei pirminis gedimas, tuo pačiu algoritmas turi saugiklį ir įvertinęs duomenis gali priimti išvadą, kad duomenis nepatikimi ir stipriai sumažinti atstatomo ruožo dydį dėl saugumo. Kitame puslapyje pateikiamas vienas iš algoritmų (4 pav.), kuris yra taikomas save gydančio tinklo veikime. Pilnai atlikęs veikimo ciklą save gydantis tinklas grįžta į normalią būseną (3 pav.) 5-ame paveikslėlyje pateikiamas konkrečiai General Electric ADMS sistemos FLIR modulio veikimo algoritmas



3 pav. Save gydančio tinklo veikimo ciklas [3]




4 pav. Savęs gydančio tinklo veikimo algoritmas [4]



5 pav. Save gydančio tinklo (FLIR) veikimo algoritmas

1.2.2. Scenarijai


Aprašomas veikimas iš techninės pusės pagal pasirinktą scenarijų.




6 pav. Gedimo scenarijus 01

Pagal pateiktą scenarijų 01 (6 pav). matyti, kad gedimas įvyko atšakoje už nevaldomos 10kV TR-4.2. Tokiu atveju po RAA poveikio jungtuvas L-100 atsijungs ir startuos save gydančio tinklo algoritmas. Programa gavusi duomenis iš valdomų objektų, kurie yra pažymėti schemoje "v" raide. Gedimo vieta nustatoma pagal TJI sumontuotus TR. Šioje schemoje turėtų būti suveikę TJI esantys TR-1, TR-3. Kadangi pagal TJI suveikimo būsenas matyti, kad TJ nepraėjo TR-5, reiškia ruožą esantį nuo TR-3 iki TR-5 galima izoliuoti ir įjungti L-100 vėl, ir permaitinti likusį ruožą galą su OLJ-200.

Apačioje pateikiama kaip schema atrodys po programos veikimo (7 pav.).

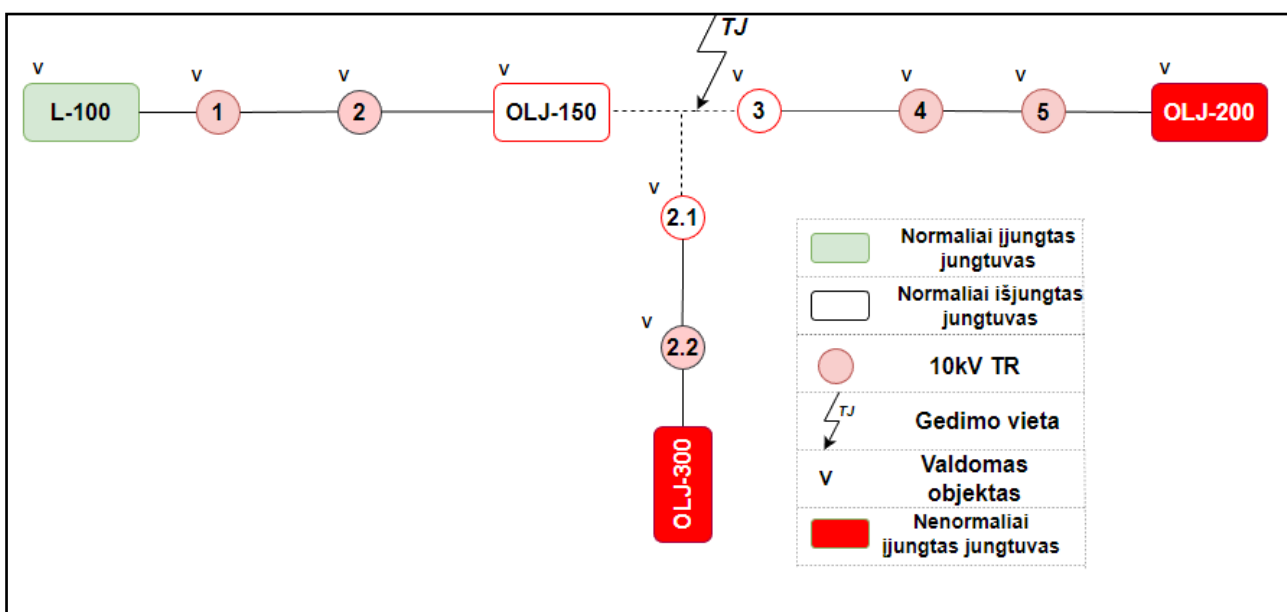


7 pav. Schema po save gydančio tinklo programos veikimo



8 pav. Gedimo scenarijus 02

Gedimo scenarijuje 02 (8 pav.) RAA poveikis bus OLJ-150, kadangi atsijungė OLJ-150 ir objektuose TR-1, TR-2 suveikė TJI, o objektuose TR-3 ir TR-2.1 TJI nesuveikė reiškia ruožas tarp OLJ-150, TR-3, TR-2.1 yra TJ. Tad šitas ruožas yra izoliuojamas. Po ruožo izoliavimo yra įjungiami OLJ-200 ir OLJ-300 nepažeisto ruožo permaitinimui. Apačioje pateikiama schema (9 pav.) kaip atrodys schema po programos veikimo.



9 pav. Schema po save gydančio tinklo veikimo

Pagal schemą matyti, kad TJ gedimo ruožas yra izoliuotas ir vartojai, kurie būtų atjungti po RAA poveikio yra permaitinti. Anot Mehdi Moandi ir kt. SGT atnešą gerą naudą, nors tinkle ir didelių pokyčių konfigūracijoje nėra, pvz.; įdiegiant naują galios skyriklį galima gauti daug naudos gedimo atveju, nes jis gali izoliuoti gedimo vietą [16].

1.3. SAIDI ir SAIFI rodikliai

SAIDI ir SAIFI yra tarptautiniai rodikliai nusakantys EE tinklų nutraukimų trukmės ir dažnio indeksus.

SAIDI (angl. *System Average Interruption Duration Index*) - sistemos vidutinės nutraukimo trukmės indeksas. Šis indeksas parodo kiek vidutiniškai laiko per ataskaitinį laikotarpį elektros energija nebuvo tiekama vienam klientui. Ataskaitinis laikotarpis dažniausiu atveju yra kalendoriniai metai. SAIDI matuojamas minutėmis klientui (gali būti matuojamas valandomis klientui).

$$SAIDI = \frac{\sum T_{ai} \times N_i}{\sum N_i}; \quad (1)$$

čia:

T_{ai} - i-tojo mazgo klientų atjungimo trukmė;

N_i - i-tojo mazgo klientų skaičius.


SAIFI (angl. *System Average Interruption Frequency Index*) - sistemos vidutinio nutraukimo dažnio indeksas. Šis indeksas parodo kiek vidutiniškai kartų per ataskaitinį laikotarpį elektros energija buvo nutraukta vienam klientui. Ataskaitinis laikotarpis dažniausiu atveju yra kalendoriniai metai. SAIFI matuojamas kartais klientui.

$$SAIFI = \frac{\sum f_i \times N_i}{\sum N_i}; \quad (2)$$

čia:

f_i - i-tojo mazgo maitinimo nutraukimų skaičius;

N_i - i-tojo mazgo klientų skaičius.




10 pav. SAIDI SAIFI palyginimas 2020 ir 2021 metų [6]

2. Literatūros analizė

Šio darbo metu buvo analizuoti užsienio valstybių duomenys apie save gydantį tinklą. Kaip ir buvo minėta šiame darbe visų nagrinėtų save gydančio tinklo variacijų tikslas – lokalizuoti gedimą, permaitinti nepažeistą ruožą.

2.1. FLISR+DER

Verta paminėti, kad buvo ir modifikuotų įdomių variantų, kaip pavyzdžiui Vašingtono universiteto mokslininkų sukurtas (modifikuotas) SGT algoritmas - FLISR papildomai buvo suintegruota funkcija naudoti DER (angl. *distributed energy resources*). DER tai mažos galios generatoriai, kurių lokacijoje yra elektros vartotojų. Šis algoritmas ištikus atsijungimui atlieka, perjungimus taip, kad vietose, kur yra sudėtingas permaitinimas galėtų išvesti į salos režimą (11 pav.)




11 pav. Simuliacija FLISR+DER integracija. spalvos žymi skirtingų pastočių žymėjimą. a) pažymėta gedimo vieta; b) dėl gedimo izoliuotas ruožas (pilka) c) minimizuotas izoliuotas ruožas ir prijungtas DER, išvestas dalis vartotojų į salos režimą [7]

Ši sistema buvo modifikuota, nes poreikis yra iškilęs dėl blogėjančių orų dėl šios priežasties yra dažni atsijungimai, kuriuos sudėtinga atstatyti [7]. Sprendimas buvo padaryti kuo daugiau mikrotinklo galimybių. Išvadose teigiama, kad testai praėjo sėkmingai. Programa buvo suprogramuota Python programavimo kalba.

2.2. FLISR įtaka SAIDI CAIFI, Iranas

Teherano universiteto mokslininkai atliko simuliacijas, kokią įtaką turi FLISR modulis ekonominei tinklo daliai. Anot Teherano universiteto mokslininkų. Įdiegus ir tinkamai eksploatuojant FLISR galima pastovus dėl atsijungimų, nes save gydantis tinklas minimizuoja žalą įvykus atsijungimui. Modeliavimas parodė, kad pastovų dėl atsijungimų būtų mažiau, o tuo pačiu išaugtų vartotojų pasitenkinimas, pagerėtų SAIDI CAIDI rodikliai.




12 pav. Simuliacijų rezultatai pagal EE nutraukimo trukmę. [8]

Pagal paveikslėlį matyti, kad visi trys simuliuoti scenarijai demonstruoja trumpesnius EE nutraukimo trukmės laikus.

2.3. FLISR įtaka SAIDI ir AENSI, Egiptas

Egipto, Tantu universitetas atliko tyrimą kokią įtaka save gydantis tinklas turi SAIDI ir AENSI rodikliams. Šiame tyrime pabrėžiama, kad siūlomas automatizuotas tinklas turi aukštą patikimumo lygį palyginti su neautomatizuotu tinklu, tai aiškiai parodo rezultatai, nes automatizuoto tinklo rodikliai daug geresni [9]. Simuliacijai buvo pasirinktas senas neautomatizuotas tinklas. Tinklo schema pateikta 13 – am paveikslėlyje.




13 pav. Testuojama skirstomojo tinklo schema. [9]

Taikant Monte Carlo metodą buvo nustatyta, kad tinklas žymiai patikimesnis, išaugs vartotojų pasitenkinimas, pagerės SAIDI, SAIFI, CAIDI, EENS, AENS rodikliai (žr. 1 lent., 14 pav.)

1 lentelė Skirstomojo tinklo patikimumo rodikliai

	SAIDI (val/m)	SAIFI (nut/m)	CAIDI (val/vart. nut)	EENSI (MWh/m)	AENS (MWh/vartotojų met)
Neautomatizuotas	1,2016	0,2052	5,855	9,193	0,0621
Automatizuotas	0,794	0,2052	3,869	6,227	0,0421




14 pav. Rezultatai po Monte Carlo simuliacijos [9]

Iš rezultatų aiškiai matyti, kad simuliuojant automatizuotą tinklą rodikliai ženkliai geresni. AENSI ir SAIDI rodiklių sumažėjimas iki 32% ir 34%.

2.4. FLISR įtaka SAIDI ir SAIFI, Kanada

Kanadoje atliktas modeliavimas sukūrus min sistemą simuliacijai, kompanijos BC Hydro ir Powertech Labs sukūrė mini skirstomojo tinklo sistemą (žr 15 pav.), kad galėtų atlikti testus su save gydančiu tinklu. Atliktas tyrimas parodė kad tinkamai sukonfigūruota paskirstymo automatika ir automatizuotas FLISR gali sumažinti gedimų trukmę nuo 639 980 minučių iki 199 090 minučių, o atjungtų klientų nuo 2972 iki 926. Plečiant automatizuotą tinklą SAIDI SAIFI proporcingai gerėja [9]




15 pav. Mini skirstomojo tinklo modelis [5]

2.5. Gedimų nustatymas skirstomajame tinkle esant remiantis grafų teorija ir giliuoju mokymui, Kinija


Kinijoje mokslininkai siūlo modelį eksploatuoti skirstomuosius tinklus – V2G (angl. *vehicle to grid*). V2G, tai būdas kai elektromobilis gali atiduoti galią į tinklą (16 pav). Tokiu būdu ši technologija gali teikti pagalbinius servisus esant galios trūkimui. Naudojant šią technologiją atsiranda naujų gedimų tikimybė tinkle. Dėl šios priežasties kinai sukūrė algoritmą, kuris gali prognozuoti šiuos gedimus.

Šiam algoritmui buvo naudojamas gilusis mokymas dėl galimybės dėl konverguoti tarp įvairių kintamųjų ir adaptyvumo. Šiam algoritmui įgyvendinti naudojama maksimalaus vidutinio skirtumo metodas tirti pavyzdinės linijos ir tikslinės linijos panašumus ir tikslinio domeno duomenys naudojami norint tiksliai suderinti perdavimo mokymą išankstinio mokymo modelį, kad būtų gautas galutinis tikslinės srities gedimų prognozės modelis [18]. Konvoliucinis neuronų tinklas yra naudojamas, kad suklasifikuotų gedimo sprendimą ir gedimo fazę.



