



Kauno technologijos universitetas

Informatikos fakultetas

Giluoju mokymu grindžiamas paviršių defektų aptikimo tyrimas

Baigiamasis magistro krypties studijų projektas

Edita Mikalauskiene

Projekto autorė

Doc. dr. A. Lipnickas

Vadovas

Kaunas, 2020



Kauno technologijos universitetas

Informatikos fakultetas

Gilioju mokymu grindžiamas paviršių defektų aptikimo tyrimas

Baigiamasis magistro krypties studijų projektas

Informacinių sistemų inžinerijos studijų programa (6211BX009)

Edita Mikalauskienė

Projekto autorė

Doc. dr. Arūnas Lipnickas

Vadovas

Prof. dr. E. Vaičiukynas

Recenzentas

Kaunas, 2020



Kauno technologijos universitetas

Informatikos fakultetas

Edita Mikalauskiene

Giluoju mokymu grindžiamas paviršių defektų aptikimo tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Edita Mikalauskiene, baigiamasis projektas tema „Giluoju mokymu grindžiamas paviršių defektų aptikimo tyrimas“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

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

(vardą ir pavardę įrašyti ranka)

(parašas)

Mikalauskienė, Edita. Giliuoju mokymu grindžiamas paviršių defektų aptikimo tyrimas. Magistro baigiamasis projektas / vadovas doc. dr. Arūnas Lipnickas; Kauno technologijos universitetas, Informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Informacijos sistemos, Informatikos mokslai.

Reikšminiai žodžiai: defektas, neuroninis tinklas, aptikimo metodas.

Kaunas, 2020. 76 p.

Santrauka

Tiriamąjį darbo tikslas yra iširti defektų aptikimo metodus, kurie tiksliausiai ir greičiausiai aptiktų defektą skirtinguose paviršiuose. Siekiant užsibrėžto tikslo, išnagrinėta dirbtinai suformuota skirtingų paviršių duomenų bazė „DAGM“, skirtingi neuroniniai tinklai ir kitų mokslininkų atlikti defektų aptikimo tyrimai. Nagrinėtuose tyrimuose yra atliekami defektų aptikimai iš „DAGM“ duomenų bazės, tačiau aptikimas atliekamas kiekvienai vaizdo klasei atskirai. Todėl pasirinkta palyginti defektų aptikimo metodus, kai neuroninis tinklas yra mokomas aptikti defektą kiekvienoje vaizdo klasei atskirai ir visose vaizdų klasėse kartu.

Sukurti du defektų aptikimo metodai: klasikinis ir hierarchinis. Klasikinio defektų aptikimo metodas sukurtas mokant neuroninį tinklą aptikti defektą neatsižvelgiant į vaizdo klasę. Kuriant klasikinį metodą atliktas trijų „U-Net“ neuroninio tinklo struktūrų kokybės įverčių palyginimas. Hierarchinio metodo atveju defektų aptikimas yra atliekamas pagal vaizdo klasę. Taip pat hierarchiniam defektų aptikimo metodui yra reikalingas vaizdo klasės atpažinimas, kuriam naudojamas klasifikavimo neuroninis tinklas. Vaizdo klasių atpažinimui yra atliekamas dviejų neuroninių tinklų kokybės įverčių palyginimas. Pagal aukščiausius neuroninių tinklų kokybės įverčius sukurti metodai, kurie naudojami skirtingų paviršių defektų aptikimo sistemoje.

Sukurta skirtingų paviršių defektų aptikimo sistema leidžia palyginti sukurtus skirtingus defektų aptikimo metodus su pasirinktu kiekiu vaizdų iš „DAGM“ duomenų bazės. Aptikimo rezultatai yra pateikiami sistemos rezultatų peržiūros lange arba suformuojamoje ataskaitoje. Skirtingų paviršių defektų aptikimo sistema gali sukurti metodų palyginimo ataskaitą, jeigu tokiems patiems vaizdams yra atliktas defektų aptikimas su hierarchiniu ir klasikiniu metodu.

Gauti tyrimo rezultatai naudingi gamybos įmonėms, kurios pagal pasiūlytą defektų aptikimo metodą, gali aptikti defektus skirtinguose paviršiuose. Taip pat naudingi kitiems mokslininkams, kurie domisi neuroniniais tinklais ir jų pritaikymu. Gauti tyrimo rezultatai parodo, kad defektas gali būti aptinkamas nežinant vaizdo klasės ir kai neuroninis tinklas yra mokytas aptikti defektą nepriklausomai nuo vaizdo klasės.

Mikalauskienė, Edita. Study of Deep Learning Based Detection of Surface Defects. Master's Final Degree Project / supervisor abbreviation of the position, prof. Dr. Arūnas Lipnickas; Faculty of Informatics, Kaunas University of Technology.

Study field and area (study field group): Information Systems, Computing.

Keywords: defect, neural network, defection method.

Kaunas, 2020. 76.

Summary

The aim of the research is to investigate the methods of defect detection that would more accurately and more quickly detect a defect on different surfaces. In order to achieve the set goal, the artificially formed DAGM database of different surfaces, different neural networks and defect detection studies performed by other scientists were examined. In the examined studies, defect detections are performed from the DAGM database but the detection is performed for each image class separately.

