



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Giliais neuroniniais tinklais grįstas automatizuotas įrankis fotomodulių gamybos kokybės kontrolei

Baigiamasis magistro projektas

Rytis Vizgirda

Projekto autorius

Prof. Habil. dr. Antanas Verikas

Vadovas

Dokt. Jonas Vaičys

Mokslinis konsultantas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Giliais neuroniniais tinklais grįstas automatizuotas įrankis fotomodulių gamybos kokybės kontrolei

Baigiamasis magistro projektas

Elektros energetikos inžinerija (6211EX010)

Rytis Vizgirda

Projekto autorius

Prof. Habil. dr. Antanas Verikas

Vadovas

Dokt. Jonas Vaičys

Mokslinis konsultantas

Prof. Saulius Gudžius

Recenzentas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Rytis Vizgirda

Giliais neuroniniais tinklais grįstas automatizuotas įrankis fotomodulių gamybos kokybės kontrolei

Akademinių 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.

Rytis Vizgirda

Patvirtinta elektroniniu būdu

Vizgirda, Rytis. Giliais neuroniniais tinklais grįstas automatizuotas įrankis fotomodulių gamybos kokybės kontrolei. Magistro baigiamasis projektas / vadovai Prof. Habil. dr. Antanas Verikas, Dokt. Jonas Vaičys; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

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

Reikšminiai žodžiai: dirbtinis intelektas, mašininis mokymas, vaizdų atpažinimas, saulės fotomoduliai, saulės fotomodulių kokybė, saulės fotomodulių defektai, kokybės kontrolės įrankis, klasifikatorius, klasifikatorių palyginimas.

Kaunas, 2022. 42 p.

Santrauka

Šiame magistro baigiamajame projekte tiriama galimybė pritaikyti dirbtinį intelektą, siekiant pagerinti saulės fotomodulių gamybos kokybės kontrolės parametrus. Projekte pateikiamas tyrimas, kuriame pasitelkiamas mašininis mokymasis ir vaizdų atpažinimo algoritmai, apmokinti taip, kad nustatytų saulės fotomodulio kokybę klasifikuojant modulį prie blogų arba gerų modulių. Siekiant sukurti modelį, pasitelkti duomenys iš Lietuvoje esančios saulės fotomodulių gamyklos. Duomenys pateikti elektroliuminescencinių nuotraukų formatu.

Atlikus tyrimą nustatyta jog giliais neuroniniais tinklais grįstas saulės fotomodulių klasifikavimo įrankis sugeba tiksliai ir greitai atpažinti ir suklasifikuoti gaminamą modulį. Norint įsitikinti jog išsikeltam uždaviniui išspręsti pasirinktas tinkamas dirbtinio intelekto modelis, atliktas sukurto modelio palyginimas su paprastu tiesiniu klasifikatoriumi. Nustatyta, jog giliais neuroniniais tinklais grįstas modelis yra pastebimai taiklesnis ir patikimesnis.

Vizgirda, Rytis. Development of Automated Tool for Solar Module Quality Control Using Deep Neural Network. Master's Final Degree Project / supervisor Prof. Habil. dr. Antanas Verikas, Doct. Jonas Vaičys; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

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

Keywords: artificial intelligence, machine learning, image recognition, solar photovoltaic modules, solar photovoltaic module's quality, solar photovoltaic module's defects, quality control tool, classifier, classifiers comparison.

Kaunas, 2022. 42 p.

Summary

This master's thesis explores the possibility of applying artificial intelligence to improve the quality control parameters for the production of solar photovoltaic modules. The project presents a study that uses machine learning and image recognition algorithms trained to determine the quality of a solar photovoltaic module by classifying the module as bad or good. In order to create the model, data from the solar photovoltaic modules manufacturing plant, which is based in Lithuania were used. Data are presented in electroluminescent images.

The study showed that the classification tool for solar photovoltaic modules based on deep neural networks is able to accurately and quickly identify and classify the manufactured module. In order to make sure that the appropriate model of artificial intelligence was chosen to solve the set problem, a comparison of the developed model with a simple linear classifier was performed. The model based on deep neural networks has been found to be significantly more accurate and reliable.

Turinys

Įvadas.....	8
1. Literatūros analizė	10
1.1. Saulės elektrinių defektai.....	10
1.2. Saulės elektrinės gedimų paieška	11
1.3. Elektroluminescencinės fotomodulių nuotraukos ir defektų atpažinimas	13
1.4. Dirbtinis intelektas	15
1.5. Mašininis mokymas	17
1.6. Vaizdų atpažinimo algoritmai.....	18
1.7. Apibendrinimas.....	21
2. Metodologijos apžvalga.....	22
2.1. Giluminių konvoliucinių neuroninių tinklų struktūra ir veikimas	22
2.1.1. Įvesties centrų reikšmė	22
2.1.2. Konvoliucinių sluoksnių veikimas	22
2.1.3. Sujungimo sluoksnis ir jo reikšmė	22
2.1.4. Požymių iškėlimo sluoksnis	23
2.1.5. Atvirkštinio skleidimo modelio taikymas	23
2.1.6. Giluminių konvoliucinių neuroninių tinklų taikymas	24
2.2. Modelio prasmė	24
2.3. Modelio kūrimo eiga.....	24
2.4. Modelio kūrimas	25
2.4.1. Duomenų rinkimas	25
2.4.2. Ekspertinis klasifikavimas.....	25
2.4.3. Duomenų transformavimas.....	26
2.4.4. Duomenų normalizavimas.....	26
2.4.5. Duomenų skirstymas mokymui ir testavimui.....	27
2.4.6. Modelio apmokymas	27
2.4.7. Modelio naudojimas	29
2.4.8. Modelio kokybės parametrai	29
2.5. Tiesinis klasifikavimo modelis	31
3. Rezultatai	32
3.1. GKNT modelio sudarymo rezultatai.....	32

3.2.	GKNT ir tiesinio klasifikatoriaus palyginimo rezultatai	36
	Išvados.....	39
	Literatūros sąrašas	40

Ivadas

Siekiant sumažinti įsibėgėjusios klimato kaitos esamą ir numatomą žalą daugelyje pasaulio šalių pereinama nuo iškastinio kurio, prie atsinaujinančiosios energetikos [1]. Atsinaujinantieji energijos ištekliai (toliau - AEI) sulaukė daug dėmesio valstybiniu ir bendrijų lygiu[2]. Šis dėmesys labiausiai atpažįstamas per skiriamas subsidijas ir pakitusią teisinę bazę, kuri leidžia vis sklandžiau integruoti naujus elektros energijos generavimo šaltinius į bendrą elektros sistemą. Atsižvelgiant į šiuos veiksmus, galima teigti, jog finansavimo lėšos ir atlikti darbai turi būti išnaudojami kuo tikslingiau ir efektyviau.

Viena labiausiai tobulėjančių ir daug dėmesio sulaukianti AEI šaka yra saulės energetika. Šių elektrinių svertinė elektros energijos kaina (*angl. levelized cost of electricity, trumpinys - LCOE*) per pastaruosius 10 metų sumažėjo net 6 kartus, o tai yra didžiausia pažanga iš visų AEI [3]. Stebint šios energetikos srities potencialą tinkama vertinti esamus ir būsimus iššūkius susijusius su efektyviu saulės energetikos vystymu.

Visų saulės elektrinių didžiąją įrenginių įrengimo ir medžiagų kainą sudaro saulės fotomoduliai. Jų dalis elektrinės kainoje gali svyruoti nuo 50-70%, todėl galima teigti jog pagrindinis saulės elektrinės elementas yra fotomoduliai, todėl ir visos elektrinės darbai bei kokybė priklauso nuo jų. Siekiant tikslingai išnaudoti saulės energetikai skiriamus finansavimo lėšas svarbu užtikrinti fotomodulių kokybę ir patikimumą.

Fotomodulių kokybės ir patikimumo užtikrinimui skirtas dėmesys pasireiškia per kelis aspektus: tikrinamos modulių sudedamosios medžiagos ar jos yra ilgaamžės ir atsparios aplinkai, tikrinama surinkimo darbo jėga, atsižvelgiant į tai, kad nebūtų išnaudojami vaikai ir tam kad būtų naudojama kuo daugiau švarios energijos bei neliktų gamybos atliekų, tikrinama surinkimo kokybė ir atliekama kokybės kontrolė daugumoje gamybos etapų. Iš šių išvardintų aspektų, labiausiai prieinamas ir nuo aplinkinių priklausomas yra kokybės kontrolės užtikrinimas.

Siekiant atlikti kokybės kontrolę gaminamam moduliui visuomet atliekama fotomodulių elektroluminescencinė nuotrauka, kurioje matomos gamybos metu padarytos klaidos. Šių klaidų padariniai – kaistantys fotoelementai, gamybos metu įvardinami kaip įtrūkimai, o eksploatacijos metu atliekamos apžiūros ataskaitos pasižymi kaip karštieji taškai (*angl. Hot-spot*). Dėl šių karštųjų taškų, yra numatyta, jog modulių grandinė praranda 1,16 % savo nominalios galios dėl vieno tokių karštojo taško. Apie tai savo ataskaitoje [4] kalba parengtos studijos autoriai. Taigi teisinga manyti, jog papildomos pastangos, siekiant užkirsti kelią defektingiems moduliams pasiekti naujas instaliacijas, yra priimtinos ir skatintinos. Dėl šios priežasties, iškeliamas tikslas, kuriuo tikimasi padėti saulės energetikos šakai tapti labiau konkurencinga, ilgaamžiai ir efektyviai.

Darbo tikslas – sukurti giliais neuroniniais tinklais grįstą, automatizuotą įrankį, kuris padėtų vykdyti fotomodulių gamybos kokybės kontrolę.

Darbo uždaviniai:

1. atlikti fotomodulių gedimų, defektų bei dirbtiniu intelektu grįstų algoritmų jų aptikimui taikymų literatūros analizę;
2. surinkti ir paruošti elektroluminescencines nuotraukas fotomodulių gedimų, defektų atpažinimo modelių kūrimui
3. sukurti giliaisiais neuroniniais tinklais grįstą modelį, gebantį atpažinti defektinius modulius.
4. palyginti giliaisiais neuroniniais tinklais grįstą modelį su paprastu tiesiniu klasifikavimo modeliu.

1. Literatūros analizė


1.1. Saulės elektrinių defektai

Žalą elektrinei galima vertinti pagal nesugeneruotą energijos kiekį ir medžiagų kiekį kurį reikia pakeisti. Fotomodulių gedimai pasitaiko ganėtinai retai, tačiau didelis modulių kiekis elektrinėse lemia, kad bet kuriuo metu, bent dalis modulių bus dalinai pažeisti ir jie dirbs nepilnu galingumu. Fotomoduliuose ir su jais susijusių dalių gedimai pasitaiko dėl nekokybiškų medžiagų ar įrengimo metu padarytų klaidų. Dalis gedimų ir priežasčių įvardinama žemiau [5]:

Blogai sujungta elektros komutacinė įranga – šį gedimą galima skirstyti į du. Pirmasis būtų gedimas dėl bloga seka sujungtų komutacinių laidininkų taip iššaukiant šuntavimą ir trumpuosius jungimus, kurie tam tikromis situacijomis gali būti nepastebėti. Apie šių gedimų aptikimą rašoma analizuotame straipsnyje [6]. Toks atvejis atsitinka kai į vieną inverterio maksimalios galios sekimo tašką yra jungiamos nedaugiau nei dvi modulių grandinės. Tuomet trumpojo jungimo metu srovė teka tik tokia, kokią gali generuoti modulis, kuri savo reikšmė nuo maksimalios galios srovės skiriasi tik keliais procentais, kas lemia sunkų tokio trumpojo jungimo identifikavimo būdą. Antrasis gedimas galimas dėl nekokybiškai užpresuotų modulių jungčių ar jungiamosiose dėžutėse arba tarpiniuose sujungimuose nekokybiškai sujungtų grandinių. Ši problema gan aktuali, kadangi šie darbai atliekami objekte atviraime lauke, kur sąlygos dirbti ne visuomet palankios.

Blogai veikiančios grandinės pasitaiko dėl priežasčių nurodytų aukščiau ir taip pat dėl netinkamo saulės elektrinės suprojektavimo, kurio metu, galima galėjo būti numatyta sujungti dvi grandines į vieną maksimalaus sekimo tašką, nors tose grandinėse numatytas nevienodas fotomodulių skaičius, dėl to, darbo metu bus nevienoda įtampa. Tai gali reikšti jog srovė teka iš vienos grandinės į kitą.

Blogai veikiantys moduliai dažniausiai pasireiškia dėl dviejų priežasčių. Pirmoji būtų montavimo metu netinkamai manipuluojama moduliais ir jie gali būti sugandinti. Priežastys gali būti įvairios, ant modulio užlipta, prispausta daliniu kūno svoriu ar netgi pasidėta dėžė įrankių ar įrangos, kuri sugadino modulyje esančias fotoelementus. Taip pat montavimo metu modulių laikantieji gnybtai per stipriai priveržiami, kas lemia jog modulio kraštuose pasireiškia pernelyg didelė apkrova ir tai lemia celių įskilimus. Tokios montavimo klaidos dažnai nepastebimos, kadangi moduliai vizualiai nepakinta, o jų elektriniai parametrai suprastėja pernelyg mažai, kad būtų galima pastebėti elektrinės bandymo metu. Antroji priežastis – nekokybiškas modulio pagaminimas (1 pav.). Gamybos metu automatizuotos rankos manipuluoja fotoelementais ir juos jungia į grandines. Taip pat išpopuliarėjęs metodas perpjauti fotoelementą per pusę, kas suteikia moduliui keletas papildomus procentus galios ir pagerina darbinių parametrų reakciją į temperatūrą. Tačiau šių perpjovimų metu, galimi mikroskopinius įtrūkimai, kurie vėliau gali virsti fotoelemento karštaisiais taškais. Tačiau dažniausiai fotoelemento karštojo taško priežastis – blogai prilituoti kontaktai. Litavimo procesas vis dar dažnai atliekamas rankiniu būdu, todėl neišvengiamas ir gamybos brokas.