16 pav. Schematinė diagrama skirstomojo tinklo su V2G technologija [18]

Grafų teorijoje duomenų taškai yra naudojami atvaizduoti tam tikrus įvykius, linijos jungiančios taškus indikuoja, kad taškai turi tam tikrą (17 pav) ryšį.




17 pav. Tinklo dalis atvaizduota pagal grafų teoriją

Kadangi skirstomojo tinklo topologija iš esmės atitinka grafų teorijos struktūrą, ją galima taikyti sprendžiant uždavinius susijusius su skirstomuoju tinklu. Tinklo modelyje yra iš analizuojamas koreliacijos tarp apkrovos ir trumpo jungimo srovių. Visi duomenys (tinklo topologija, srovių charakteristikos) yra išanalizuojami su GNL algoritmu (angl. *generalized network learning*), ir yra

panaudojami treniruoti modelį. Po treniravimo modelis turi gebėti atpažinti naujus, nematytus duomenis (gedimus).

Tinklas buvo padalintas į 4 zonas, jos dalijosi vienu maitinimo šaltiniu ir dviem įkrovimo taškais,



18 pav. Modelio struktūra

bendras linijų skaičius – 33, ilgis – 1 km. Tinkle taikomi trys apkrovų režimai 90% , 100%, 110%. Norint gauti pakankamai duomenų gedimai taikomi kas 100 metrų kiekvienoje linijoje. Naudojant PSCAD buvo sugeneruota 4230 gedimų duomenų eilučių. 3558 eilutės buvo panaudotos modelio treniravimui, 692 eilutės – testavimui. Atlikus modelio apmokymą buvo atliktas testavimas gauti rezultatai pateikiami 2-oje lentelėje.

2 lentelė Modelio testavimo rezultatai

	Vienfazis įžemėjimas	Dvifazis įžemėjimas	Dvifazis trumpas jugimas	Trifazis trumpas jungimas
Įvykių skaičius	173	173	173	173
LPA%	98,22	98,56	98,71	98,09
Laikas (s)	0,027	0,027	0,030	0,028

Pagal aukščiau esančią lentelę matyti, kad metodo tikslumas nustatant gedimus yra didesnis nei 98,09%, apskaičiavimo laikas mažesnis nei 0,030 s. Pagal šiuos rezultatus galima teigti, kad modelis nustato gedimus tiksliai ir greitai esamam tinklo modeliui. Pagal modelio skaičiavimus tai pat nustatyta, kad 1000 metrų linijoje, gedimo vietos nustatymo paklaida yra 1,8 proc (20 m). Praktikoje naudojant šį metodą inžinerinėse programose dėl duomenų konvertavimo ir apdorojimo atsiranda duomenų iškraipymas ir tokiu būdu susidaro didesnė vietos nustatymo paklaida, kuri gali padidėti iki 290 metrų, bet modelis vis tiek yra laikomas efektyviu, kad ir su tokia paklaida.

2.6. Apibendrinimas


Padarius mokslinių straipsnių analizę patampa aišku, kad save gydantis tinklas dar naujovė, nors egzistuoja ir yra bandomas, kurį laiką. Ir testuojamas dažniausiai kodo pavidalu, nes niekas nesiryžta investuoti iškart didelės pinigų sumos į įrenginius, programinius paketus, kad galėtų jį paleisti.

Atliekant testus su programa matyti didelis privalumas – greیتaveika. Tai tai pat puikus įrankis geriems tinklo rodikliams palaikyti tokiems, kaip SAIDI, SAIDI, CAIDI ir t.t. Tinkamai eksploatuojant programa sukuria ir papildomą vertę – augina klientų pasitenkinimą dėl patikimesnio tinklo. Asad Waqur ir kt. teigia, kad tokios sistemos naudojant Ai algoritmus ypatingai padidina tinklo patikimumą [23]. Didelis plusas yra tai, kad programa gali lanksčiai adaptuoti prie esamo tinklo poreikių, nes skirtingose šalyse galima atrasti labai didelių skirtumų tinklo valdyme, įrenginių specifikoje. Inžinieriams paprasta naudoti, dispečeriams išvis tik tereikia žinoti, kaip įjungti išjungti.

Kadangi straipsniuose figūruoja vien programos simuliacijos dėl to aktualumas testuoti save gydantį tinklą realiomis sąlygomis yra.

2.7. Aktualumas Lietuvoje

Atlikus užsienio valstybių straipsnių analizę, kad temos aktualumas yra didelis, tada galima daryti išvadą, kad Lietuvoje galima visai tai išmatuoti ir sužinoti pagal tinklo duomenis, nes Lietuva jau turi save gydantį tinklą.



19 pav. Automatizacijos palyginimas, sudaryta pagal šaltinius [10], [13]

Jeigu imant idealias SGT FLIR sistemos esančiose Lietuvoje veikimo sąlygas, tai net neskaičius galima pasakyti, kad SAIDI ir SAIFI rodikliai yra gerinami, tai galime pamatyti palyginę gedimo šalinimo laikus esant automatizacijai ir nesant (19 pav.).

Normaliomis darbo sąlygomis SGT mažina generavimo išlaidas, o avarinėmis sąlygomis minimizuoja apkrovos sumažinimo mastą. Algoritmas atsižvelgia į labiausiai tikėtinus ir žalingiausius atsitiktinius atvejus, kurie gali kilti tinkle [21].

Pažiūrėjus laiko skales tampa akivaizdu, kad idealioms sąlygomis viskas būtų daug geriau. Bet tinklas tikrovėje neveikia visada idealiai. Yra visokių trikdžių, galimų scenarijų kada rodikliai nebus gerinami dėl automatizacijos veikimo. Anot Liun Jinsong ir kt. plėtra, testavimas ir implementacija yra būtinas procesas SGT praktiniam veikimo gerinimui [14].

3. Problemos formulavimas

Atlikus literatūros analizę, aiškiai matyti, kad SGT pritaikymas ir susidomėjimas yra didelis dėl jo potencialo. Atliekant analizę, padaryta, išvada, kad SGT vis dar nėra plačiai taikomas realiuose skirstomuose tinkluose, nes jo įdiegimas reikalauja daug kaštų dėl šios priežasties SGT yra simuliuojamas ir tiriamas kaip algoritmas, kad nustatyti jo potencialią naudą. Analizuojant SGT vien skaitmeniniu pavidalu galima gauti iškreiptus rezultatus, nes SGT veikimo inicijavime yra daug kintamųjų. Vienas iš jų - oro sąlygos, net turint jų prognozę nėra aišku kaip tai paveiks skirstomąjį tinklą, nes jos per daug varijuoja, kad vien iš orų prognozės būtų aišku, kur ir kokios tinklo vietos bus paveiktos bei kaip suveiks SGT. Dėl šios priežasties vien orų prognozės nepakanka. Galimas sprendimo būdas – dirbtinis intelektas. Šiuolaikinėms sistemoms apsaugoti ir atlikti gedimų prognozėms sėkmingai naudojami DI. Šie algoritmai geba nuspėti įvairių įvykių rezultatus prieš jiems įvykstant. Tam kad tiksliai ir patikimai prognozuoti įvykius bei jų pasekmes reikalingi tikslūs duomenys ir didelis jų kiekis, kad būtų galima tinkamai išmokinti DI. Norint, kad DI algoritmai veiktų efektyviai, reikia ne tik tinkamai juos išmokyti, bet ir nuolat atnaujinti duomenų bazę. Tai leidžia atsižvelgti į naujausius tendencijų pokyčius ir įgytas žinias taikyti esant naujoms aplinkybėms. Taip pat, būtina priežiūra ir algoritmo optimizavimas, kad užtikrintų patikimas prognozes ir efektyvų naudojimąsi.

Svarbu pabrėžti, kad ne visi duomenys yra vienodai svarbūs. Kiekvienai sistemai, kuriai taikomas DI, turėtų būti atliekamas atitinkamas duomenų rinkinio parinkimas ir apdorojimas, kad būtų galima išskirti svarbiausias savybes, leidžiančias geriausiai prognozuoti įvykius. Be to, DI taikymas apsaugos sistemose ir gedimų prognozavime reikalauja aukšto lygio saugumo standartų. Duomenų privatumas ir saugumas yra labai svarbūs aspektai, kadangi šios sistemos dažnai naudojamos kritinėse infrastruktūrose, kurios gali būti pažeidžiamos dėl duomenų nutekėjimo ar kitokios netinkamos veiklos.

Šiuolaikinės technologijos leidžia mums ne tik prognozuoti, bet ir reaguoti į įvykius realiu laiku. Tai yra vienas iš svarbiausių DI privalumų. Tačiau, svarbu suprasti, kad DI nėra stebuklingas sprendimas visiems iššūkiams. Algoritmai gali suklysti, o prognozės nėra absoliutus garantas. Todėl svarbu nuolat stebėti sistemą, atnaujinti ir pritaikyti algoritmus, ir nuolat mokytis sistemą, kad ji būtų vis efektyvesnė.


4. Metodika

4.1. Dirbtinio intelekto modeliai skirstomojo tinklo rodikliams prognozuoti

Šiame tyrime nagrinėjami 3 modeliai:

1. Tiesinės regresijos modelis
2. Paprastasis neuroninis tinklas
3. Sudėtingasis neuroninis tinklas

Panaudojant šiuo metodus buvo atrinkti 3 geriausi modeliai prognozuoti rodikliams. Prognozės modelio



20 pav. Duomenų rinkinio sudarymo schema

Iš paveikslėlio, kad suformuotas duomenų rinkinys su orų prognoze bus naudojamas, kaip įvesties duomenys, kad išprognozuoti skirstomojo tinklo rodiklius.

4.2. Tiesinės regresijos modelis

Tiesinė regresija yra statistinė analizės technika, skirta nustatyti ryšį tarp kintamojo (priklauso nuo kitų kintamųjų) ir vieno ar daugiau nepriklausomų kintamųjų. Ji naudojama prognozavimui, laiko eilučių analizei, priežastinėms analizėms ir kt.

Tiesinė regresijos pagrindinės dedamosios:

1. Priklausomas kintamasis (Y): Tai yra kintamasis, kurį norime prognozuoti arba prognozuoti.
2. Nepriklausomi kintamieji (X): Tai yra kintamieji, kurie padeda prognozuoti priklausomąjį kintamąjį. Jie taip pat vadinami paaiškinamaisiais kintamaisiais.
3. Regresijos linija: Tai linija, kuri aprašo ryšį tarp priklausomo ir nepriklausomų kintamųjų. Tai yra linija, kuri minimizuoja visų taškų atstumą nuo linijos.
4. Nuolydis (β_1): Tai parodo, kaip priklausomas kintamasis keičiasi, kai nepriklausomas kintamasis pasikeičia vienetu.
5. Atkarpinė (β_0): Tai yra taškas, kuriame regresijos linija kerta Y ašį. Tai yra priklausomojo kintamojo vertė, kai visi nepriklausomieji kintamieji yra 0.

Tiesinė regresijos matematinė išraiška:

$$Y = \beta_0 + \beta_1 \times X + \varepsilon; \quad (3)$$

čia:

Y – priklausomas kintamasis;

X – nepriklausomas kintamasis;

β_0 – Y ašies atkarpinė;

β_1 – linijos nuolydis;

ε – atsitiktinis kintamasis, kuris aprašo nepaaiškintą informaciją.

Šio principo modelio buvo sukurti 2 variantai, prognozuoti:

- atjungtų vartotojų skaičių;
- save gydančio tinklo veikimo trukmę;
- prijungtų vartotojų skaičių.

Šiame darbe naudojamas tiesinės regresijos modelis, kuris bus apmokytas naudojant kryžminio patikrinimo metodą validacijos metodą, kuris yra naudojamas modelio tikslumo įvertinimui. Duomenys yra suskaidomi į mokymosi ir testavimo rinkinius. Modelis yra apmokomas naudojant mokymosi rinkinį, ir jo tikslumas yra vertinamas naudojant testavimo rinkinį. Procesas yra kartojamas n kartų (n yra dalijimų skaičius kryžminio patikrinimo metodu) būtent šiame modelyje 20 kartų, kiekvieną kartą naudojant skirtingą duomenų suskaidymą. Įvertinant modelio tikslumą naudojant kryžminį patikrinimą, gaunami rezultatai yra stabilūs ir mažiau priklauso nuo pradinio duomenų suskaidymo. Standartizavimas naudojamas, kad suvienodinti skirtingus kintamųjų dydžius, vienetus ir paversti, kad jų reikšmės būtų 0-1 intervale Standartizavimo funkcija aprašoma taip:

$$z = (x - \mu) / \sigma; \quad (4)$$

čia:

x – pradinė kintamojo reikšmė;

μ - vidurkis;

σ - standartinis nuokrypis.