Two defect detection methods have been developed: classical and hierarchical. The classical method was developed by teaching the neural network to detect a defect regardless of the image class. In the development of the classical method, a comparison of the quality estimates of three U-Net neural network structures was performed. In the case of the hierarchical method, defect detection was performed according to the image class. Hierarchical method requires image class recognition using a classification neural network. For image class recognition, a comparison of the quality estimates of two neural networks was performed. Methods developed according to the highest neural network quality estimates which are used in the system of detection of defects of different surfaces

The developed system allows to compare different defects detection methods with the selected number of images from DAGM database. The results are presented in the system review window or in generated report if it is necessary. The system can generate comparison report of the classical and hierarchical methods of defect detection for the same group of images.

The obtained research results are useful for manufacturing companies which according to the proposed method can detect defects on different surfaces. It also benefit other researchers interested in neural networks and their applications. The results of the study show that a defect can be detected without knowing the image class and when the neural network is trained to detect defect regardless of the image class.

Turinys

Lentelių sąrašas.....	8
Paveikslų sąrašas.....	9
Santrumpų ir terminų sąrašas	11
Įvadas	12
1. Skirtingų paviršių defektų aptikimo metodų probleminės srities analizė.....	13
1.1.Paviršinių defektų „DAGM“ duomenų bazė	13
1.2.Dirbtiniai neuroniniai tinklai	14
1.3.Konvoliuciniai neuroniniai tinklai	15
1.3.1. „R-CNN“ neuroninis tinklas	16
1.3.2. „VGG-16“, „VGG-19“ konvoliucinis neuroninis tinklas.....	17
1.3.3. „ResNet“ neuroninis tinklas.....	18
1.3.4. „MobileNet“, „Inception-v3“ neuroniniai tinklai	18
1.3.5. „U-Net“ neuroninis tinklas	19
1.4.Aptikimo kokybės įverčiai.....	21
1.5.Skirtingų paviršių defektų aptikimo metodo naudotojai	22
1.6.Esamų defektų aptikimo metodų analizė.....	22
1.7.Siekiamo sprendimo apibrėžimas	24
1.8.Analizės išvados.....	24
2. Skirtingų paviršių defektų aptikimo sistemos reikalavimų specifikacija ir projektas, formalus aprašas	25
2.1.Reikalavimų specifikacija	25
2.2.Dalykinės srities modelis.....	39
2.3.Naudotojų sąsajos modelis	39
3. Skirtingų paviršių defektų aptikimo sistemos realizacijos projektas	45
3.1.Skirtingų paviršių defektų aptikimo sistemos realizacijos priemonė.....	45
3.2.Skirtingų paviršių defektų aptikimo sistemos architektūra	45
3.3.Duomenų bazės modelis.....	47
3.4.Diegimo diagrama.....	53
4. Skirtingų paviršių defektų aptikimo metodų ir sistemos realizacija ir testavimas	54
4.1.Duomenų paruošimas	54
4.2.Neuroninio tinklo mokymo rezultatai	54
4.2.1. Hierarchinio metodo sukūrimo kokybės įverčiai	55
4.2.2. Klasikinio metodo sukūrimo kokybės įverčiai	59
4.2.3. Neuroninio tinklo mokymų apibendrinimas	65
4.3.Testavimo scenarijai ir duomenys.....	65
5. Eksperimentinis defektų aptikimo metodų tyrimas.....	69
5.1.Eksperimento planas	69
5.2.Eksperimento rezultatai.....	69
5.3.Sprendimo veikimo ir savybių analizė	73
5.4.Sprendimo taikymo rekomendacijos.....	73
Išvados.....	74
Literatūros sąrašas.....	75
Priedai	77
1priedas. Sistemos testavimo rezultatai	78

2priedas. Naudotojo vadovas.....	110
3priedas. Pirmo eksperimento rezultatai.....	121
4priedas. Antro eksperimento rezultatai	142
5priedas. Trečio eksperimento rezultatai	163