1 pav. Fotomodulio elektroliuminescencinė nuotrauka

1.2. Saulės elektrinės gedimų paieška

Saulės elektrinės apžiūros atliekamos pagal susitarimą, tačiau tai dažniausiai daroma kartą metuose. Apžiūros būtinumą taip pat gali iššaukti blogas saulės elektrinės santykinio naudingumo koeficientas. Šis koeficientas skaičiuojamas prieš įrengiant elektrinę, pagal geografinę lokaciją ir jai tenkamą saulės apšvietos kiekį per metus. Įrengiant elektrinę taip pat įmontuojamas piranometras, kuris registruoja faktinį saulės apšvietos kiekį metų bėgyje. Tai leidžia palyginti skaičiuojamąjį santykinį našumą prieš įrengiant elektrinę ir ją įrengus ir taip įvertinti saulės elektrinės darbo kokybę.

Apžiūrų metu atliekamos įvairios patikros naudojant ekspertinius vertinimus, infraraudonųjų spindulių kameras, dinamometrus ir kitus prietaisus. Ekspertinio vertinimo metu, stebima ar nepakinta įrengtų saulės elektrinės elementų pozicija, taip gali nutikti dėl didelių vėjų ir per mažo slegiančio balasto, taip pat stebima ar fotomoduliai nepakeitė spalvos, t.y. ar nepradėjo skirtis rūgštys, kurios graužia fotoelementų kontaktus. Įvertinamas fotomodulių užterštumas, kuris ypač smarkiai pasireiškia jei netoliese yra vykdoma ūkinė veikla. Stebima ar konstrukcijos elementuose nepasireiškė korozija. Toliau, naudojantis varžų matavimo prietaisais matuojama įžeminimo kontūro ir grandinių izoliacijos varža. Taip nustatoma ar elektrinė veikia saugiai. Naudojantis dinamometru tikrinamos laikančiųjų konstrukcijų jungtys, kadangi dėl šalčio ir šilumos ciklų jos gali atsilaisvinti.


Inverterių, paskirstymo spintų ir fotomodulių gedimams naudojamos termovizinės kameros, leidžiančios stebėti temperatūros pasiskirstymą. Kaip minėta anksčiau, jei į inverterį jungiama daugiau nei dvi fotomodulių grandinės, juose būtina įrengti saugiklius tarp atskirų grandinių. Esant prastos kokybės saugikliui, šis gali kaisti [7]. Inverterių prijungimas prie vidaus tinklo atliekamas naudojant varžtinius kontaktus, kurie, jei tinkamai nepriveržti - kaista. Tai galima pastebėti naudojanti termovizine kamera. Analogiškas tyrimas atliekamas paskirstymo skyduose. Juose esantys inverterių kabelių prijungimai taip atliekami varžtiniu principu ir dažniausiai yra jungiami prie automatinio jungiklio ir šynų. Šiuose komutaciniuose taškuose svarbu patikrinti ar sujungimo vietos nekaista ir dinamometru patikrinti ar yra gerai priveržtos.

Saulės fotomodulių patikra naudojant termovizines kameras atliekama jau daugelį metų, kadangi tai nereikalauja intervencijos ar kruopštaus kiekvienos grandinės tyrimo. Termovizinės apžiūros metu, svarbu tinkamai nukreipti termovizorių į saulės fotomodulį, taip kad tikrinimo metu, nesusidarytų atspindžiai nuo aplinkinių objektų, o ypač saulės. Priklausomai nuo apžiūros detalumo pasirenkama kaip dažnai atliekamos modulių termovizinės nuotraukos. Pačiu detaliausiu atveju, tai turėtų būti


atliekama visiems moduliams. Tačiau vertinant tai jog rankiniu būdu atliekant saulės fotomodulių termovizorines nuotraukas užtrunkamas apie keletą sekundžių, tai reikštų jog tokios patikros užtrunka kartais net iki kelių savaičių. Todėl dažnai pasirenkama atlikti ne visų modulių termovizines nuotraukas, o kas 10 ar 20, taip taupant laiką, tačiau rezultatų kokybei paliekant per didelę įtaką nuo tikimybės aptikti gedimą. Tačiau tokios nuotraukos labai informatyvios. Jose galima pastebėti įvairius gedimus. Gedimų sąrašas pateikiamas žemiau[8]:

- a. Saulės fotoelemento gedimas (pasižymi kaistančiu visu kvadratu) (2 pav.)
- b. Keleto saulės fotoelementų gedimas (pasižymi keletu kaistančių pilnų kvadratu)
- c. Karštieji taškai (pasižymi kelių cm dydžio karštomis sritimis modulyje) (5 pav.)
- d. Keli karštieji taškai (pasižymi keliomis kelių cm dydžio karštomis sritimis modulyje)
- e. Diodo gedimai (pasižymi trečdalio arba dviejų trečdalių modulio šuntavimu, o tai savo ruožtu sukelia padidėjusią temperatūrą) (3 pav.)
- f. Kontaktų dėžutės kaitimas (pasižymi kaitimu ten, kur modulio galinėje dalyje yra kontaktų dėžutė) (4 pav.)


Visus aukščiau išvardintus gedimus galima pastebėti su termovizorine kamera. Jų termogramos pateikiamos žemiau:




2 pav. Kaistančių celių IR nuotrauka



3 pav. Šuntuoto diodo IR nuotrauka



4 pav. Kaistančios kontaktų dėžutės IR nuotrauka



5 pav. Karštųjų taškų IR nuotrauka

Aprašytų gedimų diagnostikai skiriama daug dėmesio ir numatomi dideli pasikeitimai, kurie jau šiuo metu vyksta saulės elektrinių apžiūros rinkoje. Šie pasikeitimai įtakojami to, kad apžiūrai atlikti skiriama labai daug laiko ir tai brangiai kainuoja. Taip pat šios apžiūrai dažnai nebūna tikslios. Tačiau esant detalios apžiūros poreikiui, kuri atitiktų IEC TS 62446-3:2017 standartą, kuriame išdėstytos gairės ir reikalavimai kaip turi būti atliekama saulės fotomodulių apžiūra pasitelkiant termovizines kameras, tokios apžiūros atlikimo laikas tampa labai ilgas, naudojant rankinius termovizorius, kaip tai apžvelgta analizuotame straipsnyje [9]. Išėjus šiai problemai – be piločių orlaivių technologija arba kitaip vadinami dronai [10,11,12]. Ši sparčiai tobulėjanti sritis leido pasinaudoti galingais dronais, kurie stabiliai ir tiksliai galėtų skraidinti brangias radiometrinės kameras kurios matuoja modulių paviršių temperatūrą ir nurodo kuriuos modulius reikia keisti. Tokio drono atliktos nuotraukos dažnai apdirbamos papildomų programų kurios sudaro vadinamą ortomozaiką. Ortomozaika, tai labai aukštos kokybės nuotrauka sudaryta iš daugelio nuotraukų. Vienas didžiausių jų pliusų yra perspektyvos nebuvimas. Tai leidžia atlikti tikslius matavimus ir planavimą. Tačiau, svarbu paminėti, jog modulio kainą arba įtaką numatytam verslo modeliui yra mažiausia tuomet, kai jis dar yra pas gamintoją. Kadangi, atradus sugedusį ar sugadintą modulį, prieš pat atiduodant saulės parką užsakovui, modulio pakeitimai pareikalauja papildomų darbų. Tokiu atveju, numatytos sąmatos ir terminų pakeitimai atliekami ne tik dėl jau brokuoto modulio, bet taip pat reikia įtraukti į kainą brokuoto modulio sumontavimą, demontavimą, aptikus jog jis sugedęs, demontavimo metu, dažnai tenka samdyti papildomą darbinę techniką, tam kad darbas būtų atliktas saugiai, pasirūpinti esamos ir naujos įrangos transportavimu, utilizavimu ir taip pat sumokėti baudas, jei rangovas vėluoja priduoti saulės parką užsakovui. Taigi, defektinio saulės fotomodulio kaina išauga daugiau nei dvigubai, jei jis aptinkamas statybvietėje, o ne gamykloje.

1.3. Elektroluminescencinės fotomodulių nuotraukos ir defektų atpažinimas

Naudojant kameras, kurios yra jautrios tam tikram infraraudonųjų bangų spektro daliai galima užfiksuoti fotovoltinio modulio elektroluminescencinę nuotrauką. Spinduliai, kuriuos skleidžia modulis dirbdamas, yra artimieji infraraudonieji spinduliai (angl. Near infrared, sutr. NIR) ir pasireiškia tarp 800 nm ir 1150 nm bangos ilgio [13]. Šiose nuotraukose galima užfiksuoti labai smulkius įtrūkimus fotoelemente ir nustatyti ar modulis dirba optimaliu režimu [14]. Dažnai šių nuotraukų negalima padaryti lauko sąlygomis, kadangi aplinkinė atspindėjusi saulės šviesa yra daug didesnio ryškumo nei fotomodulių EL nuotraukos. Todėl šios nuotraukos yra atliekamos arba anksti ryte arba vėlai vakare. Kaip kokybės kontrolė elektroluminescencinės fotomodulių nuotraukos yra atliekamos fotomodulių gamyklose, taip nustatant ar nėra brokuotų ar gamybos metu pažeistų celių. Tačiau pastebėtina jog šiose nuotraukose esamus defektus turi pastebėti gamyklos operatorius ir dėl šios priežasties atsiranda žmogiškosios klaidos faktorius ir iš gamyklų vis tiek išvyksta brokuoti moduliai. Yra numatoma, jog šią užduotį tikslinga automatizuoti ir pervesti atlikti dirbtiniam intelektui.

Pagrindiniai fiksuojami gedimai yra skirstomi pagal tai, kaip gedimas paveiks modulio galią ir modulio naudojimo saugumą [15]. Pagal galimą įtaką modulio galiai, gedimai yra skirstomi į klases nuo A iki F (1 lentelė). Saugomo klasės trys, nuo A iki C (2 lentelė).

1 lentelė. Gedimo poveikio modulio galiai klasės ir aprašymai pagal IEA [16]




Galios praradimo klasė	Klasės apibūdinimas
A	Prarandamas galios kiekis toks mažas, jog yra neįmanoma aptikti.
B	Numatomas greitėjantis saulės fotomodulio degradavimas.
C	Numatomas tolygus, padidėjęs saulės fotomodulio degradavimas.
D	Numatomas įsisotinantis saulės fotomodulio degradavimas.
E	Numatoma degradacija pasireiškianti kelis kartus.
F	Numatomas degradacijos kiekis didelis ir pasireiškiantis kelis kartus.




2 lentelė. Gedimo poveikio modulio saugumui klasės ir aprašymai pagal IEA

Saugumo klasė	Klasės apibūdinimas
A	Gedimas nepadidina eksploataavimo rizikų.
B	Gedimas gali sukelti gaisrą (f), gedimas gali sukelti elektros iškrovą (e), gedimas gali padaryti fizinės žalos (m).
C	Gedimas neabejotinai sukels saugumo problemų.

Elektroliuminescencinės nuotraukos leidžia greitai atpažinti minėtus gedimus, kadangi jie tampa ryškiai matomi, atliekant patikrą. Dėl šios priežasties, daugelis, o tiksliau, visi saulės fotomodulių gamintojų naudoja šių nuotraukų peržiūrą, o vis dažniau šios nuotraukos pradedamos daryti net kelis kartus, tam pačiam moduliui, keliaujant gamybos linija, kadangi šių nuotraukų atlikimas nereikalauja daug laiko ir pastangų [16,17]. Žemiau pateikiamuose pavyzdžiuose (3 lentelė) nurodomi gedimų vizualai, kurių ieško darbuotojas atliekantis patikros funkciją.