Pirma modelio kodas apibrėžia kryžminio patikrinimo funkciją, kuris priima 4 argumentus:

- regresijos modelį;
- duomenų rinkinį X ;
- atsakymų vektorių Y ;
- kryžminio patikrinimo iteracijų skaičių (20).

Funkcija pradeda nuo kryžminio patikrinimo atlikimo. Tada jis pradeda ciklą per kiekvieną kryžminio patikrinimo iteraciją, skirsto duomenis į mokymo ir testavimo rinkinius, apmoko estimatorių, prognozuoja testavimo duomenis ir apskaičiuoja paklaidas bei R^2 (determinacijos koeficientas) reikšmę. Algoritmas išsaugo faktinius atsakymus, prognozes ir kitus svarbius atributus. Sekančiai yra paruošiami duomenys analizei. Naudojamos tik skaitinės reikšmės atributai, trūkstamos reikšmės yra užpildomos vidurkiais. Atsakymų vektoriaus Y yra stulpelis yra pašalinamas iš X įvesties duomenų, tai pat pašalinami duomenys, kurie yra iš skirstomojo tinklo gedimų rinkinio galintys suteikti

informacijos prognozei ir „padėti“ atspėti nepagrįstai. Sukuriamas tiesinės regresijos modelis ir standartizavimo objektas. X ir Y yra standartizuojami.

4.3. Paprastojo neuroninio tinklo modelis (MLP)

Šiame darbe nagrinėjamas MLP modelis su dviem paslėptaisiais sluoksniais, kurių dydžiai yra 128 ir 64. Išvesties sluoksnis yra tiesinė funkcija, kuri grąžina vieną išvesties reikšmę. Modelis kompiliuojamas naudojant optimizavimo algoritmą ir vidutinę kvadratinę paklaidą kaip praradimo funkciją. Šio modelio kodas naudoja Python neuroninių tinklų biblioteką - siekiant sukurti paprastą neuroninį tinklą. Modelis bando prognozuoti atjungtų vartotojų skaičių naudojant sukurtą modelį ir skirtingus duomenų rinkinius. Neuroninį tinklą galima laikyti sudėtinga funkcija, kuri priklauso įvesties x ir svorių W . Kiekvieno neuroninio tinklo sluoksnio operacija gali būti užrašyta taip:

$$a[i] = \sigma(W[i] \times a[i-1] + b[i]); \quad (5)$$

čia:

$a[i]$ – i -tojo sluoksnio neuronų išvestys;

σ – aktyvavimo funkcija;

$W[i]$ – i -tojo sluoksnio svoriai;

$a[i-1]$ – $i-1$ -ojo sluoksnio neuronų išvestys (arba įvestis, jei $i=0$);

$b[i]$ – i -tojo sluoksnio poslinkiai,

Apmokymo metu naudojamas optimizavimo algoritmas, kuris yra iteracinis svorių atnaujinimo metodas, grindžiamas gradientiniu nusileidimu. Kiekvienoje iteracijoje svoriai W yra atnaujinami taip:

$$W[i] = W[i] - \eta \times \nabla W; \quad (6)$$

čia:

$W[i]$ - yra svoriai i -tojo sluoksnio;

η - yra mokymosi greitis, kuris nusako, kiek svoriai yra keičiami per vieną mokymo iteraciją;

$\nabla W[i]/L$ - yra klaidos funkcijos L gradientas pagal svorius $W[i]$.

Gradientas $\nabla W[i]/L$ klaidos funkcijos pokytis, kai šiek tiek pakeičiami svoriai $W[i]$. Jis naudojamas nustatyti, kokia kryptimi reikėtų keisti svorius, kad klaida sumažėtų.

4.4. Sudėtingojo neuroninio tinklo modelis (DNN)

Šis modelis yra sudarytas iš trijų sluoksnių – pirmuose dviejuose sluoksniuose, kuriuose yra po 64 neuronus (aktyvacija), trečiasis yra išėjimo sluoksnis su linijine aktyvacijos funkcija.

Sukurtas neuroninis tinklas turi šias savybes ir funkcijas:

- tai yra sekvencinis modelis, kuris leidžia pridėti neuronų sluoksnius vienus po kito;
- šis modelis turi pilnai sujungtų sluoksnių (angl. *dense*) - pirmasis ir antrasis sluoksniai yra pilnai sujungti sluoksniai, kuriuose yra 64 neuronai, ir kurie naudoja ReLU (angl. *Rectified Linear Unit*) aktyvacijos funkciją;
- modelis naudoja išmetimo sluoksnius (angl. *dropout*) – tarp kiekvieno pilnai sujungto sluoksnio yra išmetimo sluoksnis, kuris atsitiktinai išmeta 20% neuronų per mokymo procesą,

siekiant išvengti pernelyg tikslių modelių (persimokymo), kurie nebūtų efektyvūs su naujais duomenimis;

- modelis turi galutinį sluoksnį, kuris yra pilnai sujungtas, bet jame yra tik vienas neuronas, šioje dalyje sprendžiama regresijos užduotis;
- modelis yra kompiliuojamas naudojant optimizavimo algoritmą, o jo nuostolių funkcija yra vidutinė kvadratinė paklaida šis kompiliatorius yra efektyvus stochastinio gradientinio nusileidimo variantas.

Pilnai sujungtų neuronų sluoksnyje kiekvienas neuronas yra sujungtas su visais neuronais iš ankstesnio sluoksnio. Neuroniniame tinklui atliekant spėjimą (angl. *forward propagation*), jis apskaičiuoja kiekvieno neuronų svorių suma pagal šią formulę:

$$z = W \times X + b; \quad (7)$$

čia:

W – svorio matrica;

X – įvesties vektorius;

b – poslinkio vektorius;

z – neuronų išėjimo vektorius prie aktyvacijos funkciją.

Modelyje yra naudojama aktyvacijos funkcija, kuri grąžina nulį, jei įvestis yra mažesnė už nulį, ir grąžina pačią įvestį, jei ji yra didesnė už nulį. Matematiškai formulė aprašoma taip:

$$f(x) = \max(0, x); \quad (8)$$

Išmetimo sluoksniai, kurie padedi išvengti modelio persimokymo matematiškai aprašomi taip:

$$y = f(x) \times k_t; \quad (9)$$

čia:

$f(x)$ – įvesties funkcija;

k_t – tikimybė koeficientas, kad neuronas bus išjungtas.

4.5. Modelių hiperparametrai

Modelių hiperparametrai yra parametrai, kurie nustato mokymosi proceso eigą ir yra nustatomi iš anksto prieš mokymosi procesą. Tai skiriasi nuo modelio parametrų, kurie yra tiesiogiai mokomi per mokymosi procesą. Hiperparametrai padeda reguliuoti modelio sudėtingumą, kuris gali turėti tiesioginį poveikį modelio veikimui. Jie gali būti suprantami kaip 'nustatymai', kuriuos galima reguliuoti, norint optimizuoti modelio mokymąsi ir našumą.

Šiuose modeliuose naudojami hiperparametrai:

- epochų skaičius (angl. *number of epochs*): epocha yra vienas visų mokymo duomenų perėjimas per modelį. Per daug epochų gali sukelti pernelyg didelį mokymąsi, o per mažai – nepakankamą mokymąsi;

- paketų dydis (angl. *batch size*): tai yra kiekis mokymo pavyzdžių, kuriuos modelis peržiūri vienu metu, per didelis blokas gali sukelti per didelį atminties naudojimą, o per mažas gali sukelti mokymosi nestabilumą;
- optimizavimo algoritmai (angl. *optimization algorithms*): tokie kaip SGD, Adam, RMSProp ir tt., kurie nustato, kaip modelis atnaujinama savo parametrus;
- išmetimo, išjungimo koeficientas (angl. *dropout*): jis nustato kiekį (procentais), kuriuo bus "išjungiami" neuronai per mokymo epochą, paprastai šis kiekis yra nustatytas tarp 0 ir 1 - kur 0 reiškia, kad jokie neuronai nebus "išjungti", o 1 reiškia, kad visi neuronai bus "išjungti".

Šie ir kiti hiperparametrai gali turėti didelę įtaką modelio veikimui ir efektyvumui. Hiperparametrų reguliavimas yra sudėtingas procesas, kuris gali reikalauti daugybės bandymų ir klaidų. Tai yra esminė dalis mašininio mokymosi modelio kūrimo ir tobulinimo.

4.6. Modelių vertinimas

Optimalus modelio mokymasis yra sudėtingas procesas ir priklauso nuo daug faktorių: duomenų kokybė ir kiekis, modelio architektūra, hiperparametrai, apmokymo metodas, hiperparametrai. Neišmokimas (angl. *underfitting*) arba persimokymas (angl. *overfitting*) yra dvi pagrindinės problemos modelio mokymo metu. Persimokymas atsiranda, kai modelis per daug prisitaiko prie ir tampa nebeefektyvus generalizuoti naujiems, anksčiau nematytiems duomenims. Neišmokimo atveju, priešingai - kai modelis per mažai prisitaiko prie duomenų ir negali veiksmingai atpažinti net mokymo duomenų. Optimalus modelio mokymasis yra subtilus balansas tarp šių ir kitų veiksmų, ir gali reikalauti nuodugnaus eksperimentavimo ir reguliavimo proceso. Šiame darbe modelių mokymosi procese yra naudojamas kryžminis patikrinimas, kad šių paminėtų problemų išvengti. Svarbiausiai modelių įvertinimo rodikliai, kurie yra naudojami šiame darbe:

MSE (angl. *mean squared error*) – kryžminio patikrinimo vidutinė kvadratinė paklaida yra dažnai naudojamas matavimo metodas mašininio mokymo modeliuose, kuris apibūdina vidutinį kvadratų skirtumą tarp tikrojo ir prognozuotojo modelio rezultato.

Kryžminio patikrinimo vidutinė kvadratinė paklaida (MSE) yra skaičiuojama pagal šią formulę:

$$MSE = 1/n \times \sum (y[i] - \hat{y})^2; \quad (10)$$

čia:

$y[i]$ – tikrosios reikšmės;

$\hat{y}$ – prognozuotos reikšmės;

n – stebėjimų skaičius.

MSE yra teigiamas skaičius, ir kuo mažesnė yra jo reikšmė, tuo modelis yra tikslesnis.

R^2 (angl. *r-squared*) - Kryžminio patikrinimo vidutinis determinacijos koeficientas yra statistinis rodiklis, naudojamas regresijos analizėje, kad nustatytų, kiek duomenų variacijos paaiškina modelis. R^2 apskaičiuojamas taip:

$$R^2 = 1 - (S_{res}/S_{tot}); \quad (11)$$

čia:

S_{res} – kvadratinių paklaidų suma ($\sum (y[i] - \hat{y})^2$);

S_{tot} – bendra kvadratų suma ($\sum(y[i] - y_{\text{vid}})^2$);

y_{vid} - vidutinė tikrosios reikšmės, kuri yra apskaičiuojama kaip visų tikrosių reikšmių (y) suma, padalinta iš jų skaičiaus, reikšmė.

R^2 yra $-\infty$ ir 1 intervale. Kuo didesnė yra R^2 reikšmė, tuo modelis yra efektyvesnis. R^2 reikšmė, lygi 1, reiškia, kad modelis pateikia tobulas prognozes, o R^2 , lygi 0, reiškia, kad modelis neveikia geriau nei vidurkio modelis.

Tikrų ir prognozuojamų reikšmių diagrama, tai labai iliustratyvus metodas pamatyti kaip modelis „pataiko“ į prognozes. Tai yra grafinis duomenų palyginimas. Tikros reikšmės yra realūs stebėjimai, turimi iš duomenų rinkinio, prognozuojamos reikšmės, tai duomenys kuriuos prognozuoja mokymosi modelis. Ši diagrama leidžia vertinti, kaip gerai modelis prognozuoja duomenis palyginti su tikraisiais stebėjimais. Tai gali būti naudinga siekiant suprasti modelio veikimo tikslumą, taip pat identifikuoti modelio silpnąsias vietas, tokias kaip sisteminės paklaidos arba persimokymą.

4.7. Modelių apmokymo strategija

Šiam tyrimui atlikti pasirinktas DI prižiūrimojo mokymo būdas. Šis metodas pasirinktas, nes duomenų rinkiniai, kurie bus taikomi tyrime yra su baigtiniais ir žinomais atsakymais ir būti taikomi kaip etalonai. DI prižiūrimasis metodas yra dirbtinio intelekto metodas, kuriame algoritmai yra apmokomi su žinomais rezultatais arba tikslais. Tokiuose metoduose, algoritmas yra mokomas su duomenų rinkiniu, kuriame jau yra žinomi atsakymai arba rezultatai, kad būtų galima pasiekti pageidaujamą rezultatą. Algoritmas mokosi klasifikuoti duomenis į atitinkamas kategorijas. Atlikęs klasifikaciją algoritmas gali pateikti prognozes ir subendrintus rezultatus. DI prižiūrimojo mokymo metodai yra plačiai naudojami rekomendavimo sistemose, mašininio mokymosi, kalbos vertimo ir kitose srityse, kuriose reikalinga pasiekti tikslus ir aiškius rezultatus.