Lentelių sąrašas

1.1 lentelė. Mokymo ir testavimo pasiskirstymas „DAGM“ duomenų bazėje [2]	14
1.2 lentelė. Septynių klasių aprašymo pavyzdys „U-Net“ tinkle [7].....	19
1.3 lentelė. Pasiskirstymo matrica [16].....	21
1.4 lentelė. Esamų sprendimų palyginimas.....	23
2.1 lentelė. PA „Pasirinkti defektų aptikimo metodą“ aprašymas	26
2.2 lentelė. PA „Pasirinkti vaizdų katalogą“ aprašymas	27
2.3 lentelė. PA „Inicijuoti defektų aptikimą“ aprašymas	28
2.4 lentelė. PA „Aptikti defektą klasikiniu metodu“ aprašymas.....	31
2.5 lentelė. PA „Aptikti defektą hierarchiniu metodu“ aprašymas	33
2.6 lentelė. PA „Peržiūrėti rezultatą“ aprašymas	34
2.7 lentelė. PA „Generuoti rezultatų ataskaitą“ aprašymas	36
2.8 lentelė. PA „Peržiūrėti išmokyto klasikinio metodo kokybės įverčius“ aprašymas.....	37
2.9 lentelė. PA „Peržiūrėti išmokyto hierarchinio metodo kokybės įverčius“ aprašymas	38
2.10 lentelė. Skirtingų paviršių defektų aptikimo sistemos pagrindinio lango aprašymas.....	40
2.11 lentelė. Rezultatų peržiūros lango aprašymas	41
2.12 lentelė. Ataskaitos formavimo lango aprašymas	42
2.13 lentelė. Klasikinio metodo defektų aptikimo kokybės įverčių peržiūros lango aprašymas	43
2.14 lentelė. Hierarchinio metodo defektų aptikimo kokybės įverčių peržiūros lango aprašymas... ..	44
3.1 lentelė. „Python“ duomenų failų aprašymas	46
3.2 lentelė. Lentelės „Apmokymo_rezultatas“ atributai.....	48
3.3 lentelė. Lentelės „Apmokytas_tinklas“ atributai.....	49
3.4 lentelė. Lentelės „Aptikimo_laikas“ atributai	49
3.5 lentelė. Lentelės „Aptikimo_metodas“ atributai	50
3.6 lentelė. Lentelės „Defektas“ atributai	50
3.7 lentelė. Lentelės „Neuroninis_tinklas“ atributai	50
3.8 lentelė. Lentelės „Pasirinkimai“ atributai	51
3.9 lentelė. Lentelės „Paviršiaus_vaizdas“ atributai	51
3.10 lentelė. Lentelės „Vaizdu_katalogas“ atributai	51
3.11 lentelė. Lentelės „Vaizdu_klase“ atributai.....	51
3.12 lentelė. Lentelės „Vaizdu_tipas“ atributai.....	52
4.1 lentelė. Vaizdų kiekis neuroninio tinklo mokymui ir validavimui.....	54
4.2 lentelė. Vaizdo klasių klasifikavimo kokybės įverčiai	55
4.3 lentelė. „Inception-v3“ neuroninio tinklo mokymo pasiskirstymo matrica	55
4.4 lentelė. Šešių vaizdo klasių aptikimo kokybės įverčiai	56
4.5 lentelė. Kiekvienos vaizdo klasės aptikimo kokybės įverčiai, kai neuroninis tinklas mokytas iš karto su visų klasių vaizdais	60
4.6 lentelė. Bendri visų klasių aptikimo kokybės įverčiai, kai neuroninis tinklas mokytas iš karto su visų klasių vaizdais	65
4.7 lentelė Skirtingų paviršių defektų aptikimo sistemos testavimo scenarijai	65
5.1 lentelė Pirmo eksperimento rezultatai.....	69
5.2 lentelė Antro eksperimento rezultatai	71
5.3 lentelė Trečio eksperimento rezultatai.....	72

Paveikslų sąrašas

1.1 pav. „DAGM“ paviršinių defektų duomenų bazės pavyzdžiai [2]	13
1.2 pav. DNT architektūra [3]	15
1.3 pav. „ConvNet“ tinklo semantinis segmentavimas [7]	16
1.4 pav. „R-CNN“ regiono atpažinimo konvoliucinis tinklas [8]	16
1.5 pav. „VGG-16“ struktūros pavyzdys [9]	17
1.6 pav. „ResNet“ architektūros blokų diagrama [10]	18
1.7 pav. „U-Net“ neuroninio tinklo struktūra [14]	20
1.8 pav. Enkoderio ir dekoderio dalies sluoksniai [14]	20
1.9 pav. „U-Net“ neuroninio tinklo struktūra, patobulinta su „ASPP“ [15]	21
2.1 pav. Skirtingų paviršinių defektų aptikimo sistemos panaudojimo atvejų diagrama	25
2.2 pav. „Pasirinkti defektų aptikimo metodą“ veiklos diagrama	26
2.3 pav. „Pasirinkti vaizdų katalogą“ veiklos diagrama	27
2.4 pav. PA „Inicijuoti defektų aptikimą“ veiklos diagrama	28
2.5 pav. PA „Aptikti defektą klasikiniu metodu“ proceso diagrama	30
2.6 pav. PA „Aptikti defektą hierarchiniu metodu“ veiklos diagrama	32
2.7 pav. PA „Peržiūrėti rezultatą“ veiklos diagrama	34
2.8 pav. PA „Generuoti rezultatų ataskaitą“ veiklos diagrama	36
2.9 pav. PA „Peržiūrėti išmokyto klasikinio metodo kokybės įverčius“ veiklos diagrama	37
2.10 pav. PA „Peržiūrėti išmokyto hierarchinio metodo kokybės įverčius“ veiklos diagrama	38
2.11 pav. Dalykinės srities modelis	39
2.12 pav. Skirtingų paviršių defektų aptikimo sistemos pagrindinis langas	40
2.13 pav. Rezultatų peržiūros langas	41
2.14 pav. Ataskaitos formavimo langas	42
2.15 pav. Klasikinio metodo defektų aptikimo kokybės įverčių peržiūros langas	43
2.16 pav. Hierarchinio metodo defektų aptikimo kokybės įverčių peržiūros langas	44
3.1 pav. Skirtingų paviršių defektų aptikimo sistemos architektūros modelis	46
3.2 pav. Skirtingų paviršių defektų aptikimo sistemos duomenų bazės schema	48
3.3 pav. Skirtingų paviršių defektų aptikimo sistemos diegimo diagrama	53
4.1 pav. Pirmos klasės defekto aptikimas su struktūra „Unet4“ hierarchiniame metode	57
4.2 pav. Pirmos klasės defekto aptikimas su struktūra „Unet4_res_aspp“ hierarchiniame metode	57
4.3 pav. Trečios klasės defekto aptikimas su struktūra „Unet4“ hierarchiniame metode	58
4.4 pav. Trečios klasės defekto aptikimas su struktūra „Unet4_res“ hierarchiniame metode	58
4.5 pav. Trečios klasės defekto aptikimas su struktūra „Unet4_res_aspp“ hierarchiniame metode	59
4.6 pav. Pirmos klasės defekto aptikimas su struktūra „Unet4_res“ klasikiniame metode	61
4.7 pav. Pirmos klasės defekto aptikimas su struktūra „Unet4_res_aspp“ klasikiniame metode	61
4.8 pav. Antros klasės defekto aptikimas su struktūra „Unet4“ klasikiniame metode	62
4.9 pav. Antros klasės defekto aptikimas su struktūra „Unet4_res“ klasikiniame metode	62
4.10 pav. Antros klasės defekto aptikimas su struktūra „Unet4_res_aspp“ klasikiniame metode	63
4.11 pav. Ketvirtos klasės defekto aptikimas su struktūra „Unet4“ klasikiniame metode	63
4.12 pav. Ketvirtos klasės defekto aptikimas su struktūra „Unet4_res_aspp“ klasikiniame metode	64
4.13 pav. Ketvirtos klasės defekto aptikimas su struktūra „Unet4“ klasikiniame metode	64
5.1 pav. Pirmu eksperimentu klaidingai aptiktas defektas hierarchiniu metodu 1	70
5.2 pav. Pirmu eksperimentu klaidingai aptiktas defektas hierarchiniu metodu 2	70
5.3 pav. Antru eksperimentu klaidingai aptiktas defektas klasikiniu metodu 1	71