3 lentelė. Gedimų pavyzdžiai su aprašymais ir nuotraukomis

Pavadinimas	Aprašymas	Galios praradimo klasė	Saugumo klasė	Pavyzdys
Įtrūkimas saulės fotoelemente (A tipo)	Įtrūkimas neturi įtakos srovės tekėjimui per fotoelemento celę.	C	B	
Įtrūkimas saulės fotoelemente (A+B tipo)	Įtrūkimas daro įtaką srovės tekėjimui per fotoelemento celę, tačiau vis dar išlieka kontaktas celės viduje..	C	B(f)	
Įtrūkimas saulės fotoelemente (A +B+C tipo)	Įtrūkimas daro įtaką srovės tekėjimui celėje ir visiškai nutraukia esamas elektrinės jungtis, leidžiančias srovei tekėti	C	B(f)	
Išilginis įtrūkimas	Subraižymai atsirandantys ant modulio galinės dalies, gali padidinti izoliacijos pramušimo tikimybę.	A	B(f)	


Išsišakojantys įtrūkimai	Įtrūkimai, kurie kerta pagrindines kontaktų juosteles	C	B(f)	
Korozija dėl drėgmės	Atsiradusi korozija ant priekinių kontaktų juostelių, atsirandanti dėl drėgmės ir laminato sąlyčio, o tai išskiria rugštį, kuri graužia kontaktus	F	A	
Šuntavimas	Gedimas atsirandantis dėl delaminavimosi ir sumažinantis modulio galią.	A	B(f)	
Atsijungęs kontaktas	Kontakto nutrūkimas fotoelemento celėje, gali sukelti kibirkščiavimą ir galios praradimą	A	B(f)	

Šiam darbui, kuriamame modelyje, dėl brokuotų modulių pavyzdžių stokos, nebus kuriamos kelios atskiros klasifikatoriaus klasės siekiant atskirti, kuris gedimas pasireiškė. Modelyje numatoma, kad būtų tikrinama tik sąlyga ar modulis brokuotas ar ne. Taip pat nevertinama tai, jog moduliai galimi gaminti, t.y. parduoti ir žemesnės saugumo ir galios sumažėjimo klasės nei pačios aukščiausios. Tokius sprendimus, kaip kad defektnių modulių pardavimas, turi priimti įmonės vadovai ir paminų vadovai.

1.4. Dirbtinis intelektas

Dirbtinį intelektą (DI) Oksfordo žodynas apibrėžia kaip – teoriją ir programų kūrimą, galinčių atlikti užduotis, kurioms paprastai reikalingas žmogaus intelektas, pavyzdžiui, vaizdų atpažinimas, kalbos atpažinimas, sprendimų priėmimas ir vertimas iš vienos kalbos į kitą (vertimas iš anglų kalbos). Dirbtinis intelektas apibrėžiamas kaip sistemos sugebėjimą teisingai interpretuoti išorinius duomenis, mokytis iš jų ir panaudoti tokias žinias, kad būtų įgyvendinti konkretūs tikslai ir uždaviniai, lanksčiai juos pritaikant. Dirbtinis intelektas skiriasi nuo įprastų kompiuterinių algoritmų tuo, kad gali apsimokyti, tai atlikdamas tą patį veiksmą gali elgtis kitaip priklausomai nuo prieš tai atliktų veiksmų.

Dirbtinio intelekto tyrimai remiasi psichologijos ir neurologijos, matematikos ir logikos, komunikacijos teorijos, filosofijos ir lingvistikos mokslų duomenimis. Dirbtinio intelekto tyrimuose dažnai pagal gyvų organizmų nervų sistemą kuriami supaprastinti teoriniai modeliai (6 pav.). Jie vadinami neuroniniais tinklais, kurie vėliau panaudojami sprendžiant įvairių sričių problemoms spręsti – balso ar vaizdo atpažinimui, ligų diagnozei ir panašioms problemoms, kurios tiksliais algoritmais sunkiai sprendžiamos dėl ribotų techninių galimybių.



6 pav. Dirbtinio neurono principinė schema

Dirbtinio intelekto naudojamas dirbtinis neuronas susidaro iš įvesties taškų, sumavimo funkcijos, aktyvacijos funkcijos ir išvesties taško. Visą tai kas panaudojama iš šalies, tai yra: svoriai, poslinkio svoris yra dinamiškieji parametrai, kurie, neuroniniam tinklui mokantis keičiasi. Šie pokyčiai apsprendžia kaip gerai NT atliks savo funkciją spręsti specifinę užduotį. Šių dirbtinio neurono dalių funkcijos aprašomos taip - įvesties taškuose įvedami informacija, kurios parametrai turi būti griežtai apibrėžti ir sunormalizuoti, patalpinti tarp 0 ir 1. Svoris, suteikia įvesties taškui įtakos galutiniam rezultatui kiekį, vėliau, šis kiekis reguliuojamas, atsižvelgiant į gautus rezultatus. Sumavimo funkcija, apjungia turimų įvesties duomenų ir svorių sandaugos rezultatus, taip sumažindama reikiamų vertinimo resursų kiekį. Aktyvavimo funkcija, kuri dažniausiai būna ReLU tipo (angl. *rectified linear unit*), taip pat sigmoidė ir hiperbolinio tangento. Šios aktyvacijos funkcijos esmė suteikti modeliui netiesiškumo. Tai vieta, dėl kurios yra atskiriami tiesiniai ir netiesiniai mašininio mokymo modeliai. Aktyvavimo funkcijos parenkamas atsižvelgiant į modelio sprendžiamą uždavinį. Poslinkio svoris atideda bendrą funkciją nustatytomis dalimis, visai kaip matematinėje tiesinio grafiko funkcijoje įvedami perslinkimai. Įtraukti poslinkio svorį yra pravartu, nes tai leidžia tinklo vertėms nesugrižti į pradžios tašką. Priklausomieji kintamieji, gali būti vertinami kaip išvesties taškai. Jų reikšmė, priklauso nuo užduoties. Klasifikavimo užduočiai, priklausomasis kintamasis dažnai būna tikimybinė išraiška, regresijos uždaviniui, šis kintamasis gali įgyti įvairius matmenis, priklausomai nuo suformuluotos užduoties, pavyzdžiui – saulės elektrinės galia prognozuojamu momentu. Vertindami priklausomųjų kintamųjų rezultatą galima spręsti ar modelis tinkamas tam tikriems uždaviniams, ar vis dėlto modeliui dar reikia mokintis ir keisti savo parametrus. Priklausomi kintamieji dažnai vertinami su žinomomis reikšmėmis arba numatytu rezultatu siekiant įvertinti modelio pasiektą tikslumą. Matematinė forma, dirbtinis neuronas aprašomas sekančiai:

$$y = \varphi(\sum_{j=0}^n w_j x_j) \quad (1)$$

Čia y – priklausomas kintamasis

φ – aktyvacijos funkcija


n – įvesties taškų skaičius

w_j – įvesties taškams suteikiami dinaminiai svoriai

x_j – įvesties taškas

1.5. Mašininis mokymas

Viena iš labiausiai paplitusių dirbtinio intelekto technologijų kuri yra naudojama kurti dirbtinio intelekto sistemas ir algoritmus yra mašininis mokymas. Jo naudą apžvelgia straipsnio [18] autoriai vertindami tiriamo objekto energetinį efektyvumą pasitelkiant mašininį mokymą. Mašininis mokymas veikia vadovaudamasis turimų duomenų analize ir jos skirstymu į klases. Svarbu tai, jog mašininiam mokymui yra svarbus žmogaus patvirtinimas ar sukurtas modelis atlieka tinkamus spėjimus. Tai atliekama skirstant duomenis į mokymo ir testavimo. Mokymo duomenys dažniausiai būna nesugrupuoti, o testavimui skirti duomenys yra pateikti juos sugrupuojant į atitinkamas grupes. Tai leidžia mašininio mokymo algoritmui atlikti spėjimus remiantis turima informacija ir stebint testavimo rezultatus. Dažnai tam, kad būtų pasiektas norimas taiklumas, reikalinga atlikti daug mokymosi ir testavimo ciklų. Vienas tokių ciklų vadinamas epocha. Atlikus spėjimą, po tam tikros epochos, pateikiami spėjimo tikslumo rezultatai, kai tinklas pasiekia norimą tikslumą, galima teigti, jog epochų kiekis yra pakankamas ir neuroninis tinklas įsisotino ir geresnių rezultatų nebepasiekia. Šio reiškinio ieškojimas yra vienas iš svarbiausių neuroninio tinklo kūrimo uždavinių, kadangi nenorima jog tinklo mokymas, naujais duomenimis užtruktų ilgą laiką arba taip pat svarbu, kad tinklas neprarastų savo spėjimo tikslumo, dėl to jog per daug kartų kartoja tų pačių duomenų mokymą. Siekiant išvengti spėjimo tikslumo praradimo yra naudojamas išankstinio sustabdymo algoritmas (angl. *early stopping*) [19]. Jis seka, kada neuroninio tinklo spėjimo tikslumai pradeda prastėti ir nusprendžia, jog epocha po kurios buvo pasiekti geriausi rezultatai turėtų būti paskutinioji (7 pav.).



7 pav. Modelio apsimokinimo ir testavimo paklaidų kreivės priklausomai nuo atliktų epochų skaičiaus

Apie mašininį mokymą galima galvoti, kaip apie nuspėjamosios analizės sritį, kuri savo ruožtu padeda įvairioms verslo ir pramonės industrijoms nuspėti tikėtinus įvykius ar atlikti užduotis, kurios nereikalauja kompleksinių ekspertinių vertinimų duotuoju momentu. Siekiant įgyvendinti įvykių spėjimo mechanizmą, sukurti regresijos modeliai, kurie vadovaujasi buvusių įvykių arba duomenų tarpusavio sąsajomis. Pavyzdžiui, saulės elektrinės generacijos kiekis. Elektrinės operatoriams pravartu žinoti koks bus elektrinės atiduodamas energijos kiekis, ypač jei kalbama apie didelės galios

saulės elektrinių, prijungtų prie perdavimo tinklo, generacijos nuspėjimą, kadangi tokios elektrinės generacijos svyravimai gali turėti įtakos tinklo topologijai ir numatomų režimų bei tam tikrų elektrinių generacijos apribojimo sprendimų. Taigi, regresijos modelis, atsižvelgdamas į turimų elektrinių generacijos duomenis ir buvusias meteorologines sąlygas tokias kaip saulės apšvieta, vėjo greitis, oro drėgmė, modulių įšilimas ir kt. turėdamas numatomus meteorologinius duomenis gali nuspėti, kokia turėtų būti saulės elektrinės generacija. Šią generaciją, taip pat būtų galima skaičiuoti ir su sudėtingomis programomis, o tai ir yra daroma šiuo metu, tačiau šioms programoms paleisti ir aprašyti, reikalinga žmogaus priežiūra ir nuolatinis darbas bei programos supratimas, kai tuo tarpu mašininio mokymo grįstas regresijos modelis, kartą apmokintas, gali apskaičiuoti būsimą generaciją neprašydamas detalių aprašymų ar duomenų interpretavimo, ar keitimo. Skirtingų modelių naudojimą regresijos užduočiai spręsti apžvelgia autorius, savo straipsnyje [20], kuriame pagrindinis uždavinys yra išsikeliamas saulės elektrinės generacijos nuspėjimas artimiausiai ateičiai.

Klasifikavimas yra kitas itin svarbus ir mašininio mokymo dažnai sprendžiamas uždavinys. Šiuo uždaviniu, siekiama suskirstyti arba sugrupuoti turimus duomenis į atskiras klases. Šio uždavinio sprendiniai yra naudingiausi, kai turimi dideli kiekiai duomenų, pavyzdžiui nuotraukos, elektros skaitiklių duomenys ar kiti iš pirmo žvilgsnio nebūtinai tarpusavyje susiję duomenys, tačiau turint didelę duomenų imtį, panašumai ir skirtumai, dažnai vis tiek randami. Didelis mašininio mokymo pliusas tai, jog jam nereikia įvardinti šių tarpusavio savybių sąsajų, jos randamos savaime modeliui bandant atrasti, bet kokias koreliacijas tarp turimų duomenų ar rodiklių [21]. Klasifikavimo uždaviniai, naudingiausiai pritaikomi kuomet žmogui reikia atlikti besikartojančias užduotis arba atlikti didelės duomenų apimties analizę skirstant juos į tam tikras grupes, kur šioms užduotims atlikti prireiktų daug žmogiškųjų išteklių. Neretai šis klasifikavimo uždavinys pritaikomas ir kaip kokybės tikrinimo algoritmas. Pavyzdžiui, siekiant įsitikinti, jog medienos klasė yra pati aukščiausia svarbu nustatyti kiek ir kokių šakų yra lentoje [22]. A klasės medienai, leistinos tik kelios šakos per visą lentą ir jų diametras negali būti didesnis nei 1 cm, taigi, taikant greitai judančių lentų fotografavimą su didelio kadro kiekiu per sekundę galinčia fiksuoti kamera, galima klasifikuoti nuotraukas, nustatant ar mediena A klasės ar bet kokios kitos. Tokiu atveju, mašininio mokymo grįstam neuroniniam tinklui pakaktų apsimokinti, turint kelis šimtus nuotraukų, kurios jau yra suklasifikuotos. Alternatyviu būdu lentų nuotraukos turėtų būti apdirbamos įmantria ir nevisiems suprantama programine logika, pagrįsta pikselių matavimu ir šakų fiksavimo logika.

1.6. Vaizdų atpažinimo algoritmai

Vaizdo atpažinimas siejasi su technologijomis, kurios identifikuoja vietas, emblemas, žmones, objektus, pastatus ir kitus kintamuosius skaitmeniniuose vaizduose. Mes galime lengvai atpažinti atvaizdą katės ir atskirti jį nuo arklio atvaizdo, bet tai, galbūt, nėra taip paprasta kompiuteriui. Skaitmeninis atvaizdas yra vaizdas, sudarytas iš paveikslų elementų, taip pat žinomų kaip vaizdo elementai, kiekvienas su baigtiniais, atskirais kiekiais skaitmeninio atvaizdavimo jo intensyvumui ar pilkam lygmeniui. Tokiu būdu kompiuteris mato atvaizdą kaip skaitmenines vertes vaizdo elementų ir kad atpažintų tam tikrą atvaizdą, jis turi atpažinti struktūrą ir reguliarumą šiuose skaitmeniniuose duomenyse. Vaizdus apdorojus ir tinkamai pateikus, galima sudaryti vaizdų atpažinimo algoritmą, kuris gali klasifikuoti vaizdus pagal jų pagrindines požymius t.y. pagal tai, kas juose pavaizduota.