1. Duomenų surinkimas ir paruošimas. Pirmasis žingsnis yra surinkti duomenis apie skirstymo tinklų gedimus. Duomenys turėtų apimti įvairias charakteristikas, tokias kaip gedimo laikas, vieta, gedimo tipas, priežastys, oro sąlygos ir kitus potencialiai svarbius veiksnius.
2. Duomenų analizė ir valymas. Tada bus atliekama preliminarioji duomenų analizė, kad identifikuotume trūkstamus, pasikartojančius ar netinkamus duomenis. Atliekamas duomenų valymas, kad būtų pašalinti triukšmai ir užtikrina gera kokybę.
3. Duomenų rinkinio suskirstymas. Duomenys bus suskirstomi į apmokymo (70%), validavimo (15%) ir testavimo (15%) rinkinius. Tam panaudotas kryžminio patikrinimo metodas (21 pav.)
4. Modelio pasirinkimas. Pasirenkamas tikslus modelis atsižvelgus į tyrimo tikslą ir duomenų struktūrą.
5. Modelio konfigūracija. Modelis sukonfigūruojamas, nurodomas reikia parametrų kiekis, sluoksnių skaičius, aktyvacijos funkcijas.
6. Modelio apmokymas. Modelis apmokomas su duomenų rinkiniu, rezultatai įvertinami, kad būtų įvertintas modelio tikslumas ir būtų galima išvengti persimokymo.
7. Modelio vertinimas. Įvertinimas modelio našumas.
8. Modelio optimizacija. Jei reikia, kartojama parametrų keitimai, kad optimizuoti modelį.
9. Modelio taikymas. Kai modelis parodys patenkinamus rezultatus, jį galima taikyti realiose situacijose, prognozuojant būsimus skirstymo tinklo gedimus. Tuo metu galite naudoti naujus, nepanaudotus duomenis, kad įvertintumėte modelio patikimumą praktikoje.

5 FOLDŲ KRYŽMINIS PATIKRINIMAS



21 pav. Kryžminio patikrinimo schema

Kryžminis patikrinimas (angl. *cross-validation*) yra statistinė metodika, skirta įvertinti mašininų mokymosi modelių generalizavimo gebėjimus, kai turimi riboti duomenys. Tai leidžia patikrinti, kaip gerai modelis sugeba pritaikyti tai, ką išmoko, prie naujų duomenų, kuriuos modelis anksčiau nėra matęs. Ypač svarbu, kad kryžminis patikrinimas leidžia išvengti pernelyg optimistinių įvertinimų, kurie gali atsirasti, jei modelis vertinamas naudojant tą pačią duomenų grupę, kuria jis buvo apmokytas.

5 foldų kryžminio patikrinimo metodo veikimas:

1. Pirmiausia, turimas duomenų rinkinys yra suskirstytas į 5 lygias dalis, vadinamas foldais.
2. Tada, modelis yra apmokomas 4 iš šių 5 foldų, o likęs foldas yra naudojamas kaip testavimo rinkinys.
3. Šis procesas yra kartojamas penkis kartus, kiekvieną kartą naudojant skirtingą foldą kaip testavimo rinkinį.
4. Tada, iš gautų modelio vertinimo rezultatų iš visų penkių iteracijų yra suskaičiuojami vidurkiai, kad gauti galutinį modelio vertinimą.

Galiausiai kai atlikti visi šie anksčiau paminėti žingsniai, galimas modelio taikymas. Pavyzdžiui, neuroninis tinklas gali būti apmokytas su duomenimis apie skirstomojo tinko gedimus, kaip įvairios oro sąlygos paveikia skirstymo tinklą. Tada, kai skirstomojo tinklo duomenų rinkinys yra naudojamas kaip įvestis į neuroninį tinklą, jis gali prognozuoti būsimus gedimus ir skirstomojo tinklo gedimus bei SGT veikimą.

4.8. Duomenų analizė

4.8.1. Duomenų paruošimas, restruktūrizavimas

Duomenų paruošimas mašiniame mokyme yra svarbi dalis, leidžianti efektyviai naudoti mašinius mokymosi algoritmus, kad būtų galima atlikti prognozes, klasifikaciją, rekomendacijas, klasterizavimą ir daugelį kitų užduočių. Duomenų paruošimas apima šiuos etapus:

1. Nuskaitomi trys duomenų rinkiniai iš kurie turi laiko eilutes su įvykiais (orų istoriniai duomenys, skirstomojo tinklo gedimai, FLIR suveikimai)
2. Skirstomojo tinklo gedimai, ir FLIR suveikimai sujungiami į vieną duomenų rinkinį.
3. Orų istoriniai duomenys suformatuojami, kad būtų galima juos sujungti su skirstomojo tinklo gedimų ir FLIR duomenų rinkiniu (sutvarkomas laiko formatas, laiko zona iš UTC pakeičiam į EET, kad duomenų laikas susivienodintų).
4. Orų istoriniai duomenys sugrupuojami pagal miestą ir laiką.

Šie veiksmai leidžia paruošti duomenis tolesnei analizei ir modeliavimui, nustatyti *FLIR* suveikimų ir gedimų santykį bei įvertinti orų sąlygų įtaką šiems suveikimams.

4.8.2. Skirstomojo tinklo gedimų ir FLIR suveikimų SAIDI SAIFI rodiklių analizė

SAIDI SAIFI rodiklių tyrimui pasitelkta skirstomojo tinklo gedimų duomenų bazė 2012.01.01 – 2022.06.30, SGT duomenų rinkinys 2021.01.01 – 2022.06.30 laikotarpiui. SAIDI ir SAIFI buvo apskaičiuotas naudojantis tarptautine skaičiavimo metodika:

$$SAIDI = \frac{\sum T_{ai} \times N_i}{\sum N_i}; \quad (1)$$

$$SAIFI = \frac{\sum f_i \times N_i}{\sum N_i}; \quad (2)$$

čia:

T_{ai} - i-tojo mazgo klientų atjungimo trukmė;


N_i - i-tojo mazgo klientų skaičius.

1. Apskaičiuotas viso laikotarpio bendras (su linijomis turinčiomis SGT ir be) SAIDI – 123,32.
2. Apskaičiuotas viso laikotarpio atjungimų su linijomis neturinčiomis SGT SAIDI – 122,16.
3. Apskaičiuotas viso laikotarpio SAIDI su linijomis turinčiomis SGT, vartotojams kurie buvo prijungti per SGT veikimą – 2,31.
4. Apskaičiuotas viso laikotarpio SAIDI su linijomis turinčiomis SGT, bet veikimo metu neprijungus vartotojų – 159,34.
5. Apskaičiuotas viso laikotarpio atjungimų SAIFI – 0,0079.
6. Apskaičiuotas viso laikotarpio SAIFI su linijomis turinčiomis save gydantį tinklą – 0,001.

SAIFI rodikliai gauti neįprastai maži, nes skirstomojo tinklo gedimo duomenų rinkinyje atjungimai nevertinami etapais, atjungimas įvertinamas kaip vienas vienetas, nesvarbu, kad buvo vykdomas etapais tokiu būdu vertinant SAIFI žymiai sumažėja, nes sumažėja atjungimų skaičius.

Pagal atliktus skaičiavimus aiškiai matyti, kad SAIDI rodiklis yra labai ženkliai geresnis, kai linijos yra automatizuotos ir turi save gydantį tinklą. SAIFI rodikliai didelio skirtumo neturėjo dėl to, kad atliekant perjungimus tinkle perjungimų skaičius lieka panašus atliekant dispečeriui ar SGT.

Atliktas palyginamasis vertinimas FLIR suveikimų ir likusių skirstomojo tinklo gedimų (22 pav.). Pagal šią diagramą matyti, kad FLIR suveikimų skirstomajame tinkle yra tik labai nedidelė dalis, nes skirstomojo tinklo didžioji dalis nėra pasiekusi tokio automatizavimo lygio, kad daugumoje linijų būtų galima įdiegti SGT.



22 pav. FLIR suveikimų ir likusių gedimų palyginamoji diagrama


Atlikus skirstomojo tinklo ir FLIR duomenų analizę galima teigti analizuojamame tinkle SGT sistema FLIR turi didelę potencialą, nes rodikliai akivaizdžiai yra geresni linijose su SGT, tačiau reikėtų pastebėti, kad SGT įdiegimas į likusias linijas yra procesas, kuris reikalauja investicijų ir laiko, nes reikia naujinti įrangą ją kalibruoti ir galiausiai testuoti, kad būtų užtikrintas tikslus SGT veikimas.

4.8.3. Orų istorinių duomenų analizė

Siekiant užtikrinti naudojamų duomenų teisingumą buvo atlikta oro istorinių duomenų analizė ir validacija duomenų validacija. Kadangi save gydančio tinklo ir tinklo gedimų istoriniai duomenys yra už 1,5 metų laikotarpį (2021.01.01 – 2022.06.30), reikia patikrinti bendras orų tendencijas ir nustatyti ar būtent minėtasis laikotarpis yra tinkamas šio tyrimo modelio sudarymui. Oro duomenys gali būti labai nepastovūs ir svyruoti skirtingais intervalais. Siekiant užtikrinti, kad modelis būtų atsparus šiems svyravimams, duomenų rinkinys turėtų apimti pakankamai ilgą laikotarpį, kad galėtų atspindėti šią nepastovumą. Modeliai, skirti numatyti orų prognozes, remiasi principu, kad praeities duomenys gali padėti numatyti ateities tendencijas. Tačiau tam, kad šis principas veiktų gerai, reikia, kad duomenų rinkinyje būtų pakankamai įvairumo. Kai kurios oro sąlygos gali pasitaikyti retai, todėl svarbu, kad jūsų pasirinktas laikotarpis būtų pakankamai ilgas ir reprezentatyvus, kad galėtų aprėpti šiuos retus įvykius.


Orų istoriniai duomenų validacija atlikta pagal pagrindinius kintamuosius (vėjas, krituliai, temperatūra), kurie turi įtakos skirstomojo tinklo gedimams. Tyrime suskaičiuoti metinės ir vidutinės pagrindinių kintamųjų vertės, kad būtų galima nustatyti ar šio darbo tiriamas periodas yra reprezentatyvus atspindėti Lietuvos orų tendencijas. Duomenų atvaizdavimui pasirinktos stulpelinės diagramos, nes jos geriausiai atspindi kiekvienų metų kintamųjų vertes, tokiu būdu patikrinama ar šis laikotarpis yra reprezentatyvus ir ar jame nėra jokių specifinių ypatumų, kurie gali iškreipti jūsų modelio mokymą.

Sudarius 10 metų periodo metinių kritulių kiekių diagramą matyti (23 pav.), kad kritulių kiekis kinta 8000 – 12000 mm intervale. Intervalo apatinė ir viršutinė reikšmė skiriasi reikšminga apie 4000 mm, tad galima teigti, kad duomenų variacija yra pakankamai didelė ir naudinga modeliui. 2021 ir 2022 metai, tai pat varijuoja tik ne tokiam dideliame intervale, tad galima teigti, kad šio kintamojo atžvilgiu laikotarpis tyrimui yra tinkamas.




23 pav. Metinių kritulių kiekio pagal metus diagrama

Sudarius vidutinio vėjo greičio, gūsių diagramą matyti, kad vidutinis metinio vėjo greitis svyruoja nedaug 3,75 – 4 m/s (10 metrų aukštyje) intervale per visą nagrinėjamą laikotarpį, tai rodo, kad vėjo sąlygos buvo gana stabilios ir nauda iš šių duomenų yra mažesnei dėl šios priežasties vidutinė vėjo gūsių diagrama buvo pridėta ir sudaryta bendrą diagramą (24 pav), kad susidaryti geresnį vaizdą ir pasiekti didesnę duomenų variaciją. Didesnė vėjo gūsių variacija šiame tyrime padės geriau atlikti modeliavimą ir prognozavimą, nes sukurs tikslesnį vaizdą apie vėjo elgseną ir jo dinamiką. Šioje diagramoje matyti, kad vėjo gūsių variacijos intervalų vertės, palyginus su vėjo greičio nėra didelės, bet jeigu lyginant tik vėjo gūsių greitį matyti, kad vidutinės duomenų vertės varijuoja žymiai daugiau nei vidutinis vėjo greitis. Atsižvelgus į diagramos pateikiama informaciją apie duomenis galima teigti, kad tiriamas laikotarpis yra reprezentatyvus.



24 pav. Vidutinio vėjo ir gūsių greičio diagrama pagal metus


Sudarius vidutinės metinės temperatūros diagramą (25 pav.) matyti, kad vidutinė metinė temperatūra nuo 6,3 – 8,6 °C. Toks svyravimas atsižvelgiant, kad čia matuojama tik Lietuvos temperatūra nelaikomas dideliu, tačiau turint visus duomenis apie orą padeda lengviau susidaryti įspūdį apie orą, nes skirtingų orų parametrų visuma ir nulemia skirstomojo tinklo gedimus.