5.4 pav. Antru eksperimentu klaidingai aptiktas defektas klasikiniu metodu 2	71
5.5 pav. Trečiu eksperimentu neaptiktas defektas klasikiniu metodu.....	72
5.6 pav. Trečiu eksperimentu aptiktas defektas hierarchiniu metodu	72

Santrumpų ir terminų sąrašas

Santrumpos:

Doc. – docentas;

DNT – dirbtinis neuroninis tinklas;

Dr. – daktaras;

PA – panaudos atvejis;

Prof. – profesorius.

Terminai:

Aktorius – su sistema sąveikaujantis naudotojas arba kita išorinė sistema.

Asociacija – ryšys tarp dviejų klasių tarpusavyje sujungtų.

Artefaktas – klasifikatorius, vaizduojantis tam tikrą fizinį subjektą, informacijos dalį, kuri naudojama arba gaunama programinės įrangos kūrimo proceso metu arba diegiant ir eksploatuojant sistemą.

BPMN – verslo procesų modeliavimo notacija.

Dekoderis – informacijos apdorojimo ir perdavimo įtaisas gaunamai informacijai iššifruoti ir išversti jai į priimančiai sistemai suprantamą kalbą.

Enkoderis – analoginis arba skaitmeninis keitiklis, kurio išėjime gaunamas analoginis signalas arba tam tikras impulsų skaičius.

Kryptingoji asociacija – ryšys, kuris nurodo klasių kreipimosi kryptį.

Panaudos atvejis – apibrėžia vieną naudotojui matomą ir jo atliekamą funkciją siekiant konkretaus tikslo.

Python – interaktyvi programavimo kalba, kuri leidžia naudoti keletą programavimo stilių: objektinį, struktūrinį, funkcinį, aspektinį.

Sistemos naudotojas – apibrėžia vaidmenį informacinėje sistemoje, kurį vykdo išorinis objektas, sąveikaudamas su sistema.

UML – vieninga modeliavimo kalba.

Tenzorius – geometrinis objektas, kuris susideda iš sumos komponentų, kurios yra transformuojamos pagal tiesinius sąryšius.

Įvadas

Gamyboje yra svarbi gaminamos produkcijos kokybė ir kuo didesnis pagamintų gaminių kiekis. Tačiau ne visada pavyksta suderinti produkcijos kokybę ir kiekį optimaliam bei įmonę tenkinančiam rezultatui. Gaminamos produkcijos įvairovė gali būti didelė, todėl turi būti nustatomas metodas, kuris leistų užtikrinti skirtingų gaminių kokybę.

Produkcijos įvairovė priklauso nuo formos, sudėties, paviršiaus, pagal kuriuos yra nustatoma ar produkcija atitinka kokybės reikalavimus. Paviršiaus defektas gali būti nustatomas eksperto, kai kokybės darbuotojas tikrina gaminamą produkciją, arba šis procesas gali būti atliekamas automatinio būdu. Tačiau esant skirtingiems paviršiams sistema turi nustatyti defektus, kad vieno paviršiaus vaizdas nebūtų priskiriamas kito paviršiaus defektui. Iš šito kilo darbo **problematika** – kokį metodą naudoti skirtingų paviršių defektams aptikti. Metodas, kuris tiksliau ir greičiau aptiktų skirtingų paviršių defektus, padėtų ir suteiktų papildomų žinių gamybos darbuotojams. Tiriomojo darbo rezultatai būtų **aktualūs** gamybos įmonėms, kurios gamina skirtingų paviršių produkciją ir atlieka kokybės tikrinimą rankiniu būdu. Nustatytu tiksliausiu ir greičiausiu metodu būtų galima automatizuoti kokybės tikrinimą gamyboje.