Vaizdų atpažinimo neuroniniams tinklams tobulėti padeda plačios vaizdinių duomenų bazės, kurios pradedamos traktuoti kaip standartinės ir etaloninės. Apie tai aptarta straipsnyje [23], kuriame autoriai siūlo naudotis viena, plačia duomenų baze, pagal kurią būtų apmokomi daugelis vaizdus atpažinti siekiančių įrenginių. Taip pat siūloma naudoti specifinių klasių vaizdus, tam kad būtų atskirti itin svarbūs ir specifiniai vaizdiniai. Apie tai straipsnyje [24] kalba autoriai, aptardami, kaip vaizdų atpažinimas, leidžia pagreitinti agrokultūrinių ligų atpažinimą. Taip pat, pastebėta, jog giliai konvoliuciniai tinklai leidžia tiksliau ir detaliau pažvelgti į vaizdų atpažinimo problemą, suteikiant tyrėjams platesnes pritaikymo galimybes, kurios anksčiau būdavo sunkiau įgyvendinamos dėl savo kompleksiskumo. Apie tai savo straipsnyje [25] rašo autorius, siekdamas parodyti, kaip galima pritaikyti giliuosius konvoliucinius tinklus atpažįstant plaučių patologijas iš turimų nuotraukų. Taigi, natūralu, jog daugeliui šiuolaikinių vaizdų atpažinimo užduočių, pasitelkiami giliais neuroniniais tinklais grįsti algoritmai. Pastebėta, jog maždaug nuo 2016 metų giliais neuroniniais tinklais grįsti algoritmai pradėjo įgauti pagreitį ir šiuo metu dominuoja paviršinius neuroninius tinklus, kaip tai aprašome [26] straipsnyje.


Vaizdų atpažinimas neišimtinai naudojamas ir saulės fotomodulių kokybės patikrose gamyklose ir statybos aikštelėse. Įvairūs būdai naudojami nustatyti ar moduliai atitinka kokybės parametrus ir ar yra saugu juos naudoti. Apžvelgiami keletas fotoelementų gedimo aptikimo algoritmų įvardinant didžiausius jų trūkumus (žr. 4 lentelė).

4 lentelė. Skirtinguose tyrimuose naudotų metodų apžvalginė lentelė

Naudojami vaizdiniai:			Aprašymas	Trūkumai	Trukmė gedimui aptikti	Šaltinis
EL	PL	IR				
-	-	+	Neinvazinis ir nežalojantis būdas Si kristalų saulės fotoelementų įtrūkimų aptikimui naudojant infraraudonųjų spindulių kamerą	Reikalinga brangi įranga, tokia kaip aukštos raiškos infraraudonųjų spindulių kamera	Duomenų nėra	[27]
+	-	-	Automatinė defektų atpažinimo schema paremta Haar tipo požymio iškėlimu ir nauja grupavimo technika.	Reikalinga daug sveikų ir įtrūkusių fotoelementų nuotraukų siekiant atlikti apmokymą	3,6 s	[28]
+	+	-	Metodas analizuojantis modulio užpildymo faktoriaus pakitimus ir fotoelementų atviros grandinės įtampos reikšmes siekiant pagerinti PL ir EL nuotraukų patikros įžvalgas	Metodas reikalauja fotoelemento pagrindinių elektrinių parametrų sekimo	60-120 s	[29]

-	+	-	Metodas, kuriuo siūloma atlikinėti PL nuotraukas statybvietyje naudojant modulinius įrankius.	Optiniai sensoriai ir LED šviestuvai yra būtini, siekiant gauti PL nuotraukas	Duomenų nėra	[30]
+	-	-	EL nuotraukų analizė dviejuose skirtingų temperatūrų ruožuose	Reikalinga daryti nuotraukas prie dviejų skirtingų fotoelemento temperatūrų (90 °C ir 22 °C)	120-180 s	[31]
+	-	-	Metodas grįstas binarinėmis ir diskretinėmis Fourier transformacijomis skirtomis vaizdinių apdirbimui siekiant pagerinti atvaizdus, gautus naudojant tipinius EL nuotraukų generavimo įrenginius.	Matematinės formulės ir sekos turi būti įtrauktos į EL nuotraukų generavimo įrenginį	1,62 s	[32]

Šiuo metu, didėjant įrengiamų saulės parkų skaičiui ir didėjant šių parkų galiai, prieš perduodant elektrinę užsakovui vystytojas ar rangovas vis dažniau privalo atlikti galutinį įrengtų fotomodulių patikrinimą siekiant nustatyti kaip kokybiškai yra įrengti naudojami fotomoduliai. Šių patikrinimų kertinis taškas tapo bepiločių orlaivių, dar vadinamų dronais, naudojimas atliekant infraraudonųjų spindulių nuotraukas, kurios leidžia pažvelgti į veikiančią modulį ir nustatyti ar jame yra defektinių vietų. Šios dronus naudojančios patikros didelėms elektrinėms tapo itin priimtinos pritaikius mašininių mokymų ir vaizdų atpažinimo uždavinį, kadangi modulių kiekis, kurį reikia apdoroti, didėjant įrengtajai elektrinių galiai, pasiekė dešimtis tūkstančių, o tokį modulių kiekį patikrinti žmogui užima daug laiko. Vaizdų atpažinimo algoritmas, šiose infraraudonųjų spindulių nuotraukose ieško defektams priskiriamų požymių (8 pav.). Šie požymiai apžvelgti šio darbo 1.2. skyriuje, taip pat ir straipsniuose [33,34]. Svarbu atkreipti dėmesį jog mašininio mokymosi naudojimas sprendžiant šį uždavinį sutrumpino analogiškų apžiūrų laiką dešimtis arba net šimtus kartų, apie tai kalbama



8 pav. Infraraudonųjų spindulių kamera atlikta nuotrauka naudojant dronų technologiją

straipsnio [35] 1 lentelėje. Tam jog tinkamai apmokinti vaizdų atpažinimo algoritmą, pakanka kelių drono skraidymo rezultatų ir ekspertinio gedimų vertinimo. Naudinga ir tai jog ekspertinio vertinimo metu, galima nurodyti didelį kiekį skirtingų defektų ir tai leidžia sudaryti lankstų ir itin naudingą vaizdų atpažinimo algoritmą. Tokio tipo užduotis geriausiai sprendžia tokie patys modeliai, kaip ir šiuo baigiamuoju projektu pasirinktas kurti giliaisiais konvoliuciniais neuroniniais tinklais grįstas modelis [33].

1.7. Apibendrinimas

Saulės elektrinės kokybę ir jos priežiūros paprastumą lemia pirminių ir fundamentaliųjų jos komponentų sklandus veikimas. Dėl saulės elektrinės struktūros, saulės fotomodulių kokybei turi būti skiriamas itin didelis dėmesys, tam, kad pradėjus eksploatuoti elektrinę būtų galima ramiai laukti numatytos investicinės grąžos. Saulės elektrinėse pasitaikantys defektai sunkiausiai aptinkami ir pajaučiami, būtent saulės fotomoduliuose. Jų įvairovė ir negalėjimas sekti saulės elektrinės gyvybingumo modulio lygmeniu lemia, kad dėl saulės fotomodulių defektų dažnai prarandama nemažai energijos. Siekiant išsaugoti šią energiją ir ją paversti galimybe uždirbti svarbi elektrinės gedimų prevencija. Ją užtikrinti eksploatuotojui yra pigiausia tada, kai moduliai dar nėra palikę gamyklos. Patogiausiai tai atliekama naudojant elektroliuminescencines saulės fotomodulių nuotraukas įvairiuose gamybos etapuose. Šiose nuotraukose patalpina labai daug informacijos, kadangi jų kokybė yra aukšta, o prieinamumas didelis. Iššūkį kelia tik tai, jog jų pateiktą informaciją reikia atidžiai apdoroti. Šiuo metu vaizdų apdorojimo funkciją atlieka apmokyti darbuotojai, tačiau pastebėta, jog šios informacijos apdorojimui puikiai tinka ir dirbtinis intelektas. Dirbtinis intelektas savo plačiąja funkcija apima daugybę sričių, tačiau tokioms automatizavimo užduotims labai gerai tinka mašininio mokymo grįsti įrankiai. Mašininio mokymo grįstas įrankis, kartą apmokytas, gali atlikti tą pačią, pasikartojančią užduotį daugybę kartų, be perstojo, nepavargdamas ir neprarasdamas tikslumo. Gilinantis, numatyta, jog šios užduoties struktūra grįsta vaizdų atpažinimo algoritmais ir geriausiai tam tinkamas yra giliais konvoliuciniais tinklais grįstas mašininio mokymo algoritmas. Sekančiuose skyriuose apžvelgiami minėto algoritmo sudėtis, sudarymo procesas, apmokymo ypatybės ir gautieji rezultatai.

2. Metodologijos apžvalga

2.1. Giluminių konvoliucinių neuroninių tinklų struktūra ir veikimas

Giluminiai konvoliuciniai neuroniniai tinklai (toliau – GKNT) pasižymi vienos krypties informacijos tekėjimu iš įvesties centrų link išvesties. Yra keletas GKNT struktūrų, tačiau dažniausiai jie turi sudaryti iš pasikartojančių modulių. Modulį sudarom konvoliucinis ir sujungimo sluoksnis. Tuomet seką bent vienas arba daugiau nei vienas klasifikavimo užduotį atliekantis sluoksnis (angl. *fully connected layer*). Būtent šių modulių kiekis t.y. daugiau nei vienas, ir reiškia, jog modulis yra gilusis.

GKNT veikia pateikdamas vaizdą į įvesties centrus, tuomet informacija keliauja per konvoliucinio sluoksnio centrą, kur yra tikrinami tam tikri vaizdo požymiai, šie požymiai yra perduodami į sujungimo sluoksnį, kuriame bandoma identifikuoti, būtent kokios savybės buvo rastos. Vėliau tai keliauja arba į sekantį analogišką modulį ieškoti kitų savybių arba į klasifikavimo užduotį atliekanti sluoksnį kuriame yra nusprendžiama ar gautas atsakymas surinko daugiausia atitikimo taškų iš grupės lygiagrečių sluoksnių.

2.1.1. Įvesties centrų reikšmė

Įvesties centruose svarbu atkreipti dėmesį jog tikrinamo atvaizdo pikselis turi keletą reikšmių. Šios reikšmės susijusios su pikselio spalva, kuri priklauso nuo pikselio esančių raudonos žalios ir mėlynos spalvos dedamosios dažniausiai išreikštų tarp 0 ir 225 reikšmės. Taip pat pikselio aprašomas ryškumas arba jei tai nespaltotas vaizdas, baltos ir juodos spalvos santykis. Būtina atkreipti dėmesį, jog kiekvienas atvaizdo pikselis turi savo įvesties centrą.

2.1.2. Konvoliucinių sluoksnių veikimas

Konvoliuciniai sluoksniai tarnauja kaip požymių išgavėjai, ir tokiu būdu jie studijuoja savo įvesties atvaizdų ypatybes. Neuronai konvoliuciniame sluoksniuose yra išsidėstę į specialius žemėlapius – matricas (angl. *kernel*). Kiekvienas neuronas žemėlapyje turi imlų lauką, kuris yra prijungtas prie kaimynystės neuronų ankstesniame sluoksnyje per komplektą mokimosi svorių. Įvestys yra konvoliucinamos su studijuotais svoriais, kad apskaičiuotų naują žemėlapią ir konvoliutuotus rezultatus nusiunčia per netiesinę aktyvacijos funkciją. Visi neuronai žemėlapio viduje turi svorius, kurie yra suvaržyti būti lygūs. Tačiau, skirtingi žemėlapiai to paties konvoliucinio sluoksnio viduje turi skirtingus svorius, kad keli požymiai galėtų būti ištraukti skirtingose vietose

2.1.3. Sujungimo sluoksnis ir jo reikšmė

Sujungimo sluoksnių tikslas sumažinti dimensijų kiekį skirtą požymių žemėlapiams ir tokiu būdu pasiekti erdvinį netolygumą. Pradžioje, tai buvo įprasta praktika, tam kad panaudotų vidutinius sujungimo sukaupimo sluoksnius, kad skleistų vidurkį visų įvesties verčių, mažos kaimynystės atvaizdo į kitą sluoksnį. Tačiau, naujesniuose modeliuose, maksimalus sukaupimo sluoksnių sujungimas išskleidžia maksimalią vertę ne tik lauko viduje, bet ir į kitą sluoksnį.

2.1.4. Požymių iškėlimo sluoksnis

Keli konvoliuciniai ir sujungimo sluoksniai yra sudedami vienas po kito, kad ištrauktų abstraktesnį ypatybės pavaizdavimą toliau keliaujant per tinklą. Visiškai susiję sluoksniai, kurie seka konvoliucinius ir sujungimo sluoksnius interpretuoja ypatybes iškeltas buvusių sluoksnių ir įvykdo funkciją aukštesniame lygyje. Klasifikacijos problemoms spręsti, panaudojamas minkšto maksimumo operatorius pačiame modelio gale. Pastebėta, kad pakeitus minkšto maksimumo operatoriaus į atraminių vektorius mašina (angl. SVM) priartėjama prie pagerinto klasifikacijos tikslumo.