25 pav. Vidutinė metinė temperatūra pagal metus


Duomenų kokybės nustatymui buvo sudaryta smuiko diagrama už visą laikotarpį (26 pav.) kuri atspindi duomenų stebėjimą skirtinguose taškuose, tam kad įsitikinti ar duomenys yra teisingai pagal geografines vietas.

Ši diagrama leidžia vizualizuoti duomenų pasiskirstymą ir gali padėti identifikuoti ar yra kokių nors anomalijų ar atskirų grupių duomenyse. Jis taip pat parodo ar duomenys yra simetriški, ar yra linkę į kurią nors pusę, ir ar yra aukštos ar žemos reikšmės, kurios gali trukdyti modeliui. Kiekvieno smuiko plotis atspindi temperatūros pasiskirstymo tankį toje vietovėje - platesnė plotis reiškia daugiau stebėjimų esant tam tikrai temperatūrai. Pagal diagramą matyti, kad orų istorinių duomenų rinkinio



26 pav. Smuiko grafikas temperatūros duomenų simetriškumui nustatyti

duomenų stebėjimų duomenys yra kokybiški, nes smuiko pločiai yra beveik simetriški ir didžiausia imtis yra netoli vidutinės metinės temperatūrų reikšmių. Palygimui, kad įsitikinti, kad ši tendencija vienoda su tiriamu laikotarpiu smuiko diagrama sudaryta ir save gydančio tinklo veikimo laikotarpiu.




27 pav. Smuiko grafikas temperatūros duomenų simetriškumui nustatyti

Palyginus abi diagramas matyti, kad duomenų kokybė abiem laikotarpiais yra gera. Analogiškos diagramos buvo sudarytos ir kitiems kintamiesiems.

Atlikus duomenų validaciją už abu laikotarpius galima teigti, kad duomenys yra tinkami, jų kokybė yra gera ir jų yra pakankamai daug.

4.8.4. Hierarchinis klasterizavimas



28 pav. Orų istorinių duomenų klasterizavimas

Atliekant duomenų analizę buvo panaudota hierarchinis klasterizavimas artumų matricai sudaryti. Hierarchinis klasterizavimas yra metodas, kuris ieško panašumų tarp duomenų taškų, siekiant sujungti juos į grupes, arba klasterius. Klasterizavimas leidžia suprasti ir atskleisti duomenų struktūrą, padeda identifikuoti modelio formavimo strategijas ir gali būti naudingas vizualizuojant duomenis. Šiame modelyje hierarchinis klasterizavimas yra naudojamas orų istoriniams duomenims, kurie yra svarbūs šiam tyrimui. Šie duomenys turi daug matmenų, todėl klasterizavimas padės suprasti, kaip skirtingi orų rodikliai yra susiję tarpusavyje ir su save gydančio tinklo veikimais. Atlikus hierarchinį klasterizavimą rezultatai atvaizduojami dendrograma. Dendrogramoje (28 pav.) kiekvienas duomenų taškas yra atvaizduojamas kaip horizontali linija. Horizontalios linijos yra sujungtos vertikaliosiomis linijomis, kurios rodo, kaip duomenų taškai yra sujungti į klasterius. Kuo mažesnis yra vertikaliosios linijos ilgis, tuo labiau duomenų taškai yra panašūs vienas į kitą. Kuo ilgesnė yra vertikalioji linija, tuo labiau skiriasi duomenų taškai, kurie yra sujungti per šią liniją.

Dendrogramoje matyti, kad duomenų rinkinys turi keturis skirtingus, bet viduje susijusius segmentus. Kiekvienas iš šių segmentų turėtų turėti panašius ypatumus, kurie išskiria jį iš kitų segmentų. Atlikus dendrogramos klasterizavimo analizę matyti, kad išskiriami šie segmentai:

1. Oro sąlygos.
2. Oro sąlygų intensyvumas.
3. Vietovės.
4. Paros laikas.

Atstumai šioje artumų matricoje yra matuojami Euklidiniu atstumo matavimu, kuris yra užrašomas taip:

$$d(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + (x_3 - y_3)^2}; \quad (12)$$

Šiame modelyje buvo naudojamas metodas, kuris gražina hierarchinio klasterizavimo rezultatą, kuris vadinamas artumų matrica. Ši matricą yra $N \times 4$, kurioje N yra duomenų rinkinio eilučių skaičius:

Šio metodo funkcija apibrėžiama taip:

$$W(C) = \sum (x \in C) (x - \mu(C))^2; \quad (13)$$

Čia:

$W(C)$ – kvadratinis atstumas nuo kiekvieno taško iki klasterio centro,

C – klasteris

x – taškas klasterio viduje

μC – klasterio centro taškas, apibrėžtas kaip vidurkis visų klasterio taškų

4.8.5. Duomenų rinkinio sudarymas


Duomenų rinkinys mašiniame mokyme yra struktūruota duomenų bazė, skirta apmokyti, validuoti ir testuoti mašininis mokymosi modelius. Duomenų rinkiniai yra svarbūs mašininio mokymosi procese, nes jie yra modelio mokymosi pagrindas. Duomenų rinkiniai gali būti įvairių tipų ir formatų, įskaitant teksto, nuotraukų, garso ar video. Pagal uždavinį ir tipą, mašininis mokymasis gali naudoti šiuos duomenų rinkinius:

- mokymo duomenų rinkinys;
- validavimo duomenų rinkinys;
- testavimo duomenų rinkinys.

Šiam tiriamajame darbe duomenų rinkinio sudarymas atliekamas iš duomenų rinkinių:

- skirstomojo tinklo atsijungimų duomenų bazė;
- save gydančio tinklo veikimo duomenų bazė;
- orų istoriniai duomenys.

Kiekvienas duomenų rinkinys turi įvairius kintamuosius, tarp duomenų rinkinių yra kintamųjų, kurie sutampa, tokiu būdu galima lengviau integruoti duomenų bazes į vieną duomenų rinkinį, kad atlikti jų bendrą analizę. Žemiau lentelėse pateikiam tiriamojo darbo duomenų bazių visi kintamieji ir jų aprašymai. Žemiau paveikslėlyje pateikiama duomenų rinkinio sudarymo schema. Prieduose lentelė



29 pav. Duomenų rinkinio sudarymo schema

sudaryti duomenų rinkiniai, pagal kuriuos galima patyti kaip yra susieti duomenis iš skirtingų duomenų rinkinių.

4.8.6. Kintamųjų atranka

Kintamųjų atranka yra svarbus žingsnis modeliavime ir duomenų analizėje, nes tai padeda sumažinti modelio sudėtingumą, pagerinti modelio interpretaciją ir padėti išvengti modelio persimokymo (angl. *overfitting*). Pagal turimą istorinių oro duomenų masyvą ir save gydančio tinklo suveikimų istorinius duomenis buvo ekspertiškai įvertinta, kurie kintamieji bus naudojami modelyje. Skirstomojo tinklo gedimams didžiausią įtaką turi:

- stiprūs vėjai: stiprus vėjas gali išsiūbuoti - nutraukti laidus išvartyti medžius, kurie gali užgriūti ant elektros linijų;
- sniegas ir šaltis: sniegas, ypač dideliais kiekiais, gali susikaupti ant šalia esančių medžių, šakoms lūžtant nutraukiami oro linijų laidai, šaltis sukelia medžiagų traukimąsi esant staigiems temperatūros pokyčiams, toks poveikis yra žalingas.
- ledas: ledas gali aptraukti elektros linijas ir stulpus, padidindamas jų svorį ir galimybę lūžti, ledas gali sukelti medžių šakų lūžimus, kurios gali užgriūti ant elektros linijų.
- žaibai: žaibai yra vienas iš didžiausių elektros tinklo gedimų priežasčių, nes jie gali tiesiogiai sugadinti elektros linijas, transformatorius ar kitą įrangą.
- sausros: ilgalaikės sausros gali pakenkti elektros tinklo infrastruktūrai, pavyzdžiui, dėl dirvožemio susitraukimo gali susidaryti plyšiai, kurie gali paveikti pamatus, ant kurių yra pastatyti elektros stulpai.

Pagal šias prielaidas išskiriami pagrindiniai kintamieji, kurie bus naudojami modelyje, kad būtų atlikta kuo tikslesnė prognozė:


- vėjas;
- krituliai;
- temperatūra.

Nusistačius oro istorinių kintamuosius sudaroma koreliacijos matrica, kad patikrinti kaip koreliuoja oro istoriniai duomenys su save gydančio tinklo veikimo duomenimis. Tokiu būdu bus matomas išsamesnis vaizdas iš sudaryto duomenų rinkinio. Sudarius koreliacijos matricą (30 pav.) matyti, kad daugiausiai tarpusavyje koreliuojantys kintamieji yra apibūdinantys oro sąlygas.

	Vartotojai	Atjungimo trukmė	Atjungtų vartotojų skaičius	FLIR prijungtų vartotojų skaičius	Data	Temperatūra	Drėgmė	Vėjo greitis	Vėjo kampas	Vėjo gūšiai	Lietus	Sniegas	Oro intesyvumo indeksas	FLIR veikimo laikas
Vartotojai	1,00	0,92	0,75	0,06	-0,01	0,07	-0,10	-0,12	-0,03	0,04	-0,09	0,01	0,09	0,51
Atjungimo trukmė	0,92	1,00	0,79	0,06	-0,01	0,07	-0,09	-0,12	-0,04	0,00	-0,08	0,00	0,09	0,54
Atjungtų vartotojų skaičius	0,75	0,79	1,00	0,14	-0,07	0,01	-0,04	0,03	0,03	0,02	-0,03	0,03	0,05	0,45
FLIR prijungtų vartotojų skaičius	0,06	0,06	0,14	1,00	-0,02	-0,08	-0,07	0,19	0,07	0,01	0,12	-0,08	-0,02	0,18
Data	-0,01	-0,01	-0,07	-0,02	1,00	0,31	-0,39	-0,31	-0,21	-0,01	0,09	-0,37	0,08	-0,09
Temperatūra	0,07	0,07	0,01	-0,08	0,31	1,00	-0,46	-0,54	-0,19	-0,07	-0,19	-0,48	0,36	0,04
Drėgmė	-0,10	-0,09	-0,04	-0,07	-0,39	-0,46	1,00	0,12	0,05	-0,15	0,19	0,35	-0,33	-0,20
Vėjo greitis	-0,12	-0,12	0,03	0,19	-0,31	-0,54	0,12	1,00	0,36	0,18	0,09	0,26	-0,30	-0,01
Vėjo kampas	-0,03	-0,04	0,03	0,07	-0,21	-0,19	0,05	0,36	1,00	-0,02	-0,01	0,22	-0,02	0,03
Vėjo gūšiai	0,04	0,00	0,02	0,01	-0,01	-0,07	-0,15	0,18	-0,02	1,00	0,04	-0,03	-0,28	0,07
Lietus	-0,09	-0,08	-0,03	0,12	0,09	-0,19	0,19	0,09	-0,01	0,04	1,00	-0,14	-0,47	-0,06
Sniegas	0,01	0,00	0,03	-0,08	-0,37	-0,48	0,35	0,26	0,22	-0,03	-0,14	1,00	-0,23	-0,01
Oro intesyvumo indeksas	0,09	0,09	0,05	-0,02	0,08	0,36	-0,33	-0,30	-0,02	-0,28	-0,47	-0,23	1,00	0,05
FLIR veikimo laikas	0,51	0,54	0,45	0,18	-0,09	0,04	-0,20	-0,01	0,03	0,07	-0,06	-0,01	0,05	1,00

30 pav. Duomenų rinkinio koreliacijos matrica

Kintamųjų stulpeliai, kurie bus prognozuojami šiame darbe yra pažymėti. Pagal koreliacijos matricą matyti, kad stipresnė ($>0,5$) koreliacija yra tarp duomenų, kurie yra iš to pačio duomenų rinkinio, tai reiškia, kad SGT ir orų duomenys koreliuoja labai silpnai, tai leidžia teigti, kad SGT veikimas nėra tiesiogiai priklausomas nuo oro sąlygų. Dėl šios priežasties, kad susidaryti aiškų vaizdą yra sudaroma antra koreliacijos matrica iš viso tinklo gedimų, kuri apima didesnę kiekį duomenų (apie 83 000 eilučių). Tokiu būdu bus matyti ar didesnė duomenų imtis rodo panašius koreliacijos koeficientus.



31 pav. Porinių diagramų rinkinys

Pagal diagramą matyti, kad stiprūs ryšiai yra tarp tų kintamųjų oro istorinių duomenų kintamųjų, tačiau diagramoje galima išžvelgti ir silpnų ryšių tarp SGT ir orų istorinių duomenų kintamųjų, bet stiprių eksponentinių pasiskirstymo dėsnų tarp SGT ir orų duomenų nėra.

5. Rezultatai

5.1. Atjungtų vartotojų skaičiaus prognozavimo modelių rezultatai

Atliktų modelių testavimo rezultatai (vidutinės reikšmės) pateikiami 2-oje lentelėje, o pilni testavimo grafikai priede.