Tiriomojo darbo **tikslas** – ištirti defektų aptikimo tikslumą skirtinguose paviršiuose sukuriant vaizdų atpažinimo sistemas, grindžiamas dirbtiniu intelektu, prototipą.

Tiriomojo darbo **uždaviniai**:

1. Išnagrinėti DAGM defektų duomenų bazę;
2. Susipažinti ir palyginti skirtingus neuroninius tinklus;
3. Pateikti apibendrintus neuroninių tinklų mokymų su DAGM duomenų baze rezultatus;
4. Sukurti defektų aptikimo skirtinguose paviršiuose vaizdų atpažinimo sistemą;
5. Palyginti defektų aptikimo, skirtingų paviršių vaizduose, metodus;
6. Apibendrinti tyrimo rezultatus.

Tiriomojo darbo **objektas** – defektų aptikimo metodas. Defektų aptikimo metodas būtų sukuriamas naudojant neuroninius tinklus, kurie mokomi aptikti defektus iš pasirinktos duomenų bazės. Todėl tiriomojo darbo **sritis** – neuroniniai tinklai, kurių mokymo rezultatai lemia defektų aptikimo metodų tikslumą.

Atlikus tiriamąjį darbą būtų išsiaiškintas metodas, kuriuo būtų pasiekiamas didžiausias tikslumas ir greitis aptinkant defektą skirtinguose paviršiuose. Šio tyrimo rezultatai būtų **svarbūs** tiems, kurie ieško būdų pagerinti gamybos kokybę įmonėje. Nors tiriomojo darbo metu nagrinėjami ir eksperimentui naudojami dirbtinai sukurtos DAGM duomenų bazės vaizdai, bet ištirtą metodą būtų galima analogiškai panaudoti su realiais duomenimis.

Tiriomojo darbo **struktūra** – darbas susideda iš 76 puslapių, kuriuose yra 40 lentelių ir 47 paveikslai, ir 107 priedo lapų. Darbas sudarytas iš 5 skyrių – probleminės srities analizės, kuriamos sistemos reikalavimų specifikacijos, sistemos realizacijos projekto, neuroninio tinklo mokymo rezultatų apibendrinimo ir eksperimentinio defektų aptikimo metodų tyrimo.

1. Skirtingų paviršių defektų aptikimo metodų probleminės srities analizė


Šiame skyriuje analizuosime informaciją susijusią su tiriamajame darbe naudojamais metodais ir jų taikymu. Taip pat detalai išnagrinėsime tyrimo objektą, sritį ir problematiką. Pagal nustatytus kriterijus nagrinėsime esamus problemos sprendimus, kurie buvo gauti sprendžiant panašius uždavinius.

Analizės tikslas – praplėsti žinias apie neuroninius tinklus, kokybės vertinimą ir „DAGM“ duomenų bazę. Atlikus analizę turime suprasti, kokie yra neuroniniai tinklai, aptikimo kokybės įverčiai.

1.1. Paviršinių defektų „DAGM“ duomenų bazė

„DAGM“ – viešai prieinama paviršinių defektų duomenų bazė. Duomenų bazė atsirado laikotarpiu, kurio metu vyko konkurencija dėl paviršinių defektų aptikimo. Tada Vokietijos modelių atpažinimo asociacija („DAGM“) paskelbė duomenų rinkinį, kurį pavadino asociacijos garbei. Viename duomenų rinkinyje esantys vaizdai yra labai panašūs, tačiau kiekvienas duomenų rinkinys sukuriamas pagal skirtingas tekstūras ir defektus. Taip pat svarbu pastebėti, kad ne visi nuokrypiai nuo tekstūros būtinai yra defektai. [1]

Duomenų rinkinys susideda iš dirbtinai sukurtų tekstūruotų paviršių. „DAGM“ duomenų bazė susideda iš šešių skirtingų paviršių klasių, kuriose galima įžvelgti įvairius defektus (žr. 1.1 pav.).



1.1 pav. „DAGM“ paviršinių defektų duomenų bazės pavyzdžiai [2]

Tam tikras vaizdas yra teigiamas, jeigu jame yra defektas ir neigiamas, jeigu jame nėra defekto. Pateikiame mokymo ir testavimo pavyzdžių pasiskirstymas duomenų rinkinyje (žr. 1.1 lentelė). Visą duomenų rinkinį sudaro 8000 mokymo pavyzdžių, iš kurių 1046 yra su defektu, ir 8050 testavimo pavyzdžių, iš kurių 1054 yra su defektu. Defektai pateikiami elipsėmis, kurios parodo ne tik tai, kad tam tikrame vaizde yra defektas, bet tam tikrų mastu įtraukia sritis be defektų (žr. 1.1 pav.). Iš to seka, kad didelė dalis taškų yra netiksliai pažymimi ir tai gali daryti įtaką mokymo procesui. Tačiau ši problema yra tikėtina realaus pasaulio situacijose, nes labai tikslios paviršinių defektų anotacijos yra labai sudėtingos ir brangios [2].