2.1.5. Atvirkštinio skleidimo modelio taikymas

Vienas iš paprasčiausių algoritmų — yra algoritmas su atvirkštiniu skleidimu (angl. *back-propagation*). Šiam algoritmui būtina žinoti teisingą rezultatą. NT skiriama užduotis, tada skaičiuojama paklaida, palyginus NT rezultatą su iš anksto žinomu rezultatu. Paklaida verčiama „baudos“ signalais, kurie siunčiami atgal į tinklą. Atsižvelgdami į kanalų pralaidumą, jie išsiskaido. Tuomet kanalai „baudžiami“ — svoris mažinamas tiek, kiek „baudos“ taškų juose susikaupę. Kanalai, prisidėję prie teisingo rezultato, „giriami“ - jų svoriai didinami. Taip kartojama su įvairiais pavyzdžiais iki tol, kol mokytojas nusprendžia, kad tinklas pasiruošęs darbui.

Įrodyta, kad paprasčiausi neurono svorių atsiradimo matematiniai modeliai, naudojami klasifikavimui ir prognozavimui, mokant juos pasitelkus jau minėtą iteracinį algoritmą, pereidami nuo pačių primityviausių matematine prasme svorių įvertinimo metodų prie vis sudėtingesnių. Teoriškai ištirta įvairių svorių įvertinimo metodų tikslumo priklausomybė nuo panaudoto mokymui duomenų kiekio. Iš to seka, kad, pavyzdžiui, esant mažam duomenų kiekiui, neuroną reikia mokyti trumpai, o turint daug duomenų — ilgai. Šis teorinis rezultatas sudarė prielaidą efektyvesniems NT mokymo ir panaudojimo metodams pasiūlyti. Kita vertus, darant prielaidą, kad jau minėtas matematinis neurono modelis tikrai egzistuoja gamtoje, seka, jog per pastarąjį šimtmetį dauguma sukurtų įvertinimo ir sprendimų priėmimo metodų, paremtų tikimybių teorija ir matematine statistika parametru, jau daugelį milijonų metų veikia gamtoje.

Matematiniai modeliai, naudojami neurono mokymo bei jo metu apdorojamam informacijos procesui aprašyti, turi universalumo savybių ir tinka įvairiems reiškiniams, tiriamiems kitose mokslo šakose, aprašyti. Pavyzdžiui, žaliavų, paslaugų, gaminių kainų visuma sudaro daugiamatį vektorių, kuris laikui bėgant kinta. Šį kainų vektorius kitimą galima aprašyti pasitelkus iteracinį mokymo algoritmą, o kainų adaptavimuisi prie besikeičiančios rinkos nagrinėti galima panaudoti jau žinomus matematinius rezultatus. Analogiška situacija ir su gamybinėmis mokymosi kreivėmis. Žinoma, kad gamybai vystantis kiekvieno naujo gaminio (nesvarbu, kas tai bebūtų — televizorius ar atliktas vertimas) savikaina mažėja. Kainos kitimo priklausomybė nuo pagamintų gaminių kiekio vadinama gamybine mokymosi kreive. Aprašius gamybos parametrus daugiamatį vektoriumi, gamybos tobulėjimą galima analizuoti kaip iteracinį mokymąsi, analogišką tam, kuris naudojamas neurono mokymuisi nagrinėti.

2.1.6. Giluminių konvoliucinių neuroninių tinklų taikymas

Nuotraukų atpažinimui ir skirtingų požymių juose atpažinimui šio darbo apimtyje tiriamas dirbtinio intelekto modelis pagrįstas giliaisiais konvoliuciniais neuroniniais tinklais (toliau - GKNT). Šis tinklas tinkamai apmokintas sugeba atpažinti nuotraukoje vaizduojamo objekto nelygumus ir kontūro pasikeitimus, o fotomodulio EL nuotraukoje fiksuojami pasikeitimai būtent tokie ir yra. Šie GKNT sudaromi atsižvelgiant į norimo tirti objekto pobūdį. Dažniausiai neuroninį tinklą sudaro įvesties centrai, paslėptieji sluoksniai ir išvesties centrai. Nuotraukų atpažinime, vienas įvesties centras atitinka vieną pikselį, todėl atsižvelgiant į tai jog GKNT su daug įvesties centrų savo skaičiavimus atliktų labai ilgai, reikia naudoti kuo mažesnio dydžio nuotraukas pavyzdžiui 254x254 raiškos nuotraukas. Giluminiai konvoliuciniai neuroniniai tinklai pasižymi ir tuo, jog gali išskirti atskirus nuotraukos bruožus, kiekvieną kartą atlikdamas atpažinimą ieškotų vis kitokių nuotraukos ypatybių.

2.2. Modelio prasmė

Siekiant palengvinti saulės fotomodulių gamybos procesą suteikiant didesnę kokybės patikros tikslumą prie tinkamų priemonių priskiriama kompiuterinė rega. Kompiuterinė rega (angl. *computer vision*) pasižymi geresnėmis tikslumo ir atidumo savybėmis ir gali peržiūrėti daugiau objektų per minutę, nei operatorius, dirbantis gamybos linijoje. Kompiuterinė rega ypač dažnai naudojama ten, kur gaminami objektai gamybos linija keliauja dideliu greičiu, tai yra tokiu, greičiu, prie kurio žmogus nebegali sukcentruoti žvilgsnio į keliaujantį gaminį, pavyzdžiui lentos lentpjūvėje, birių produktų gamyklos ar kitos didelį kiekį produkcijos gaminančios įmonės. Saulės fotomodulių gamyboje, tokių didelių produkcijos keliavimo greičių nėra, tačiau kokybės patikros kompleksiskumas yra gan platus. Fotomodulyje dažniausiai būna bent 60 fotoelementų ir gali siekti iki 300 fotoelementų, naudojant fotoelemento pjaustymo technologijas. Kiekviename iš šių fotoelementų yra nuo 10 iki 20 vietų kur yra tikėtina, jog pasireikš įtrūkimas. Taigi objektų, kuriuos reikia peržvelgti operatoriui yra nemažai. Šioje vietoje, kompiuteriniai regai tai ne iššūkis. Atlikus fotografiją, kompiuteris gali matyti visus elementus iškart. Tikimasi jog tokios regos pritaikymas gali sudaryti geresnes sąlygas fotomodulių gamintojų augimui ir žmonių darbo kokybės pagerinimui. Šiai užduočiai įgyvendinti pasirinkta mašininio mokymo programa dar vadinama gilusis konvoliuciniais neuroninis tinklas. Kai išnagrinėta pirmame skyriuje, šie tinklai pasižymi specifine struktūra, nuo jos ir pradedamas kurti modelis.

2.3. Modelio kūrimo eiga

Modelio kūrimas atliekamas sekančia tvarka:

1. Surenkami pagrindiniai tiriamieji duomenys – EL nuotraukos;
2. Nuotraukos išrūšiuojamos į klases – nustatoma ar modulis geras ar blogas;
3. Duomenys apdirbami į programai tinkamą formatą – nuotraukų dydžio keitimas;
4. Duomenys normalizuojami – vertės normalizuojamas tarp 0 ir 1;
5. Duomenys paskirstomi į mokymosi ir testavimo imtis;
6. Atliekamas programos apmokymas;
7. Atliekama programos optimizacija, ieškoma geriausių tinklo struktūrų ir parametrų;
8. Optimizuotas modelis naudojamas nuotraukoms klasifikuoti.

Plačiau apie kiekvieną iš šių žingsnių, kaip jie buvo atlikti ir kokie pagrindiniai iššūkiai pasitaiko atliekant tyrimą, aprašoma sekančiuose skyriuose.


2.4. Modelio kūrimas

2.4.1. Duomenų rinkimas

Kuriant numatytą giliais neuroniniais tinklais grįstą modelį pasirinkta naudoti tensorflow.keras mašininio mokymo biblioteka. Siekiant apmokyti neuroninį tinklą, jam būtina gauti plačią imtį darbinių duomenų. Šie duomenys, naudojami siekiant supažindinti NT su pagrindine jo užduoties sąlyga t.y. atskirti, kurie iš pateiktų vaizdų vaizduoja brokuotą produktą, o kurie yra nebrotuoti. Duomenys – šiuo atveju saulės fotomodulių nuotraukos, turi būti tokio paties dydžio, nuotraukų pikselių aukštis ir plotis turi sutapti, kadangi vėliau šios nuotraukos yra transformuojamos. Vienos tinkamiausių nuotraukų yra nespaltotos, taip vienam pikseliui priskiriant tik vieną reikšmę – šviesumą, kadangi spalvotose nuotraukose taip pat priskiriama ir trijų pagrindinių spalvų kiekiai, o tai trikdytų numatytą kodą. Nuotraukas, kurios buvo tinkamos pagal aukščiau aprašytus parametrus suteikė lietuviškų saulės fotomodulių gamyklą Vilniuje įsikūrusi Mokslininkų g. 6a UAB „Solitek cells“. Jų gamybos grandinėje esančios elektroluominescencinės kameros fiksuodavo pagamintų modulių EL nuotraukas ir talpindavo jas į duomenų bazę. Įmonė suteikė 29015 atskiras nuotraukas atliktas jų gaminamiems moduliams.

2.4.2. Ekspertinis klasifikavimas


Mašininis mokymas vis dar geriausiai ir paprasčiausiai veikia gaudamas ekspertų išvada apie turimą duomenų imtį (9 pav.). Šios išvados, dažniausiai atitinka siektinų klasifikavimo grupių specifiką. Šio baigiamojo darbo apimtyje išskirtos dvi klasifikavimo grupės – geri ir blogi moduliai. Taigi ekspertinio klasifikavimo metu būtina nurodyti kurie iš turimų duomenų pakliūva į gerus modulius atitinkančią grupę, o kurie į blogus modulius atitinkančią grupę. Nustatyta jog iš turimų duomenų – EL nuotraukų 28934 vienetai buvo gerų modulių. O 81 blogų – brokuotų modulių nuotraukos. Vadovaujantis atliktais bandymais nustatyta, jog geriausi rezultatai pasiekiami naudojant maždaug vienodą gerų ir blogų modulių nuotraukų skaičių, todėl teko sumažinti gerų modulių skaičių iki 227 ir padidinti blogų modulių skaičių iki 162 vienetų jas paprasčiausiai apverčiant 180 laipsnių, taip, praktiškai, sukuriant papildomus blogų modulių pavydžius.



9 pav. Ekspertinio klasifikavimo procesas mašiniam mokymui

2.4.3. Duomenų transformavimas

Siekiant paversti esamas nuotraukas į NT suprantamą duomenų seką, reikalinga atlikti keletą jų transformavimo veiksmų. Pirmiausia, nuotraukoms suteikiamas vienos dimensijos pikselio reikšmės matas. Dažniausiai nuotraukos turi tris spalvos dimensijas – raudona, mėlyna ir žalia. Mūsų atveju, siektina, jog nuotraukos turėtų tik ryškumo dimensiją ir būtų nespaltvotos (10 pav.).



10 pav. Nuotraukos spalvos kanalų pavertimas į pilkąją skalę

2.4.4. Duomenų normalizavimas

Atliekant duomenų peržiūrą, NT geriausiai veikia, jei duomenys yra patalpinti į tam tikrus rėžius ir jų peržengia. Taip numatoma, kad NT gauna duomenų vertę ne kiekvienam duomenų mėginiui skirtingo formato, bet visuomet tuose pačiuose intervaluose. Praktiškai, tai pasiekama dalinant duomenis iš didžiausios jų vertės. Mūsų atveju, tai 255. Skaitmeniniuose vaizdiniuose arba nuotraukose, tai yra didžiausias vertė suteikiama vienam pikseliui vienoje iš dimensijų tokių kaip viena iš spalvų – pavyzdžiui raudona. Vadovaujantis 2.3.3. skyriumi, žinome, jog mūsų nuotraukose buvo tik viena vertė – ryškumas. Taigi pikseliai, kurie bus visiškai balti, turėtų 255 vertę, o juodi 0 vertę. NT geriausia, jei šie duomenys patalpinti tarp 0 ir 1. Taigi, visų nuotraukų pikselius daliname

iš 255, taip gauname, kad baltas pikselis turės vertę lygią 1, o juodas 0. Šis procesas vadinamas duomenų normalizavimu.

2.4.5. Duomenų skirstymas mokymui ir testavimui

Neuroniniuose tinkluose visi duomenys skirstomi į skirtus NT mokymui ir NT testavimui. Neuroninių tinklų mokymas atliekamas supažindinant tinklą su turimais duomenimis nusakant, kurie duomenys priklauso vienai ar kitai kategorijai. Taip tinklas susipažįsta kuriai kategorijai priskiriami tam tikri faktoriai arba požymiai. Pavyzdžiui, apmokant tinklą atskirti brokuotą įrenginį, nuo gero, jis bus supažindintas jog brokuotame įrenginyje yra įtrūkimų, o geruose jų nėra, taigi tinklas atlikdamas savo numatytą darbo funkciją ieškos įtrūkimų, kai bus prašoma atskirti ar produktas geras, ar blogas. Didžiausias NT privalumas yra tai, jog jam nereikia nurodyti specifinės grupės defektų, kurių NT turi ieškoti t.y. defektai gali būti ne tik įtrūkimai, tačiau ir begalė kitų, dėl kurių, ekspertinio klasifikavimo metu, produktai buvo atskirti nuo gerųjų. Šis privalumas ypač naudingas sprendžiant labiau komplikuotus klausimus, tokius kaip gyvūnų, emocijų ar kitas realaus gyvenimo užduotis, kuomet žmogus gali klasifikuoti šiuos objektus be didelių pastangų, o tinklas, neturėdamas tikslaus klasės aprašymo, gali klasifikuoti objektus, tiesiog susipažinęs arba apsimokęs su dideliu kiekiu pavyzdžių, t.y. jau klasifikuotų duomenų.