3 lentelė Modelių testavimo rezultatai

Modelis	R^2 (testavimas)	MSE (testavimas)	R^2 (mokymasis)	MSE (mokymasis)
Tiesinė regresija	0,767	0,178	0,855	0,145
Paprastasis neuroninis tinklas	0,655	0,281	0,997	0,00294
Sudėtingasis neuroninis tinklas	0,923	0,0494	0,985	0,1147


Pagal tiesinės regresijos modelio rezultatus matyti, kad modelis vidutiniškai paaiškina 76,7% duomenų variacijos. R^2 , rodo, kad modelis gana gerai prognozuoja mokymo duomenis. Tačiau kryžminio patikrinimo ir mokymo rezultatų skirtumas gali reikšti, kad modelis galimai yra persimokęs, todėl gali blogai prognozuoti naujus duomenis.

Pagal paprastojo neuroninio tinklo modelio rezultatus matyti, kad modelis puikiai prognozuoja mokymo duomenis, tačiau blogai prognozuoja naujus duomenis, modelis yra persimokęs.

Pagal sudėtingojo neuroninio tinklo modelio rezultatus matyti, kad modelis gerai prognozuoja tiek mokymo, tiek naujus duomenis. Skirtumas tarp mokymo ir kryžminio patikrinimo rezultatų yra mažesnis nei kituose modeliuose, todėl DNN modelis yra mažiau permokytas ir gali būti geriausias pasirinkimas šiems duomenims. Įvertinant visus modelius, neuroninio tinklo modelis atrodo kaip geriausias modelis šiam duomenų rinkiniui, nes jis turi mažiausią MSE ir didžiausią R^2 reikšmes tiek mokymo, tiek testavimo duomenims. Be to, jis taip pat atrodo mažiau permokytas nei kiti du modeliai.

Pateikiamos modelių tikrųjų ir prognozuojamų reikšmių diagramos (32 pav.).

Tikros ir prognozuojamos reikšmės (atjungtų vartotojų skaičius)



32 pav. Tikros ir prognozuojamos reikšmės diagrama

Pagal diagramas matyti, kad sudėtingojo neuroninio tinklo modelis geriau prognozuoja naujas reikšmes, nei kiti modeliai, bet kai kuriuose segmentuose netikslumų yra.

5.2. FLIR veikimo laiko prognozavimo modelių rezultatai

Atliktų modelių testavimo rezultatai (vidutinės reikšmės) pateikiami 3-ioje lentelėje, o pilni testavimo grafikai priede.

4 lentelė Modelių testavimo rezultatai

Modelis	R^2 (testavimas)	MSE (testavimas)	R^2 (mokymasis)	MSE (mokymasis)
Tiesinė regresija	-0,071	0,745	0,349	0,650
Paprastasis neuroninis tinklas	-0,536	0,031	1,03	0,031
Sudėtingasis neuroninis tinklas	0,567	0,176	0,951	0,050


Pagal tiesinės regresijos modelio testavimo rezultatus matyti, kad šis modelis nesugeba gerai prognozuoti duomenų, nes mokymosi MSE ir testavimo MSE yra didelė. R^2 reikšmės, rodo kad modelis negeba paaiškinti didžios dalies duomenų rinkinio duomenų variacijos. Neigiama vidutinė R^2 rodo, kad modelis gali būti per daug sudėtingas ir modelio suderinamumas su duomenis yra nepakankamas, ai pat gali signalizuoti jog modelio pasirinkimas šiems duomenims yra netinkamas.

Pagal paprastojo neuroninio tinklo testavimo rezultatus matyti, sugeba gerai prognozuoti mokymosi duomenis labai gerai, nes MSE ir R^2 metrikų vertės yra labai geros. Tačiau pagal testavimo duomenis matyti, kad modelis labai gerai išmoksta treniravimo duomenis, bet nesugeba gerai prognozuoti naujų duomenų. Šis modelis kaip ir tiesinės regresijos modelis turi neigiamą vidutinę R^2 reikšmę.

Pagal sudėtingojo neuroninio tinklo testavimo rezultatus matyti, modelis yra geriausias iš visų. Vidutinis MSE yra geras tiek testavimo tiek mokymosi duomenyse. R^2 reikšmės rodo, kad modelis gerai atitinka treniravimo duomenis (56,7% priklausomosios kintamųjų variacijos yra paaiškinamos modelio), tačiau jis taip pat geba gerai prognozuoti testavimo duomenis (95,1% priklausomosios kintamųjų variacijos).

Apibendrinant matyti, kad sudėtingojo neuroninio tinklo modelis šio kintamojo prognozavime pasirodo geriau, tačiau reiktų atkreipti dėmesį į didelę R^2 skirtumą, tai gali rodyti, kad modelis yra persimokęs ir ateityje gali pateikti netinkamas prognozes. Pateikiamos modelių tikrųjų ir prognozuojamų reikšmių diagramos (33 pav.).

Tikros ir prognozuojamos reikšmės (FLIR veikimo laikas)



33 pav. Tikros ir prognozuojamos reikšmės diagrama

Pagal diagramas matyti, kad sudėtingojo neuroninio tinklo modelis geriau prognozuoja naujas reikšmės, nei kiti modeliai, bet pagal taškų sklaidą matyti, kad FLIR veikimo laikas nėra taip tiksliai prognozuojamas kaip atjungtų vartotojų skaičius.

5.3. Prijungtų vartotojų prognozavimo modelių rezultatai

Atliktų modelių testavimo rezultatai (vidutinės reikšmės) pateikiami 4-ioje lentelėje, o pilni testavimo grafikai priede.

5 lentelė Modelių testavimo rezultatai

Modelis	R^2 (testavimas)	MSE (testavimas)	R^2 (mokymasis)	MSE (mokymasis)
Tiesinė regresija	0,0204	0,474	0,592	0,408
Paprastasis neuroninis tinklas	-0,139	0,734	0,01	0,990
Sudėtingasis neuroninis tinklas	0,792	0,098	0,973	0,028


Pagal tiesinės regresijos modelio testavimo rezultatus matyti, kad, kad modelis netiksliai prognozuoja duomenis, nes R^2 reikšmė yra maža. Tačiau reikia atsižvelgti į tai, kad vienoje iš kryžminės validacijos iteracijų R^2 yra labai neigiamas (-0,43), kas gali rodyti, kad modelis labai blogai prognozuoja toje aibėje. Mokymo metu MSE vidurkis yra 0,408, o R^2 vidurkis yra 0,592. Tai rodo, kad modelis geriau atitinka mokymo duomenis nei testavimo duomenis, kas gali reikšti persimokymą.

Pagal paprastojo neuroninio modelio testavimo rezultatus matyti, kad MSE yra 0,734, o vidutinis R^2 yra -0,139. Tai rodo, kad šis modelis yra prastesnis už tiesinės regresijos modelį prognozuojant testavimo duomenis. Mokymo metu MSE vidurkis yra 0,01, o R^2 vidurkis yra 0,990. Tai rodo, kad modelis puikiai atitinka mokymo duomenis, tačiau prastai prognozuoja testavimo duomenis. Tai gali rodyti labai stiprų persimokymą. Šis modelis kaip ir tiesinės regresijos modelis nėra tinkamas prognozuoti tokio tipo duomenis.

Pagal sudėtingojo neuroninio modelio testavimo rezultatus matyti, kad MSE yra 0,098, o vidutinis R^2 yra 0,792. Mokymo metu MSE vidurkis yra 0,028, o R^2 vidurkis yra 0,973. Tai rodo, kad modelis gerai atitinka mokymo duomenis ir yra geriausias iš trijų modelių mokymo duomenų atžvilgiu.

Pateikiamos modelių tikrųjų ir prognozuojamų reikšmių diagramos.

Tikros ir prognozuojamos reikšmės (Prijungtų vartotojų skaičius)



34 pav. Tikros ir prognozuojamos reikšmės diagrama

Pagal diagramas matyti, kad sudėtingojo neuroninio tinklo modelis žymiai geriau prognozuoja naujas reikšmes, netikslumų yra tačiau jie nedideli.

5.4. Modelių optimizavimas

Kadangi sudėtingojo neuroninio tinklo modelis parodė geriausius rezultatus jam buvo atliktas hiperparametrų optimizavimas. Pirmų žingsniu buvo testuojama, kaip modelis prognozuos kai kryžminio patikrinimo metu bus naudojama 10 foldų. Foldų skaičius kryžminio patikrinimo metu gali turėti įtakos modelio įvertinimui. Daugiau foldų gali suteikti tikslesnį modelio įvertinimą, tačiau tai gali būti brangesnė tiek laiko, tiek atminties prasme. Tuo tarpu mažesnis foldų skaičius gali suteikti mažiau stabilų modelio įvertinimą, bet būti greitesnis ir naudoti mažiau atminties. Kai turime mažesnę duomenų rinkinį, foldų skaičiaus sumažinimas nuo 20 iki 10 gali būti naudingas dėl kelių priežasčių:

1. Mažesnis skaidymo klaidų kiekis: Su mažesniu duomenų rinkiniu yra didesnė tikimybė, kad folduose atsitiktinai gali būti mažiau įvairių duomenų. Tai gali padidinti klaidų kiekį ir daryti didesnę įtaką modelio įvertinimui. Sumažinus foldų skaičių iki 10, turime didesnę tikimybę, kad kiekviename folde bus daugiau įvairių duomenų ir modelio įvertinimas gali būti patikimesnis.
2. Greitesnis modelio įvertinimas: Su mažesniu duomenų rinkiniu kiekvieno foldo mokymas ir testavimas gali užtrukti mažiau laiko. Mažesnis foldų skaičius sumažina bendrą patikrinimo laiką, o tai gali būti naudinga, jei turime laiko apribojimus arba dažnai atliekame hiperparametrų optimizaciją.
3. Optimaliausias foldų skaičius: Pasirinkimas tarp foldų skaičiaus yra subalansuotas procesas, kuriame turime apsvarstyti daugelį veiksnių, įskaitant duomenų rinkinio dydį, modelio kompleksumą ir turimus resursus. 10 foldų gali būti geriau pritaikytas mažesniai duomenų rinkiniui, kuris gali užtikrinti geresnį modelio įvertinimą.
4. Tačiau reikia paminėti, kad foldų skaičiaus pasirinkimas nėra absoliutas ir priklauso nuo konkrečios situacijos. Visada svarbu išbandyti ir stebėti, kaip foldų skaičius paveikia modelio veikimą, taip pat įvertinti kitus veiksnius, pvz., modelio stabilumą ir tikslumą, kai keičiame foldų skaičių.

Sumažinus foldų skaičių iki 10 modelio mokymasis pagreitės, nes mažesnis fold skaičius reiškia mažiau kryžminio validavimo iteracijų, bet tai gali turėti įtakos kitiems rezultatams dėl šios priežasties yra testuojami ir kiti hiperparametrai. Sekančiu žingsniu buvo panaudotas algoritmas, kuris ieško likusių pasirinktų hiperparametrų modelio prognozavimo reikšmės pagerinti. Gerinant parametrus siekiama sumažinti modelio persimokymą ir padidinti mokymosi tikslumą bei greitį, nekeičiant fold skaičiaus vertės. Geriausią parametrų derinį pasirinkti yra tikras iššūkis, nes tai sudėtingas procesas reikalaujantis atlikti daug iteracijų, o tai užima labai daug laiko. Toliau skyreliuose pateikiami visi rezultatai.

5.4.1. Modelių su kryžminio patikrinimo 10 foldų hiperparametru rezultatai

Atliktų modelių testavimo rezultatai (vidutinės reikšmės) pateikiami 5-ioje lentelėje, o pilni testavimo grafikai priede.

6 lentelė Modelių testavimo rezultatai (kryžminis patikrinimas su 10 foldų)

Modelis	R ² (testavimas)	MSE (testavimas)	R ² (mokymasis)	MSE (mokymasis)
Atjungtų vartotojų prognozavimas				
Tiesinė regresija	0,798	0,183	0,855	0,143
Paprastasis neuroninis tinklas	0,686	0,308	0,997	0,002
Sudėtingasis neuroninis tinklas	0,9172	0,068	0,980	0,019
FLIR suveikimo laiko prognozavimas				
Tiesinė regresija	0,111	0,77	0,352	0,646
Paprastasis neuroninis tinklas	-0,18	1,07	0,980	0,019
Sudėtingasis neuroninis tinklas	0,602	0,290	0,933	0,067
Prijungtų vartotojų prognozavimas				
Tiesinė regresija	0,389	0,491	0,593	0,405
Paprastasis neuroninis tinklas	-0,091	0,793	0,991	0,005
Sudėtingasis neuroninis tinklas	0,679	0,198	0,925	0,075

Apibendrinant rezultatus, galima teigti, kad sudėtingasis neuroninis tinklas pasižymi geriausiu prognozavimo tikslumu ir pritaikymu tiek testavimo, tiek mokymosi duomenims visose trijose prognozavimo užduotyse. Jis pasiekė aukščiausią R² rezultatą ir mažiausią rezultatą, rodydamas gerą duomenų variacijos paaiškinimą ir mažą skirtumą tarp prognozių ir tikrų reikšmių.