1.1 lentelė. Mokymo ir testavimo pasiskirstymas „DAGM“ duomenų bazėje [2]

Paviršius	Mokymo pavyzdžiai		Testavimo pavyzdžiai	
	Teigiami	Neigiami	Teigiami	Neigiami
1	79	496	71	504
2	66	509	84	491
3	66	509	85	490
4	82	493	68	507
5	70	505	81	494
6	83	492	67	508

1.2. Dirbtiniai neuroniniai tinklai

Dirbtinis neuroninis tinklas (DNT) yra mašininio mokymosi metodas, kuris modeliuoja žmogaus smegenis ir susideda iš didelio kiekio dirbtinių neuronų. DNT neuronas yra linkęs turėti mažiau jungčių, nei biologinis neuronai. Kiekvienas DNT neuronas gauna daug įvesčių, kurioms yra taikoma aktyvinimo funkcija. Žinios apie mokymosi užduotį pateikiamos kaip pavyzdžiai, kurie vadinami mokymo pavyzdžiais [3].

Pateikiame apibendrinta dirbtinio neuroninio tinklo architektūra, kurią sudaro įvesties, paslėptas ir išvesties sluoksniai. Žemiau aptariamas kiekvienas iš paminėtų sluoksnių:

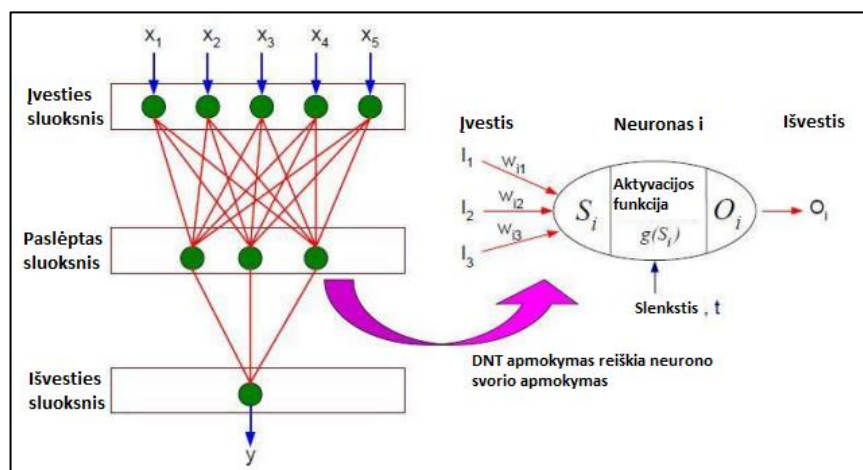
1. Įvesties sluoksnis – susijęs su išorine aplinka, kurio pagalba pradinis modelis yra pateikiamas neuroniniam tinklui. Įvesties sluoksnis taip pat gali reikšti būseną, pagal kurią mes mokome neuroninį tinklą [3].
2. Paslėptas sluoksnis – yra tarpinis sluoksnis tarp įvesties ir išvesties, kuris susideda iš paslėptų mazgų. Jeigu yra naudojamas paslėptas sluoksnis, yra taikoma aktyvinimo funkcija. Paslėpti magai yra neuronai, kurių nėra įvesties ar išvesties sluoksniuose [3].
3. Išvesties sluoksnis – pateikia išorinės aplinkos modelį, t. y. rezultatą. Išvesties neuronų skaičius turi būti tiesiogiai susijęs su darbo tipu, kurį atlieka neuroninis tinklas [3].

Aktyvinimo funkcijos – naudojamos neuroniniuose tinkluose norint apskaičiuoti svertinę įvesties ir poslinkio sumą, kuri nusprendžia ar neuronas gali būti atmestas. Manipuliuojama pateiktais duomenimis per tam tikrą gradiento apdorojimą. Dažniausiai tam yra naudojamas gradiento nusileidimas, pagal kurį yra kuriamas neuroninio tinklo išėjimas, kuriame yra duomenų parametrai. Kai kuriuose literatūros šaltiniuose galima atrasti, kad šios funkcijos yra vadinamos perdavimo funkcijomis [4].

Pagal [3], aktyvinimo funkcijos pasirenkamos priklausomai nuo problemos, kurią reikia išspręsti neuroniniam tinklui. Taip pat pateikiame keletą bendrų aktyvinimo funkcijų, kurias analizavo P. Sibi's, S. A. Jones ir P. Siddarth'as viename iš savo straipsnių [5]:

1. Tiesinė aktyvinimo funkcija (angl. *Linear activation function*) – gali pateikti tik teigiamus skaičius iš visos realiųjų skaičių aibės. Ši funkcija negali būti naudojama fiksuotame taške.
2. Iš dalies tiesinė aktyvinimo funkcija (angl. *Piecewise Linear activation function*) – ši aktyvinimo funkcija dar yra vadinama linijinės funkcijos prisotinimu ir gali turėti tiek dvejetainę, tiek bipolinę reikšmę išvestyje. Išvesties sritis yra nuo nulio iki vieneto.