Duomenų imtis skirta NT efektyvumo testavimui yra atskiriama nuo mokymui skirtų duomenų imties ir pateikiama kai tinklas jau yra apsimokęs. Testavimo duomenys atskiriami tam, kad būtų užtikrintas NT nešališkumas, t.y. tinklas gaudamas testavimo duomenis dar nebus jų matęs ir negalės vadovautis buvusiu patirtimi, o veikiau turės remtis mokymo duomenų suteiktomis įžvalgomis. Mokymo ir testavimo duomenys, dažniausiai skirstomi apytiksliai santykiu – 80-90 proc. turimų duomenų atidedama mokymui, likę 20-10 proc. testavimui. Pastabėta, jog panašaus santykio duomenų išskirstymas teikia geriausius rezultatus. Atliktame modelio kūrimo pasinaudotas santykis 90 proc. mokymui ir 10 proc. testavimui.

2.4.6. Modelio apmokymas

Modelio apmokymas buvo atliekamas įgyvendinant ankstesniuose skirsniuose aprašytas duomenų apdorojimo metodikas bei veiksmus ir galiausiai apdorotus duomenis pateikiant klasifikavimui skirtam neuroniniam tinklui, kuris yra pačiame gale bendro NT. Apdoroti duomenys, patalpinami į duomenų stulpelį (angl. *Flatten*) sluoksnį, kuriame yra 128 informacijos vienetai, kurie sekančiai pateikiami į klasifikatoriaus įvesties mazgus.

Svarbu paminėti, jog neatlikus duomenų apdirbimo, šiam klasifikatoriui tektų sudėtingesnis uždavinys, kadangi duomenų apdirbimo procese yra sumažinamas reikalingų įvesties mazgų kiekis. Tai įvykdoma pasitelkiant aktyvatoriaus (angl. *Conv2D*) ir požymio iškėlimo (angl. *MaxPooling2D*) sluoksnius. Aktyvatorių variantų yra keletas, vieni jų pasižymi greitesniu veikimu, tačiau mažesniu tikslumu kiti sugeba sugrąžinti NT į teisingą kelią, jei pastebima jog paklaidos išauga. Modelio kūrimui buvo pasitelktas universalus aktyvatorius ReLU. Požymio iškėlimo sluoksnyje atliekama paprasta aritmetinė seka. Naudojami žemėlapiai - matricos, kurie yra perdengiami virš duomenų, mūsų atveju nuotraukos pikselių ir naudojant žemėlapyje užkoduotą logiką iškeliami reikiama vertė.


Taip yra sumažinamas pikselių skaičius ir savo ruožtu reikiamų klasifikatoriaus įvesties mazgų skaičius, tačiau išlaikoma pagrindinė informacija esanti nuotraukoje (11 pav.).



11 pav. Duomenų iškėlimo sluoksnyje naudojamos matricos loginis atvaizdavimas

Matricų, kurios gali iškelti šią informaciją, yra ne vieno tipo ir jos gali atlikti skirtingus aritmetinius veiksmus – sudėti, atimti, perstumti ir t.t. Naudojant skirtingas matricas, gaunami geresni ar blogesni rezultatai. Dažniausiai tai priklauso nuo užduoties pobūdžio, pavyzdžiui veidų atpažinimas naudos vieną matricą, o defektų aptikimas kitą.

Klasifikatorius, gavęs 128 įvesties duomenis jiems suteikia tam tikrus svorius, kurie yra paslėpti viduje NT, dėl to ši dalis dar vadinama paslėptaisiais neuroniniais sluoksniais. Klasifikatorius išvesties sluoksnyje sumažėja iki dviejų mazgų. Viena iš jų pateikiama klasifikatoriaus spėjama tikimybė, jog modulis yra geras, o kita spėjama tikimybė, jog modulis yra blogas. Toliau naudojant suapvalinimo sluoksnį (softmax) didesnioji tikimybė, parenkama kaip reikšmė 1 (12 pav.). Ši reikmė parodo, kurioje iš klasių, geroje ar blogoje, turėtų būti patalpintas pateiktas modulis. Kitaip sakant,



12 pav. Klasifikatoriaus principinė struktūra

jei didesnė tikimybė jog modulis geras, jam bus priskirta skaitinė reikšmė 1 ir prie klasės „good“ bus patalpinamas skaitmuo 1.

2.4.7. Modelio naudojimas

Kuriamo NT naudos išreiškimui ir galutiniam pritaikymui skirta taip pat nemažai dėmesio. Šio modelio taiklumas ir patikimumas priimti kaip vieni svarbiausių ir naudą kuriančių parametrų. Numatomam praktiniam taikymui taip pat svarbi greitaveika. Pats modelis pasižymi paprastumu. Jis susideda iš dviejų pagrindinių failų. Pirmasis skirtas NT apmokymui, antrasis skirtas tiesioginiam šio įrankio naudojimui. Taigi, antrasis failas pavadinimu klasifikatorius.ipynb, naudoja gaminamo modelio elektroliuminescencinę nuotrauką kaip įvesties duomenis. Atlikus šios nuotraukos transformavimą iki NT tinkamo dydžio yra atliekama klasifikavimo procedūra. Natūralu, jog šis procesas turi būti atliktas ypač greitai, kadangi gaminamų modulių kiekis ir patikros srautas numatomas ganėtinai didelis. Siektina užtikrinti, jog greitaveika nepakenktų modelio tikslumui norint nusakyti kuriai klasei priklauso gaminamas modelis. Atlikus klasifikavimo procedūrą, modelis pateikia atsakymą aiškia ir lengvai matoma forma. Šio modelio naudojimo pavyzdys tikroje modulių gamykloje numatomas pritaikyti artimiausiu metu.

2.4.8. Modelio kokybės parametrai

Šiame poskyryje aprašomi pagrindiniai modelio kokybės parametrai nusakantys kaip neuroninius tinklais grįstas modelis gerai atlieka savo darbą. Šiame darbe stebėti parametrai pasirinkti vadovaujantis logika, jog geriausia NT konfigūracija pateikia teisingiausius spėjimus su mažiausiomis paklaidomis. Šie parametrai yra:

- Taiklumas (angl. *Accuracy*)
- Tikslumas (angl. *Precision*)
- Atkūrimas (angl. *Recall*)
- F1 įvertis (angl. *F1 score*)
- Kappa įvertis (angl. *Kappa*)
- Plotas po kreive (trump. PPK) (angl. *AUC*)

Taiklumas nusako modelio suteikiamą pasitikėjimo savo spėjimu dydį. Kitaip sakant, modelio nusakomą tikimybę, kad jo spėjimas yra teisingas. Arba jei kalbama apie testavimo taiklumą, tuomet jis nusako kiek spėjimų buvo teisingi iš visų buvusių spėjimų. Tačiau taiklumas pats iš savęs kartais gali būti ir klaidinantis. Šio modelio atveju, turimos tik dvi klasės, gera ir bloga, tačiau atvejais, kai jų yra ne dvi, o daugiau ir duomenų imtys pasiskirsčiusios netolygiai tarp naudojamų klasių, galima susidurti su problema, kai modelis rodo jog yra taiklus, tačiau neatlieka tinkamo darbo. Pavyzdžiui, diagnozuojant ligas, nustatyta jog modelio taiklumas yra 91%. Iš pirmo žvilgsnio tai yra geras rodiklis, nes iš 100 pacientų, 91 kartus buvo nustatyta tinkama liga. Tačiau jei šis modelis iš 91 pacientų 90-imčiai nustatė vieną ligą – nepiktybinį vėžį, kai tokių realybėje buvo 91 tuomet labai gerai, tačiau iš likusių 9 pacientų, teisingai buvo nustatytas tik 1 teisingas atvejis – piktybinis vėžys, tuomet rezultatai labai blogi. Taigi sumoje, 91 teisingas atsakymas iš 100 galimų skamba gerai, tačiau

tai neatspindi ar modelis sugeba atskirti klases ir kaip gerai gali klasifikuoti skirtingų klasių duomenis. Šiai užduočiai pasitelkiami kiti tikslumo rodikliai aprašomi toliau.

Tikslumas kokybės parametras apskaičiuoja spėjimų tikslumą atsižvelgdamas į turimas klases. Parametras sukuria du vietinius kintamuosius TP – teisingai priskirtas (anlg. *true positive*) ir FP - neteisingai priskirtas (angl. *false positive*), kurie vėliau naudojami parametro apskaičiavimui. Teisingai priskirtas reiškia jog NT spėjimas, patikrinus pagal turimus ekspertinius duomenų išskirstymus, yra teisingas ir klasifikavimas atliktas tinkamai. Neteisingai priskirtas reiškia jog NT atliko klaidą priskirdamas duomenis ne tai klasei. Iš esmės atliekamas paprastas aritmetinis veiksmas – teisingai priskirtas padalinamas iš teisingai priskirtas ir neteisingai priskirtas sumos. Jei neteisingai priskirtų buvo 0, tai galutiniam rezultate rodiklis tikslumas lygus 1.

$$\text{Tikslumas} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{Tikslumas} = \frac{100}{100+1} = 0,991$$

Atkūrimas – šis kokybės parametras labai panašus į prieš tai aprašytą tikslumas kokybės parametą, tačiau naudoja kitą vietinį klaidos kintamąjį FN – neteisingai atmetas (angl. *false negative*). Šis kintamasis reiškia jog NT gavęs tinkamos klasės duomenis juos atmetė.

$$\text{Atkūrimas} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{Atkūrimas} = \frac{100}{100 + 0} = 1$$

F1 įvertis - parametras nusako bendrinį naudojamo modelio našumą ir būklę. Šiam parametrai apskaičiuoti, naudojami aukščiau aprašyti kokybės parametrai tikslumas ir atkūrimas, taigi F1 įvertis sugeba apimti teisingai priskirtus spėjimus, kurie savyje turi informaciją apie tai, kaip gerai modelis gali aprašyti teisingus spėjimus ir taip pat savo apimtyje geba įvertinti atmetų spėjimų kokybę. Bendruoju atveju, F1 įvertis aprašoma šia formule:

$$\text{F1 įvertis} = 2 * \frac{\text{Tikslumas} * \text{Atkūrimas}}{\text{Tikslumas} + \text{Atkūrimas}} \quad (4)$$

arba

$$\text{F1 įvertis} = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \quad (5)$$

Statistiškai, šis parametras aprašo svartinį tikslumo ir atkūrimo vidurkį

Plotas po kreive (trump. PPK) (angl. *AUC - area under curve*) kokybės parametras aprašo kaip gerai modelis sugeba išvengti neteisingai priskirtų arba neteisingai atmetų klasifikavimo atvejų. PPK parametras vertinamas kaip geras, kai jo vertė yra tarp 0,8 ir 1.

2.5. Tiesinis klasifikavimo modelis

Atliekant modelio kūrimą ir analizę išsikeltas tikslas palyginti sukurta giliais neuroniniais tinklais grįstą modelį arba kitaip įvardinant sudėtingą modelį su tiesiniu klasifikatoriumi, kuris yra paprastas. Tiesinis klasifikavimo modelis (anlg. *linear classifier*) yra pagrįstas tikimybinio duomenų vertinimu. Kitaip sakant, jis vertina kokios yra tikimybė, jog tiriami duomenys tinka viena ar kitai klasei. Šis klasifikatorius, nebūtų mašininio mokymo modelis, jei neturėtų gilesnių duomenų apdirbimo ir analizės funkcijų. Tiesinis klasifikatorius yra tinkamas, kai užduotis yra paprasta, o duomenys aiškiai atskirti ir turi daug skirtingų požymių. Šiam klasifikatoriui nesudėtinga vertinti duomenis skirstant juos į keletą klasių, taigi jis pasižymi geba atskirti duomenis nesudarant tarp jų nereikalingų ryšių. Taip pat, tiesinis klasifikatorius pasižymi itin didele sparta. Jo apmokymo laikas žymiai trumpesnis už kitų klasifikatorių ir juolab už giliais neuroniniais tinklais grįstų klasifikatorių. Tačiau nesugebėjimas suteikti duomenų sąsajoms tinkamo svorio ir atrasti esamas koreliacijas apriboja šio klasifikatoriaus veikimą iki paprastų užduočių.

Tiesinio klasifikatoriaus, kuris buvo pasitelktas palyginimui atlikti veikimo principas pagrįstas tikimybių teorijoje naudojama Bajeso teorema, kuri pateikta žemiau:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (6)$$

Čia $P(A)$ – apriorinė A hipotezės tikimybė;

$P(A|B)$ – A hipotezės tikimybė, atsirandant B įvykiui (aposteriorinė tikimybė);

$P(B|A)$ – įvykio B atsiradimo tikimybė esant teisingai A hipotezei;

$P(B)$ – įvykio B tikimybė.