Tiesinė regresijos modelis pasižymi vidutiniu prognozavimo tikslumu, bet negali paaiškinti duomenų variacijos, kad galėtų efektyviai modeliuoti sudėtingesnes sąsajas tarp kintamųjų.

Paprastasis neuroninis tinklas pasižymi geru pritaikymu mokymosi duomenims, tačiau jis nėra pakankamai geras prognozuojant testavimo duomenis. Tai rodo galimą modelio persimokymą arba prastą tinklo suderinamumą su duomenų struktūra.

5.5. Modelių optimizavimas pagal likusius hiperparametrus

Atliekant iteracinį paieškos bandymą su algoritmu buvo testuojami šie parametrai: išmetimo, koeficientas (0,1, 0,2, 0,3) optimizavimo algoritmo parinkimas (Adam, SGD, RMSprop, Adagrad) epochų skaičius (50,100), paketų dydis (16, 32, 64). Atlikus bandymą nustatyti optimalūs parametrai pateikiami 5 – oje lentelėje.

7 lentelė Geriausiai hiperparametrai

Prognozuojamas kintamasis	Išmetimo koeficientas	Optimizavimo algoritmas	Epochų skaičius	Paketų dydis
Atjungtų vartotojų skaičius	0,1	RMSprop	100	16
FLIR veikimo laikas	0,2	Adam	50	16
FLIR prijungtų vartotojų skaičius	0,3	RMSprop	50	64

Nustačius geriausius parametrus buvo testuojami skirtingų kintamųjų modeliai, kad pamatyti rezultatus ir palyginti. Rezultatai pateikiami 6 – oje lentelėje o testavimo grafikai prieduose.

8 lentelė Modelių rezultatai

Modelis	R ² (testavimas)	MSE (testavimas)	R ² (mokymasis)	MSE (mokymasis)
Atjungtų vartotojų skaičius	0,949	0,032	0,988	0,015
FLIR veikimo laikas	0,529	0,209	0,932	0,067
FLIR prijungtų vartotojų skaičius	0,763	0,088	0,972	0,027

Atlikus modelių hiperparametrų optimizavimą galima teigi, kad pastebimai geresni rezultatai yra tarp yra matomi modeliuose kurie prognozavo atjungtų vartotojų skaičių, ir FLIR prijungtų vartotojų skaičių, o FLIR suveikimo laikas, duomenų variacijos atpažinime pablogėjo, bet pagerėjo reikšmių prognozėje.

5.6. Rodiklių prognozė

Atlikus išsamų vertinimą pagal gautus geriausius hiperparametrų reikšmės modeliai yra nustatomi atlikti prognozę 2022 07 01 – 2022 12 31 laikotarpiu, modelio įvestis prognozei yra tie patys duomenys iš orų istorinių duomenų, orų istorinių duomenų laikotarpis buvo apimtas iki 2023 01 01, o SGT veikimo duomenų rinkinys iki 2022 06 01, tad modelis neturi jokių SGT veikimo duomenų prognozuojama laikotarpiui. Rezultatai pateikiami 7 lentelėje reikšmės yra vidurkiai iš visų gautų reikšmių per vieno foldo iteracijas. Faktinės reikšmės pateikiamos pagal skirstomojo tinklo duomenis.

9 lentelė Prognozių ir faktinių reikšmių palyginimas

Rodiklis	Atjungtų vartotojų skaičius	FLIR suveikimo laikas	FLIR prijungtų vartotojų skaičius	SAIDI	SAIFI
Prognozės reikšmės	105935	143,7	56261	1,8	0,003
Faktinės reikšmės	95873	117,27	45821	1,77	0,001

Pagal rezultatus matyti, kad kaip ir planuota tiksliausiai buvo prognozuojamas atjungtų vartotojų skaičius.

6. SGT įtakos SAIDI SAIFI rodikliams vertinimas

Po atliktų prognozių ir gautų visų rezultatų galima palyginti ir įvertinti kokią įtaką daro SGT SAIDI SAIFI rodikliams. Duomenų analizės ir modeliavimo metu nustatyta:

- linijose su SGT prijungus vartotojus per SGT veikimą SAIDI sumažėjo 98%, nei linijose neturinčiose SGT;
- linijose su SGT, bet SGT suveikus ir neprijungus vartotojų SAIDI padidėjo 30,44%;
- pagal SAIFI vertes matyti, kad SGT gali sumažinti atsijungimų dažnumą;
- bendras SAIDI linijose matuojant kartu su SGT ir be SGT yra gana panašūs, nes SGT turi ribotą veikimą;
- DI prognozių rezultatai išlaiko tas pačias tendencijas abiejų rodiklių atžvilgiu, kaip ir faktinės reikšmės;
- remiantis prognozių ir faktinių reikšmių palygimu (9 lentelė), galima teigti, kad modelis prognozuoja labai kritiškai, nes modeliavimas ir prognozė atliekama su ribotu kiekiu duomenų dėl šios priežasties modelis gali būti ir ne toks tikslus.

Remiantis šiais rezultatais galima padaryti išvadą, kad SGT prisideda prie sumažinto atjungimų dažnio ir trukmės tokiu būdu gerindamas tinklo patikimumą. Tačiau reiktų pabrėžti, kad veikimo metu neprijungtų vartotojų skaičius žymiai padidina SAIDI rodiklį, tai yra indikacija, kad linijos su SGT turėtų turėti daugiau valdomų komutacinių įrenginių, kad tiksliau atidalinti pažeistą ruožą bei palikti minimalų kiekį vartotojų be EE.

Išvados

1. Paskutiniu metu skirstomojo tinklo operatoriai įvairiose pasaulio šalyse išbando arba jau naudoja SGT, jo nauda yra akivaizdžiai apčiuopiama, atliekami visokie tyrimai, kad ištirti ir pagerinti SGT veikimą.
2. Surinkus duomenis ir atlikus duomenų analizę, nustatyta, kad orų istoriniai duomenys neturi tiesioginės koreliacijos su save gydančio tinklo veikimu. Atlikus hierarchinį klasterizavimą nustatyta, kad orų istorinių duomenų rinkinys pasiskirsto į keturis segmentus: oro sąlygos, oro, sąlygų intensyvumas, vietovės, paros laikas. Taip pat nustatyta, kad duomenys, kurie bus panaudoti DI modeliams prognozėms, tinkamai reprezentuoja pasirinktą laikotarpį (2021 01 01 – 2022 06 30). Naudojantis skirstomojo tinklo gedimų duomenų rinkiniu apskaičiuoti ir palyginti SAIDI SAIFI rodikliai 2021.01.01 – 2022.06.30 laikotarpiu visiems tinklo gedimams ir linijoms, kuriose yra SGT.
3. Iš turimų duomenų rinkinių sukurtas atskiras duomenų rinkinys kuris panaudotas mašininame mokyme. Duomenų rinkinio dydis – 309 laiko eilutės, duomenų rinkinyje naudojami SGT veikimo ir orų istoriniais duomenys.
4. Šiame darbe buvo panaudoti, tiesinės regresijos, paprastojo neuroninio tinklo, sudėtingojo neuroninio tinklo dirbtinio intelekto algoritmai sprendžiant trys uždavinius: prognozuojant SGT veikimo laiką, prognozuojant skirstomojo tinklo atjungtų vartotojų skaičių linijose turinčiose SGT ir prognozuojant prijungtų vartotojų skaičių linijose turinčiose SGT. Visi modeliai įvertinti pagal kryžminio patikrinimo vidutinio determinacijos koeficiento ir vidutinės kvadratinės paklaidos metrikas. Pagal metrikų rezultatus nustatyta, kad sudėtingojo neuroninio tinklo labiausiai tinkamas atlikti prognozes su sudarytu duomenų rinkiniu. Šie modelių tikslumo skirtumai atsiranda dėl pačių modelių struktūros ir jų parametrų sudėtingumo bei pajėgumų. Tiesinės regresijos modelio rezultatai yra prastesni dėl nesugebėjimo interpretuoti duomenų, nes duomenyse, kaip ir buvo nustatyta, nebuvo reikalingų tiesinių ryšių tarp kintamųjų. Paprastojo neuronų tinklo modelio metrikos lyginant sudėtingojo neuroninio tinklo modeliu buvo prastesnės dėl struktūros ir sudėtingumo skirtumų, sudėtingasis turėjo daugiau paslėptų neuronų sluoksnių ir turėjo išmetimo koeficiento sluoksnį, kuris padeda išvengti persimokymo.
5. Panaudotas mašininio mokymo sudėtingojo neuroninio tinklo modelis, kuris 2022.07.01 – 2022.12.31 laikotarpiui išprognozavo: atsijungusių vartotojų skaičių linijose su SGT, prijungtų vartotojų skaičių su SGT ir SGT veikimo laiką. Pagal prognozes apskaičiuoti būsimi SAIDI ir SAIFI rodikliai. Prognozes palyginus su faktinėmis reikšmėmis, nustatyta, kad tiksliausiai atlikta prognozė - atsijungusių vartotojų skaičius.
6. Įvertinta SGT įtaka SAIDI SAIFI rodikliams, palyginus visus šio darbo rezultatus nustatyta, kad SGT įtaka SAIDI SAIFI rodikliams yra didelė, bet kol SGT turinčių linijų kiekis skirstomajame tinkle yra mažas, įtaka bendra bendriems rodikliams nėra žymi. Taip pat nustatyta, kad SGT linijas reiktų automatizuoti daugiau, nes po SGT veikimo likę neprijungti vartotojai didina SAIDI SAIFI rodiklius. Atliekant prognozes su DI modeliu tendencija rodikliams išliko ta pati. Lyginant faktinės rodiklių reikšmės su prognozėmis matyti, kad DI modelis prognozuoja su paklaida, nes prognozuoja su ribotu skaičiumi duomenų.

Literatūros sąrašas

1. JIANWEI Hou. A method of distribution network reconstruction based on self-healing technology. *The 9th China International conference on electricity distribution*. 2021 04 09 p.1 [žiūrėta 2023 m. rugsėjo 10 d.]. Prieiga per: doi: 10.1109/CICED50259.2021.9556720
2. AVAZOV Artur, SOBINOVA Liubov A.. Advanced distribution management. *ResearchGate* [interaktyvus]. 2016 02 23 p. 2 [žiūrėta 2022 m. birželio 14 d.]. Prieiga per: doi:10.1051/epjconf/201611001004
3. MARTINEZ Rodrigo, VARGAS Hector. Self- healing electric distribution networks: a review. *ResearchGate* [interaktyvus]. 2018 05 p. 2-4 [žiūrėta 2022 m. birželio 14 d.]. Prieiga per: doi:10.1109/ICCCC.2018.8390438
4. BANDZA Almantas, TERVYDIS Paulius, JANKAUSKIENĖ Rūta. The Performance Control in Power Distribution Grid. *ResearchGate* [interaktyvus]. 2019 10 p. 5-6. [žiūrėta 2022 m. birželio 14 d.]. Prieiga per internetą: https://www.researchgate.net/publication/351884723_The_Performance_Control_in_Power_Distribution_Grid
5. GUO Richard, VANKAYALA Vidya, QU Chris. Fault Location, Isolation and Service Restoration – Optimizing Field Operations for Utilities. *IEEE Xplore* [interaktyvus]. 2016 05 18 p. 34 [žiūrėta 2022 m. birželio 18 d.]. ISBN:978-1-4673-7615. Prieiga per internetą: doi: 10.1109/REPC.2016.14
6. AB „ESO”. 2021 m. metiniai finansiniai ir veiklos rezultatai. Vilnius, 2021
7. POUDEL Shiva, SHARMA Poorva, DUBEY Anamika. Advanced FLISR with Intentional Islanding Operations in an ADMS Environment Using GridAPPS-D. *IEEE Xplore* [interaktyvus]. 2020 06 18 p. 2-8 [žiūrėta 2022 m. gegužės 10 d.]. ISSN: 2169-3536. Prieiga per doi: 10.1109/ACCESS.2020.3003325
8. SHAVSAVAVRI Alireza, AMELI Amil, Lesani Hamid. A Healer Reinforcement Approach to Smart Grids by Improving Fault Location Function in FLISR. *IEEE Xplore* [interaktyvus]. 2013 01 [žiūrėta 2022 m. gegužės 10 d.]. ISBN:978-1-4799-2803-3. Prieiga per doi: 10.1109/EEEIC-2.2013.6737893
9. ABOELAZM Mohamamed, AZMY Mohamed, ELKADEEM Mohamed R.. Improving performance of underground MV distribution networks using distribution automation system: A case study. *ResearchGate* [interaktyvus]. April 2016 p. 3-11 [žiūrėta 2022 m. gegužės 10 d.]. Prieiga doi: 10.1016/j.asej.2016.04.004
10. MTHETHWA Fundiswa, VAN COLLER John. Investigation into the Issues Associated with Closing an Automated Normally Open (N/O) Point on Medium Voltage (MV) Networks Where Fault Location, Isolation and Service Restoration (FLISR) Tool Is Planned. *ResearchGate* [interaktyvus]. August 2018 p.106-107 [žiūrėta 2022 m. gegužės 10 d.]. Prieiga per doi: 10.1109/SEGE.2018.8499490
11. BOARDMAN Eathan. Advanced Applications in an Advanced Distribution Management System: Essentials for Implementation and Integration. *IEEE Xplore* [interaktyvus]. 2019 12 31 [žiūrėta 2022 m. gegužės 10 d.]. ISSN: 1540-7977. Prieiga per doi: 10.1109/MPE.2019.2947818
12. PARIKH Palak, VOLOH Ilia, MAHONY Michael. Fault location, isolation, and service restoration (FLISR) technique using IEC 61850 GOOSE. *IEEE Xplore* [interaktyvus]. July 2013 [žiūrėta 2022 m. gegužės 10 d.]. ISBN:978-1-4799-1303-9. Prieiga per: doi: 10.1109/PESMG.2013.6672862