3. Sigmoidinė funkcija (angl. *Sigmoidal function*) – gali sukurti tik teigiamus skaičius nuo nulio iki vieneto. Ši funkcija yra tinkamiausia mokymo duomenimis, kurie taip pat yra nuo nulio iki vieneto. Sigmoidinė funkcija yra viena iš daugiausiai naudojamų aktyvinimo funkcijų.
4. Gauso aktyvinimo funkcija (angl. *Gaussian activation function*) – gali būti naudojama, kai reikia tikslesnio valdymo aktyvinimo srityje. Išvesties sritis nulis arba vienetas: nulis, kai $x = \infty$ ir vienetas, kai $x = 0$.



1.2 pav. DNT architektūra [3]

Pateiktoje dirbtinio neuroninio tinklo architektūroje matosi visi paminėti sluoksniai ir aktyvinimo funkcija, kurios pagalba įvestis konvertuojama į išvestį (žr. 1.2 pav.).

Skirtingi neuroniniai tinklų tipai yra atsakingi už skirtingų uždavinių sprendimą. Vaizdų atpažinimo užduotims spręsti labiausiai paplitę ir dažniausiai naudojami yra konvoliuciniai (angl. *Convolutional*) neuroniniai tinklai. Todėl kitame skyriuje plačiau išanalizuosime konvoliucinius neuroninius tinklus.


1.3. Konvoliuciniai neuroniniai tinklai

Konvoliuciniai tinklai – mokomoji daugiapakopė architektūra, kuri yra sudaryta iš kelių etapų. Kiekvieno etapo įvestis ir išvestis yra masyvų rinkiniai, kurie yra vadinami funkcijų žemėlapiais. Pavyzdžiui, jei įvestis yra spalvotas vaizdas, tada kiekvienas funkcijų žemėlapis yra 2D matrica, kuri susideda iš įvesties vaizdo spalvų. Atitinkamai garso įvesties atveju kiekvienas funkcijų žemėlapis būtų 1D matrica, o filmuoto vaizdo – 3D matrica.

Išvestyje kiekvienas funkcijų žemėlapis reiškia tam tikrą funkciją, kuri ištraukiama iš visų įvesčių. Kiekvienas etapas sudarytas iš trijų sluoksnių: juostinio perdavimo sluoksnis (angl. *filter bank layer*), netiesiškojo sluoksnio (angl. *non-linearit layer*) ir funkcijų sluoksnio (angl. *a feature pooling layer*). Paprastas konvoliucinis tinklas susideda iš vieno, dviejų ar trijų sluoksnių, po kurių seka klasifikacijos modelis [6].

Vienas iš konvoliucinių tinklų yra „ConvNets“ tinklas, kuris buvo sukurtas vaizdo klasifikavimo problemai, kuri susideda iš skirtingų vaizdo prognozavimo objektų. Pirmiausiai buvo pritaikyti žinomi klasifikavimo tinklai, tokie kaip „VGG-16“ ar „Google“ tinklas (angl. *GoogleNet*), kurių pagalba buvo atliekamas pilnas vaizdo semantinis segmentavimas, paverčiant juos visiškai konvoliuciniais neuroniniais tinklais. Tačiau tiesiogiai pritaikant šiuos tinklus yra gaunama rupūs pikseliai išvestyje (mažas taškų tikslumas). Šių rezultatų patobulinimui, pasiūlyta apjungti gautus

rezultatus su žemesniuose sluoksniuose esančiomis aktyvinimo funkcijomis, naudojant praleistus ryšius [7].

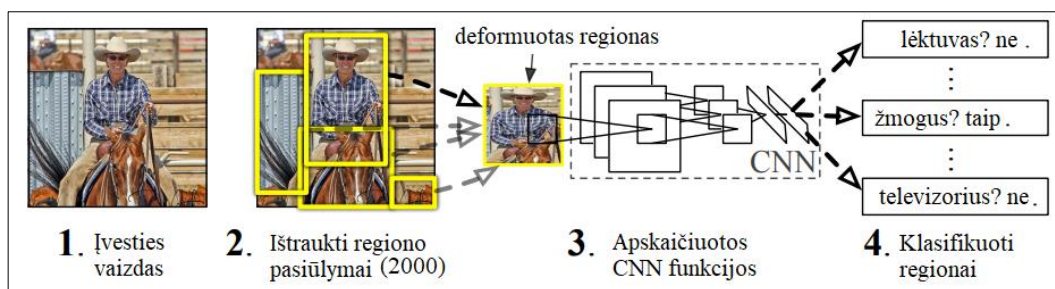


1.3 pav. „ConvNet“ tinklo semantinis segmentavimas [7]

Pateikiame pavyzdį, kuriame galime matyti kaip atrodo įvesties vaizdas po „ConvNet“ tinklo segmentavimo (žr. 1.3 pav.). Visų pirma viršuje pateikiama segmentavimo sistema, pagal kurią galima matyti seką, kada panaudojamas „ConvNet“ tinklas. Paveiklo apatinėje dalyje pateikiamas įvesties vaizdas ir „ConvNet“ tinklu sukurtas išvesties vaizdas. Išvesties vaizde galime pastebėti, kad kiekvienas objektas yra pažymimas skirtinga spalva, kuri nurodo, kad neuroninis tinklas gerai atpažįsta objektą.