Tiesinio klasifikatoriaus kūrimui panaudoti tie patys duomenų ruošiniai kaip ir sudėtingojo modelio kūrime. Pasirinkta naudoti nuotraukas, kurių raiška atitinka sudėtingojo modelio įvesties rezoliuciją tam jog būtų užtikrinta jog rezultatai yra tinkami.


Lygindami sukurta giliais neuroniniais tinklais grįstą modelį su tiesiniu klasifikatoriumi siekiame pateikti priežastis, kodėl pasirinktai užduočiai buvo reikalinga kurti sudėtingą ir ilgai apmokyti trunkantį klasifikavimo modelį. Sekančiame skyriuje apžvelgiami šių dviejų klasifikatorių rezultatai ir palyginamas jų apmokymo greitis.

3. Rezultatai

Apžvelgiant gautus rezultatus tikimasi supažindinti su naudotų modelių kokybės rodikliais ir jų kaita, bei pagrįsti užduotyse išsikeltų problemų aktualumą. Rezultatų apžvalgos metu dėmesys skiriamas pagrindiniam baigiamojo projekto modeliui paremto giliaisiais neuroniniais tinklais ir šio modelio palyginimui su paprastu tiesiniu klasifikavimo modeliu, kuris buvo sudarytas vadovaujantis šio darbo 2.5. skyriuje išdėstyta tiesinio modelio veikimo logika.


3.1. GKNT modelio sudarymo rezultatai

GKNT klasifikatoriui sudaryti pasitelkti duomenys, gauti iš saulės fotomodulių gamintojo, kuriuose pateikiamos 389 elektroluminescencinės nuotraukos darytos naujos saulės fotomodulių gamybos linijos pirmaisiais darbo mėnesiais. Nuotraukų raiška – 3764 x 2296 arba bendras pikselių skaičius lygus – 8642144. Numatyta jog tokios aukštos raiškos nuotraukos negali būti efektyviai naudojamos vaizdų atpažinimui dėl 2.4.6. skyriuje aprašytų priežasčių. Todėl išsiaiškinta, kokios bendros raiškos nuotraukos turėtų būti naudojamos siekiant turėti greitai veikiantį klasifikavimo modelį ir tuo pačiu, patikimus rezultatus. Atlikus taiklumo priklausomybės nuo pikselių skaičiaus analizę sudarytas 13 paveiksle pavaizduotas grafikas iš kurio matyti jog didėjantis bendras pikselių kiekis, turi nedidelę įtaką modelio tikslumo gerėjimui. Pastebėtina, jog modelis įsisotina ir pasiekia tinkamą tikslumą, kuris yra lygus 0,9946, ties 39936 pikselių skaičiumi. Tokios pikselių skaičius, išlaikant nuotraukos kraštinių santykius (santykis 1,639:1) lyginant su originaliomis nuotraukomis yra lygus 256 pikseliai horizontaliai ir 156 pikseliai vertikalčiai.



13 pav. Taiklumo priklausomybės nuo bendro pikselių skaičiaus grafikas

Siekiant užtikrinti jog pasirinktas pikselių kiekis iš tiesų yra optimalus ir neverta didinti bendro pikselių skaičiaus įvertinta laiko priklausomybė nuo nuotraukų raiškos tikrinant kiek laiko modelis užtrunka apsimokinti naudojant įvairios raiškos nuotraukas.




14 pav. Modelio apmokymo trukmė priklausomai nuo bendro pikselių skaičiaus

Kaip matyti iš 14 pav. laikas, kuris yra reikalingas apmokinti modelį didėja tiesiškai, priklausomai nuo kompleksiško t.y. nuo pikselių esančių nuotraukose bendro skaičiaus. Taigi galime daryti išvadą jog sprendimas naudotis 256x156 raiškos nuotraukomis buvo teisingas ir pagrįstas siekiu taupyti laiką, nesumažinant modelio spėjimo tikslumo.

Kitas faktorius, kuris smarkiai prailgina modelio apmokymo laiką, yra epochų skaičius, naudojamas modeliui apmokinti. Šis skaičius, kaip tai aprašoma 1.4. skyriuje nusako kiek kartų, modelis bus supažindinamas su atsitiktinai išrinktais duomenimis. Po kiek vienos epochos, modelio taiklumas didėja, kadangi modelis gauna vis daugiau duomenų. Svarbu, kad modelis negautų tų pačių duomenų, per kiekvieną epochą, todėl yra naudojama funkcija k dalinė imtis (angl. *k folds*). Ji turimus treniravimo ir testavimo duomenis išskaido į nurodytą dalių skaičių, pavyzdžiui 10. Taip išskaidyti duomenys užtikrina jog modelis nenaudos nuotraukų, kurios gali būti panašios, dėl savo grupavimo duomenų bazėje. Išdalinti duomenų į skirtingas dalis nepakanka, reikia ir atlikti pradinės imties (angl. *seed*) perslinkimą, kuris nurodo modeliui nuo kelinto duomens pradėti skaičiuoti pradžią. Modeliui

kurti pasirinkta, kad šis perslinkimas būtų atliekamas atsitiktine tvarka, t.y. išrenkama atsitiktinė nuotrauka, kuri priimama kaip primoji. Siekiant nustatyti optimalų epochų skaičių, atlikti bandymai vertinant modelio taiklumą ir klydimo rezultatus kiekvienos epochos metu. Bandymų rezultatai pateikiami 15 pav.




15 pav. Modelio taiklumo ir klaidos rezultato kreivės, priklausomai nuo nuotraukų raiškos

Paveiksle pateiktos taiklumo kreivės skirtingos raiškos nuotraukoms. Modelio taiklumą parodo kreivės esančio viršutinėje paveikslėlio dalyje. Jos yra suskirstytos į apmokymo (mėlyna) (angl. *train*) ir testavimo (oranžinė) (angl. *test*) kreives, siekiant pateikti realų vaizdą, kaip modelis tobulėja kiekvienos epochos metu. Pastebėta, jog skirtingos raiškos nuotraukoms reikalingas skirtingas epochų skaičius siekiant, kad modelis įsisotintų ir pateiktų tenkinamus rezultatus. Kuo didesnės raiškos nuotrauka, tuo mažiau epochų prireikė, kad modelis pasiektų norimą taiklumo rezultatą. Tai yra, todėl, nes iš didesnės raiškos nuotraukos galima išskirti daugiau požymių su kuriais susipažinęs, NT gali atlikti tikslius klasifikavimo uždavinius. Kaip matome iš X+2 Pav. žemos raiškos (64 pikseliai horizontaliai ir 39 pikseliai vertikalčiai) nuotraukoms reikia daugiau nei 20 epochų, kad tinklas pasiektų norimą taiklumo lygį. Vidutinės raiškos (256 pikseliai horizontaliai ir 156 pikseliai vertikalčiai) nuotraukoms, pakanka ir mažiau nei 20 epochų t.y. apie 12, o dar aukštesnės raiškos (753 pikseliai horizontaliai ir 459 pikseliai vertikalčiai) nuotraukoms, reikia tik šešių epochų, kad pasiektų norimus taiklumo rezultatus. Tačiau, kaip minėta anksčiau, dėl savo kompleksiskumo, didesnės raiškos nuotraukų naudojimas pareikalauja daugiau laiko - apie pusės valandos, tam kad būtų apmokintas NT. Taip pat apžvelgiama, kokie yra modelio klydimo rezultatai (angl. *model loss*). Šie rodikliai parodo kiek modelis buvo netaiklus, spėdamas duomenų klasę. Klydimo rezultatai, kitaip nei taiklumo neturėtų būti traktuojami kaip absoliučioji vieneto dalis arba procentai. Šie rezultatai parodo sumą gautų paklaidų testavimo ir apmokymo metu. Kaip matome žemesnės raiškos nuotraukas naudojantis NT klaidas sumažina iki minimalios vertės tik pačiame apmokymo gale, t.y.

apie dvidešimtą epochą. Svarbu pastebėti ir tai, jog matomi paklaidų šuoliai, nenusistovėjimas ties viena reikšme. Taip nutinka todėl, nes modelis, nors ir apsimokinęs, atranda vis naujų požymių, kurių dar nebuvo pakankamai dažnai peržvelgęs ir tai lemia didesnes paklaidas. Vidutinės raiškos nuotraukoms, paklaidų suma, sumažėja iki tinkamo lygio ir nusistovi ties viena reikšme ties 12 epocha, o naudojant didesnės raiškos nuotraukas, klydimo rezultatai sumažėja ir nusistovi itin greitai t.y. ties 3 epocha. Taip nutinka todėl, nes didesnės raiškos nuotraukos, nesulieja pikselių, kurie, savo ruožtu gali imituoti klaidą. Taigi daroma išvada jog pagal taiklumo pasiekimo greitį ir pagal klydimo rezultatus, tolimesniam naudojimui yra tikslinga naudoti vidutinės raiškos (256 pikseliai horizontaliai ir 156 pikseliai vertikaliai) nuotraukas.

Papildomai, siekiant įsitikinti jog modelis atlikdamas savo darbą nepersisotina ir jo rezultatai nepradedą prastėti, buvo atlikta taiklumo ir klydimo rezultato rodiklių analizė, modeliui užduodant atlikti 2000 pakartotinių epochų. Per tokį didelį kiekį epochų, modelis, jei jame nėra numatyta papildomų apsaugos nuo persisotinimo funkcijų, turėtų pradėti rodyti ženklus jog modelio testavimo rezultatai prastėja. Rezultatai pateikiami 16 paveiksle. Iš jų matome, jog net ir po 2000 epochų testavimo



16 pav. Modelio persisotinimo tikrinimo grafikas

rezultatai nesuprastėjo, kaip tai numato 1.5. skyriuje aprašyta analizė bei iliustruoja X Pav. To priežastis – mašininiame mokyme dažnai naudojamas išankstinio sustabdymo algoritmas (anlg. *early-stopping*). Jis taip pat aprašomas 1.5. šio darbo skyriuje. Kaip ir nurodoma aprašyme, algoritmas sugeba suvaldyti modelį prieš jam persisotinant ir norint gali sustabdyti tolimesnį

persisotinimą. Tačiau šiuo atveju, algoritmas tiesiog atstato modelio parametrus į geriausius buvusius ir taip leidžia modeliui atlikti ir 2000 epochų.

Kurtam modeliui taip pat apskaičiuoti kiti svarbūs modelio taiklumo ir patikimumo parametrai. Jų skaičiavimui naudoti vidurkiai iš penkių pakartotinių vertinimų išvedant tikrinamų parametrų vidurį ir apskaičiuojant standartinį nuokrypį. Jie pateikti 5 lentelėje.

5 lentelė. Modelio taiklumo ir patikimumo parametrų suvestinė

Parametras	Taiklumas	Tikslumas	Atkūrimas	F1 įvertis	Kappa	PPK
Vidurkis	0,993	0,983	0,997	0,991	0,978	0,987
Standartinis nuokrypis	0,016	0,027	0,010	0,014	0,033	0,018

Parametrų aprašymai pateikti 2.4.8. skyriuje. Vertinant gautuosius rodiklius, matyti jog modelis yra labai tikslus. Tikimybė, kad modelis teisingai klasifikuos pateiktą nuotrauką siekia net 99,3%. Kiti modelio rodikliai taip pat rodo, kad modelio spėjimai buvo teisingi ir tikėtinų nuokrypių vertės yra nedidelės. Numatyta jog modelio tikslumas siekia 0,983 santykinio vieneto dalies, atkūrimas artimas vienetai, F1 įvertis, kuris apibendrina modelio kokybę įvertintas aukštu balu – 0,991 santykinio vieneto. Kappa parametras siekia 0,978 s.v. o PPK, kuris savo ruožtu taip pat parodo koks tikslus yra modelis siekia – 0,987 s.v. Standartiniai nuokrypiai, šiems parametrams taip pat yra labai geri ir siekia 0,016 taiklumo parametru, 0,027 tikslumo parametru, 0,01 atkūrimui, F1 įverčiui 0,014, Kappa 0,033 ir PPK 0,018.

Modelio pritaikomumas taip pat vertinamas ir pagal tai, kaip greitai ištreniruotas GKNT gales atlikti klasifikavimo užduotį. Tai svarbu todėl, nes norima algoritmą įdiegti į produkto gamybos liniją, taigi algoritmas turi pasižymėti greitaveika. Tam patikrinti, sukurta virtuali programa, kurios klasifikavimo variklis yra parengtasis modelis. Ši programa leidžia įkelti nuotrauką ir gauti atsakymą kokios būklės tai modulis geras ar blogas. Jos klasifikavimo greitis siekia 0,496 sekundės. Toks laukimo intervalas yra priimtinas integruojant tokio pobūdžio kokybės patikros programinę įrangą. Galima daryti išvadą, jog sukurtas modelis, grįstas giliaisiais neuroniniais tinklais yra tikslus ir pasižymi tinkama greitaveika.


3.2. GKNT ir tiesinio klasifikatoriaus palyginimo rezultatai

Siekiant patvirtinti jog kokybės patikros pagerinimo, naudojant vaizdų atpažinimą, uždaviniui spręsti reikalingas kompleksinis sprendinys atliktas palyginimas tarp sudėtingo ir paprasto, tiesinio, modelio. Tiesinio modelio struktūra ir veikimo principas aprašyti 2.5. skyriuje. Sekančiose lentelėse ir grafikuose atvaizduojamas skirtumas tarp tiesinio modelio ir GKNT modelio.