13. ZHENG H., CHENG Y., GOU B. Impact of automatic switches on power distribution system reliability. *Science Direct, , Electric power Systems Research* 83 (2012) 51-57 [interaktyvus]. February 2012 [žiūrėta 2022 m. gegužės 10 d.]. Prieiga per: doi:10.1016/j.epsr.2011.08.018.
14. DONG Liu. JINSONG Liu, WANGSHUI Ling, ZHIBIN Li. Study on simulation and testing of FLISR. *IEEE Xplore* [interaktyvus]. May 2018 [žiūrėta 2023 m. rugsėjo 12 d.]. ISBN:978-1-4577-0066-8. Prieiga per internetą: <https://ieeexplore.ieee.org/document/5736124>
15. WADI Mohamed, SHOBOLE Abdufetah Abdela. Multiagent systems application for the smart grid protection. *Science Direct, Renewable and Sustainable Energy Reviews, Volume 149*, 111352 [interaktyvus]. October 2021 [žiūrėta 2023 m. rugsėjo 10 d.]. Prieiga per: doi: 10.1016/j.rser.2021.111352
16. LUNA Aivaro, RODRIGUEZ Pedro, MONADI Mehdi. Distributed FLISR algorithm for smart grid self-reconfiguration based on IEC61850. *IEEE Xplore* [interaktyvus]. 2015 01 22 [žiūrėta 2023 m. rugsėjo 14d.]. Prieiga per: DOI: 10.1109/ICRERA.2014.7016420
17. ARIF Anmar, MA Shansan, WANG Zhaoy. Dynamic Reconfiguration and Fault Isolation for a Self-Healing Distribution System. *IEEE Xplore* [interaktyvus]. 2018 08 22 [žiūrėta 2023 m. rugsėjo 10 d.]. ISBN:978-1-5386-5583-2. Prieiga per: doi: 10.1109/TDC.2018.844048122.
18. ZHOU Shu, Ai Lin, HU Yuanyuan, CAO Anting. Distribution network fault location method based on graphs theory and deep learning under charging load access. October 2021 [žiūrėta 2022 balandžio 22]. *IEEE Xplore* [interaktyvus]. Prieiga per: doi: 10.1109/EI252483.2021.9713574
19. LAGOS Dimitris, KORRES George. Microgrid Protection Against Internal Faults: Challenges in Islanded and Interconnected Operation. *IEEE Xplore* [interaktyvus]. 2021 04 19 [žiūrėta 2023 m. lapkričio 15 d.]. Prieiga per doi: 10.1109/MPE.2021.3057950.
20. ANSARAI Bnanen, SOROUDI Alireza. Restoration strategy in self-healing distribution network with distributed energy resources and flexible loads. *ResearchGate* [interaktyvus]. June 2016 p. 6 [žiūrėta 2023 m. rugsėjo 10 d.]. Prieiga per: doi: 10.1109/EEEIC.2016.7555776
21. GIUSTINA Davide Della, PONCI Ferdinanda, REPO Sami. Automation for smart grids in Europe 2018. *Science Direct* [interaktyvus]. Prieiga per: doi: 10.1016/B978-0-12-803128-5.00007-6
22. TORRES Bruno S., BORGES DA SILVA Luiz E. A study of distribution system self healing considering intelligent approaches. *ResearchGate* [interaktyvus]. December 2019 p. 8 [žiūrėta 2022 m. lapkričio 15 d.]. Prieiga per: doi: 10.1109/ISAP48318.2019.9065972
23. WAQUR Asad, HUSSAIN Muntazir, KHAN Sohaib Ali. Digital Twin for Advanced Automation of Future Smart Grid. *ResearchGate* [interaktyvus]. January 2023 p. 2 8 [žiūrėta 2023 m. sausio 15 d.]. Prieiga per: doi: 10.1109/ICAISC56366.2023.10085428

Informacijos šaltinių sąrašas

1. *Orų istorinių duomenų šaltinis*: <https://openweathermap.org/>
2. *SCADA Explained*, [žiūrėta 2022 m. gegužės 10 d.]. Prieiga per internetą: <https://www.electricaltechnology.org/2015/09/SCADA-systems-for-electrical-distribution.html>
3. *General Electric, Digital Transformation: The Benefits of a SCADA to ADMS Evolution* [žiūrėta 2022 m. gegužės 10 d.]. Prieiga per internetą: <https://www.ge.com/digital/lp/digital-transformation-benefits-SCADA-ADMS-evolution>
4. NAVICKAS A. *Elektros energetikos sistemų patikimumas*. Kaunas. Technologija 2007.

Priedai

1 priedas. Duomenų kintamųjų suvestinė

Skirstomojo tinklo atsijungimų duomenų rinkinio kintamųjų lentelė

Kintamasis	Aprašymas	Vienetai
Unikalus atsijungimo ID	Atsijungimo metu priskiriamas unikalus ID.	-
Atjungimo data ir laikas	Atsijungimo pradžios laikas	-
Ijungimo data ir laikas	Laikas kada buvo prijungti vartotojai	-
Atsijungimo trukmė	Laikas per kurį buvo pašalintas gedimas.	-
Atjungtų vartotojų skaičius	Atjungtų vartotojų skaičius po atsijungimo	-
Regionas	Lietuvos regionas	-
Skyrius (rajonas)	Regiono skyrius	-

Save gydančio tinklo veikimo duomenų rinkinio kintamųjų lentelė

Kintamasis	Aprašymas	Vienetai
Unikalus atjungimo numeris	Atsijungimo metu priskiriamas unikalus ID.	-
Save gydančio tinklo veikimo starto data ir laikas	Atsijungimo pradžia, programos veikimo pradžia	-
Save gydančio tinklo veikimo pabaigos data ir laikas	Atsijungimo pabaiga, programos veikimo pradžia	-
Atjungtų vartotojų skaičius	Atjungtų vartotojų skaičius po atsijungimo	-
Prijungtų vartotojų skaičius	Prijungtų vartotojų skaičius po programos veikimo	-
Regionas	Lietuvos regionas	-
Skyrius (rajonas)	Regiono skyrius	-

Orų istoriniai duomenų rinkinio kintamųjų lentelė


Kintamasis	Aprašymas	Vienetai
Data ir tikslus laikas		
Regionas		
Rajonas		
Temperatūra		°C
Vėjo greitis		m/s
Vėjo gūsiai		m/s
Vėjo kryptis		laipsniai
Vėjo aukštis		m
Atmosferos slėgis		hPa
Lietus per paskutinę valandą		mm
Sniegas per paskutinę valandą		mm
Drėgmė		%

Duomenų rinkinių sutampančių kintamųjų lentelė


	Skirstomojo tinklo atsijungimų duomenų bazė	Save gydančio tinklo veikimo duomenų bazė	Orų istoriniai duomenys
Unikalus atsijungimo ID	+	+	
Atjungimo data ir laikas	+		
Ijungimo data ir laikas	+		
Save gydančio tinklo veikimo starto data ir laikas		+	
Save gydančio tinklo veikimo pabaigos data ir laikas		+	
Atjungtų vartotojų skaičius		+	
Prijungtų vartotojų skaičius		+	
Regionas	+	+	+
Skyrius (rajonas)	+	+	+
Data ir tikslus laikas			+

2 priedas. Atjungtų vartotojų skaičiaus prognozavimo modelių rezultatų grafikai


Kryžminio patikrinimo vidutinė kvadratinė paklaida pagal fold numerį
(Atjungtų vartotojų skaičius)




Kryžminio patikrinimo vidutinis determinacijos koeficientas didėjant fold kiekiui
(Atjungtų vartotojų skaičius)



Kryžminio patikrinimo vidutinė kvadratinė paklaida su mokymo duomenimis pagal fold numerį
(Atjungtų vartotojų skaičius)




Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims didėjant fold kiekiui
(Atjungtų vartotojų skaičius)




3 priedas. FLIR veikimo trukmės prognozavimo modelių rezultatų grafikai


Kryžminio patikrinimo vidutinė kvadratinė paklaida pagal fold numerį
(FLIR veikimo laikas)




Kryžminio patikrinimo vidutinis determinacijos koeficientas didėjant fold kiekiui
(FLIR veikimo laikas)



Kryžminio patikrinimo vidutinė kvadratinė paklaida mokymo duomenims pagal fold numerį
(FLIR veikimo laikas)




Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims didėjant fold kiekiui
(FLIR veikimo laikas)




4 priedas. Prijungtų vartotojų skaičiaus prognozavimo modelių rezultatų grafikai


Kryžminio patikrinimo vidutinė kvadratinė paklaida pagal fold numerį
(Prijungtų vartotojų skaičius)




Kryžminio patikrinimo vidutinis determinacijos koeficientas didėjant fold kiekiui
(Prijungtų vartotojų skaičius)



Kryžminio patikrinimo vidutinė kvadratinė paklaida mokymo duomenims didėjant fold kiekiui
(Prijungtų vartotojų skaičius)




Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims didėjant fold kiekiui
(Prijungtų vartotojų skaičius)




5 priedas. Atjungtų vartotojų skaičiaus prognozavimo modelių rezultatų grafikai (10 foldų)


Kryžminio patikrinimo vidutinė kvadratinė paklaida pagal fold numerį
(Atjungtų vartotojų skaičius)




Kryžminio patikrinimo vidutinis determinacijos koeficientas didėjant fold kiekiui
(Atjungtų vartotojų skaičius)






Kryžminio patikrinimo vidutinė kvadratinė paklaida su mokymo duomenimis pagal fold numerį
(Atjungtų vartotojų skaičius)



Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims didėjant fold kiekiui
(Atjungtų vartotojų skaičius)




Tikros ir prognozuojamos reikšmės (Atjungtų vartotojų skaičius)




6 priedas. FLIR veikimo laiko prognozavimo modelių rezultatų grafikai (10 foldų)


Kryžminio patikrinimo vidutinė kvadratinė paklaida pagal fold numerį
(FLIR veikimo laikas)




Kryžminio patikrinimo vidutinis determinacijos koeficientas didėjant fold kiekiui
(FLIR veikimo laikas)




Kryžminio patikrinimo vidutinė kvadratinė paklaida mokymo duomenims pagal fold numerį
(FLIR veikimo laikas)



Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims didėjant fold kiekiui
(FLIR veikimo laikas)




Tikros ir prognozuojamos reikšmės (FLIR veikimo laikas)




7 priedas. Prijungtų vartotojų prognozavimo modelių rezultatų grafikai (10 foldų)


Kryžminio patikrinimo vidutinė kvadratinė paklaida pagal fold numerį
(Prijungtų vartotojų skaičius)




Kryžminio patikrinimo vidutinis determinacijos koeficientas didėjant fold kiekiui
(Prijungtų vartotojų skaičius)






Kryžminio patikrinimo vidutinė kvadratinė paklaida mokymo duomenims didėjant fold kiekiui
(Prijungtų vartotojų skaičius)



Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims didėjant fold kiekiui
(Prijungtų vartotojų skaičius)




Tikros ir prognozuojamos reikšmės (Prijungtų vartotojų skaičius)




8 priedas Optimizuotų modelių testavimo grafikai ir diagramos (atjungtų vartotojų skaičius)


Kryžminio patikrinimo vidutinė kvadratinė paklaida mokymo duomenims pagal fold numerį



Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims pagal fold numerį




Tikros ir prognozuojamos reikšmės




9 priedas Optimizuotų modelių testavimo grafikai ir diagramos (FLIR suveikimo laikas)


Kryžminio patikrinimo vidutinė kvadratinė paklaida mokymo duomenims pagal fold numerį



Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims pagal fold numerį




Tikros ir prognozuojamos reikšmės




10 pr. Optimizuotų modelių testavimo grafikai ir diagramos (FLIR prijungtų vartotojų skaičius)

Kryžminio patikrinimo vidutinė kvadratinė paklaida mokymo duomenims pagal fold numerį



Kryžminio patikrinimo vidutinis determinacijos koeficientas mokymo duomenims pagal fold numerį



Tikros ir prognozuojamos reikšmės