6 lentelė. Tiesinio ir GKNT grįsto modelių kokybės parametrų vidurkių palyginimas

Parametras	Taiklumas	Tikslumas	Atkūrimas	F1 įvertis	Kappa	PPK	Laikas, s
Tiesinis modelis	0,510	0,558	0,440	0,446	0,159	0,516	0,119
GKNT modelis	0,993	0,983	0,997	0,991	0,978	0,987	259

Kaip matome iš 6 lentelės, visi pagrindiniai tiesinio modelio kokybės rodikliai yra prastesni nei GKNT. Vienintelis rodiklis, kuris yra geresnis nei GKNT, tai apmokymui reikalingas laikas. Šiuo




17 pav. Modelių kokybės rodiklių vidurkių palyginimo grafikas

atžvilgiu, labiau kompleksinis modelis apmokymui reikalauja daug daugiau laiko ir kompiuterinių resursų. Pastebėta, jog nuotraukų raiškos reikšmėms didėjant virš 753x459 nebeužteko laisvai prieinamų vaizdo plokščių resursų gaunamų iš Google Colab, kurie leidžia naudotis 12 GB RAM.

17 pav. pateikiamas grafinis kokybės rodiklių atvaizdavimas. Matoma jog tiesinio modelio rodikliai dažnai yra net du kartus blogesni nei GKNT. Dažnu atveju, tiesinio modelio tikimybė labiau priminė atsitiktinį spėjimą, kadangi pasitikėtinas taiklumas tesiekė 50 procentų. 7 lentelėje pateikiami duomenys, atspindi tiesinio ir GKNT modelio standartinių nuokrypių skirtumus. Galime matyti, jog tiesinio modelio rezultatai yra daug mažiau patikimi dėl galimų standartinio nuokrypio įtakų.

7 lentelė. Tiesinio ir GKNT grįsto modelių kokybės parametrų standartinių nuokrypių palyginimas

Parametras	Taiklumas	Tikslumas	Atkūrimas	F1 įvertis	Kappa	PPK
Tiesinis modelis	0,066	0,129	0,234	0,135	0,309	0,047
GKNT modelis	0,016	0,027	0,010	0,014	0,033	0,018



18 pav. Modelių kokybės rodiklių standartinių nuokrypių palyginimo grafikas

Siekiant vizualiai atvaizduoti standartinių nuokrypių skirtumus tarp GKNT ir tiesinio modelio pateikiamas 18 pav. Jame matome jog standartiniai nuokrypiai yra žymiai didesni tiesinio modelio ir tai parodo koks nepatikimas yra modelis atlikti klasifikavimo uždavinį.

11	7,8
10,8	8,4

1) Tiesinis modelis

16	0
0	22

2) GKNT

19 pav. Modelių klaidų matricos

19 pav. pateikiamos klaidų matricos tiesiniam ir GKNT tinklui ir jos parodo, kiek kartų vidutiniškai modelis buvo teisus savo spėjime ir kiek kartų suklydo. Teisingi spėjimai pavaizduoti įstrižainėje iš kairio viršutinio kampo į dešinį apatinį, o klaidingi spėjimai atvaizduojami iš kairio apatinio kampo į dešinį viršutinį. Kaip matome 1) tiesinio modelio klaidų matricoje, modelis vidutiniškai atliko 18,6 klaidingus spėjimus ir tik 19,4 teisingu iš bendrų 38 spėjimų. GKNT modelis, atspėjo visus galimus spėjimus teisingai. Taigi daroma išvada, jog paprasto modelio nebūtų pakakę kokybės kontrolės uždavinio problemai spręsti ir turėjo būti sukurtas sudėtingesnis, tačiau itin tikslus vaizdų atpažinimo ir klasifikavimo modelis.

Išvados

1. Saulės elektrinėse naudojamų komponentų, saulės fotomodulių, gamybos metu, siekiant sumažinti brokuotų įrenginių kiekį atliekamų elektroluminescencinių nuotraukų vertinimui naudojamos priemonės priimtose kaip nevisiškai patikimos ir nustatyta jog siekiant sumažinti gaminamos įrangos broko kiekį tikslinga naudoti dirbtiniu intelektu grįstus vaizdų atpažinimo algoritmus.
2. Baigiamojo darbo apimtyje sukurtas giliaisiais neuroniniais tinklais grįstas vaizdų atpažinimo algoritmas, kurio pagrindinis tikslas padėti pastebėti brokuotus gaminius ir juos klasifikuoti į dvi klases – geras ir blogas modulis. Sukurtas modelis pasižymintį aukštu taiklumu – 0,993 s.v., ir žemu standartiniu nuokrypiu – 0,016. Kiti modelio tinkamumo parametrai taip pat parodė aukštas vertes.
3. Patikrinta modelio greitaveika atliekant klasifikavimo uždavinį siekiant įvertinti ar modelis tinkamas dirbti realiu laiku ir nestabdo gamybos proceso. Nustatyta greitaveika – 0,496 sekundės, daroma išvada jog gamybos proceso tokia greitaveika nestabdo.
4. Sukurtas sudėtingas modelis palygintas su tiesiniu klasifikatoriumi siekiant įsitikinti jog nepakanka paprasto klasifikatoriaus norint kokybiškai atlikti klasifikavimo uždavinį ir nustatyta jog tiesinis klasifikatorius yra visiškai netinkamas numatytai užduočiai, taigi daroma išvada jog giliais neuroniniais tinklais grįsto modelio kūrimas buvo pasirinktas teisingai.

Literatūros sąrašas

1. IEA (2020), Renewables 2020, IEA, Paris <https://www.iea.org/reports/renewables-2020>
2. New Cohesion Policy https://ec.europa.eu/regional_policy/en/2021_2027/
3. RENEWABLE POWER GENERATION COSTS IN 2019 https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2020/Jun/IRENA_Power_Generation_Costs_2019.pdf
4. How much power is lost in a hot-spot? A case study quantifying the effect of thermal anomalies in two utility scale PV power plants. <https://www.sciencedirect.com/science/article/pii/S0038092X20311245>
5. PV Module fault detection & diagnosis https://www.researchgate.net/publication/325538280_PV_Module_fault_detection_diagnosis
6. Safety issues in PV systems: Design choices for a secure fault detection and for preventing fire risk <https://www.sciencedirect.com/science/article/pii/S2214398X14000120>
7. Inverters Thermal Behavior https://www.researchgate.net/publication/318607982_Inverters_Thermal_Behavior
8. Reviewing Anomalies <https://docs.raptormaps.com/docs/reviewing-anomalies>
9. A directional-spectral approach to estimate temperature of outdoor PV panels <https://www.sciencedirect.com/science/article/abs/pii/S0038092X19302786>
10. OUTDOOR NON-DESTRUCTIVE INFRARED THERMOGRAPHY OF PHOTOVOLTAIC MODULES AND PLANTS FOR INSPECTION: IEC 62446-3 https://www.researchgate.net/publication/304624479_OUTDOOR_NON-DESTRUCTIVE_INFRARED_THERMOGRAPHY_OF_PHOTOVOLTAIC_MODULES_AND_PLANTS_FOR_INSPECTION_IEC_62446-3
11. PV system defects identification using Remotely Piloted Aircraft (RPA) based infrared (IR) imaging: A review <https://www.sciencedirect.com/science/article/abs/pii/S0038092X20306228>
12. Raptor Maps Adherence to IEC TS 62446-3:2017 <https://raptormaps.com/adherence-to-iec-ts-standards/>
13. Electroluminescence of silicon solar cells using a consumer grade digital camera https://www.researchgate.net/publication/311496425_Electroluminescence_of_silicon_solar_cells_using_a_consumer_grade_digital_camera
14. M. Dhimish and P. Mather, "Ultrafast High-Resolution Solar Cell Cracks Detection Process," in *IEEE Transactions on Industrial Informatics*, vol. 16, no. 7, pp. 4769-4777, July 2020, doi: [10.1109/TII.2019.2946210](https://doi.org/10.1109/TII.2019.2946210).
15. Efficient deep feature extraction and classification for identifying defective photovoltaic module cells in Electroluminescence images <https://www.sciencedirect.com/science/article/pii/S0957417421002517#f0010>
16. U. Jahn, M. Herz, M. Köntges, D. Parlevliet, M. Paggi, I. Tsanakas, J. S. Stein, K. A. Berger, S. Ranta, R. H. French, M. Richter, and T. Tanahashi, Review on Infrared and Electroluminescence Imaging for PV Field Applications. International Energy Agency, 2018. Available at: <https://iea-pvps.org/key-topics/review-on-ir-and-el-imaging-for-pv-field-applications/>

17. Realization and Verification of Deep Learning Models for Fault Detection and Diagnosis of Photovoltaic Modules
18. Ming Gan, Hui Hou, Xixiu Wu, Bo Liu, Yawei Yang, Changjun Xie, Machine learning algorithm selection for real-time energy management of hybrid energy ship, Energy Reports, Volume 8, Supplement 5, <https://doi.org/10.1016/j.egyr.2022.02.200>
19. Matthew Behnkea, Shenghan Guob, Weihong “Grace” Guob, Comparison of Early Stopping Neural Network and Random Forest for In-Situ Quality Prediction in Laser Based Additive Manufacturing <https://doi.org/10.1016/j.promfg.2021.06.065>
20. Bouchaib Zazoum, Solar photovoltaic power prediction using different machine learning methods, <https://doi.org/10.1016/j.egyr.2021.11.183>.
21. Konpat Preechakul, Sira Sriswasdi, Boonserm Kijisirikul, Ekapol Chuangsuwanich, Improved image classification explainability with high-accuracy heatmaps,. <https://doi.org/10.1016/j.isci.2022.103933>
22. İsmail Kırbaş, Ahmet Çifci, An effective and fast solution for classification of wood species: A deep transfer learning approach, <https://doi.org/10.1016/j.ecoinf.2022.101633>
23. Russakovsky, O., Deng, J., Su, H. et al. ImageNet Large Scale Visual Recognition Challenge. Int J Comput Vis 115, 211–252 (2015). <https://doi.org/10.1007/s11263-015-0816-y>
24. R. D. Devi, S. A. Nandhini, R. Hemalatha and S. Radha, "IoT Enabled Efficient Detection and Classification of Plant Diseases for Agricultural Applications," 2019 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET), 2019, pp. 447-451, doi: 10.1109/WiSPNET45539.2019.9032727
25. H. -C. Shin et al., "Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning," in IEEE Transactions on Medical Imaging, vol. 35, no. 5, pp. 1285-1298, May 2016, doi: 10.1109/TMI.2016.2528162
26. Don Chathurika Amarathunga, John Grundy, Hazel Parry, Alan Dorin, Methods of insect image capture and classification: A Systematic literature review, <https://doi.org/10.1016/j.atech.2021.100023>
27. W.S. Brooks, D.A. Lamb, S.J. Irvine, IR reflectance imaging for crystalline Si solar cell crack detection, IEEE J. Photovolt. 5 (2015) 1271e1275, <https://doi.org/10.1109/JPHOTOV.2015.2438636>
28. D.M. Tsai, G.N. Li, W.C. Li, W.Y. Chiu, Defect detection in multi-crystal solar cells using clustering with uniformity measures, Adv. Eng. Inf. 29 (2015) 419-430, <https://doi.org/10.1016/j.aei.2015.01.014>
29. O. Nos, W. Favre, F. Jay, F. Ozanne, A. Valla, J. Alvarez, D. Muñoz, P.J. Ribeyron, Quality control method based on photoluminescence imaging for the performance prediction of c-Si/a-Si: H heterojunction solar cells in industrial production lines, Sol. Energy Mater. Sol. Cells 144 (2016) 210e220, <https://doi.org/10.1016/j.solmat.2015.09.009>
30. R. Bhoopathy, O. Kunz, M. Juhl, T. Trupke, Z. Hameiri, Outdoor photoluminescence imaging of photovoltaic modules with sunlight excitation, Prog. Photovolt. Res. Appl. 26 (2018) 69e73, <https://doi.org/10.1002/pip.2946>
31. M. Fraz~ao, J.A. Silva, K. Lobato, J.M. Serra, Electroluminescence of silicon solar cells using a consumer grade digital camera, Measurement 99 (2017) 7e12, <https://doi.org/10.1016/j.measurement.2016.12.017>

32. Mahmoud Dhimish, Violeta Holmes, Solar cells micro crack detection technique using state-of-the-art electroluminescence imaging, <https://doi.org/10.1016/j.jsamd.2019.10.004>
33. Parsa Haidari, Ali Hajiahmad, Ali Jafari, Amin Nasiri, Deep learning-based model for fault classification in solar modules using infrared images, <https://doi.org/10.1016/j.seta.2022.102110>
34. Álvaro Huerta Herraiz, Alberto Pliego Marugán, Fausto Pedro García Márquez, Photovoltaic plant condition monitoring using thermal images analysis by convolutional neural network-based structure, <https://doi.org/10.1016/j.renene.2020.01.148>
35. Nallapaneni Manoj Kumar, K. Sudhakar, M. Samykano, V. Jayaseelan, On the technologies empowering drones for intelligent monitoring of solar photovoltaic power plants, <https://doi.org/10.1016/j.procs.2018.07.087>