1.3.1. „R-CNN“ neuroninis tinklas

Dalis neuroninių tinklų ne tik sugeba klasifikuoti objektus pagal tam tikrus požymius, bet gali nustatyti ir objekto tipą. Vienas iš tokių neuroninių tinklų yra „R-CNN“. Pagal [8], „R-CNN“ yra grindžiamas indukcinio perkėlimu, naudojant Pan ir Yang taksonomiją. „R-CNN“ mokymui naudojamas „ImageNet“ klasifikavimas ir duomenų rinkinys. Tinklas mokomas naudojant mokymą su mokytoju (angl. *supervision*) ir tada perkeliamas tinklas į tikslinę užduotį ir duomenų rinkiniui naudojamą koregavimą su mokytoju. Šis metodas yra susijęs su tradiciniu daugiafunkciniu mokymu, išskyrus tai, kad užduotis mokoma nuosekliai ir norima tikslinę užduotį atlikti gerai.



1.4 pav. „R-CNN“ regiono atpažinimo konvoliucinis tinklas [8]

Pateikiame pavyzdį kaip atrodo „R-CNN“ neuroninio tinklo vaizdo atpažinimas (žr. 1.4 pav.). „R-CNN“ tinklo pavyzdyje galima matyti, kaip įvesties vaizdas yra padalijamas į regionus (pagal tinklo metodiką vaizdas padalijamas į 2000 regionų) ir tada kiekvienam regionui yra apskaičiuojamos funkcijos, pagal kurias klasifikatorius atpažįsta vaizdo regioną.

Kitoks neuroninis tinklas yra „Greitasis R-CNN“, kuris įveda visą vaizdą į objektų pasiūlymų rinkinį. Neuroninis tinklas pirmiausia apdoroja visą vaizdą su keliais konvoliuciniais sluoksniais, kad būtų sukurtas funkcijų žemėlapis. Tada kiekvieno objekto dominuojančio regiono pasiūlymui, sujungimo sluoksnis išskiria fiksuoto ilgio funkcijų vektorių iš funkcijų žemėlapio. Kiekvienas funkcijų vektorius įeina į visiškai sujungtą sluoksnių seką, kuri pasiskirsto į du giminingus išvesties sluoksnius: pirmą, kuris sukuria normalizuotą eksponentinę funkciją (angl. *softmax*), padalijančią tikimybių prognozes k objektų klasėms ir surandančią visas fonines klases, antrą sluoksnį, kuris kiekvienai k objektų klasei pateikia keturis realius vertinimus. Kiekvienas keturių reikšmių rinkinys koduoja ribines pozicijas vienai iš k klasių [8].

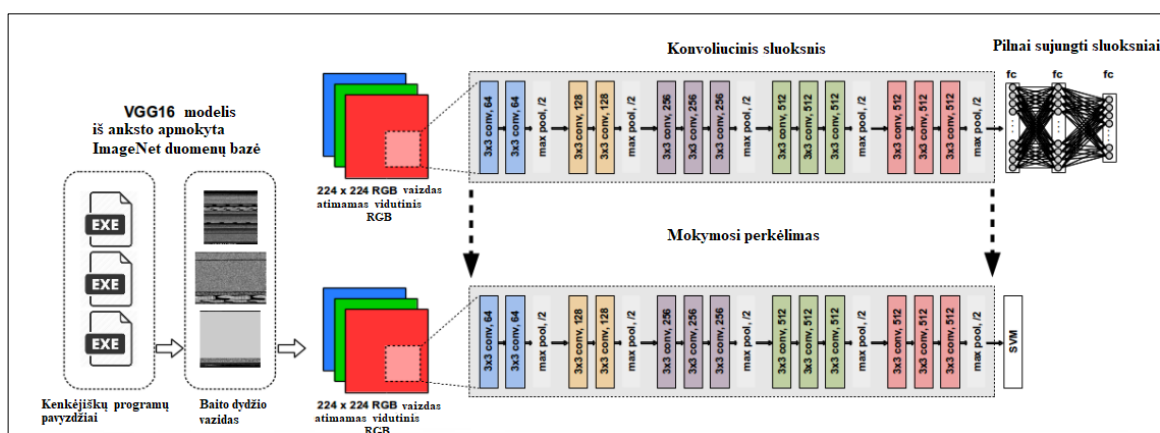
Apibendrinant regioninius konvoliucinius neuroninius tinklus galima teigti, kad jie gali pasiekti gerų rezultatų aptinkant tam tikrus objektus, tačiau „R-CNN“ turi ir trūkumų:

1. Mokymas susideda iš kelių etapų;
2. Mokymas yra brangus vietos ir laiko atžvilgiu;
3. Objektų aptikimas yra lėtas.

Lyginant „R-CNN“ ir „Greitąjį R-CNN“ galime teigti, kad „Greitasis R-CNN“ yra pranašesnis aptikimo greičiu, nes „Greitajam R-CNN“ nereikia padalinti įvesties vaizdo į 2000 regionų. Vietoje to įvesties vaizdas yra apdorojamas vieną kartą, sukuriant funkcijų žemėlapi. Nors „R-CNN“ ir „Greitasis R-CNN“ yra pakankamai tikslūs regiono aptikimuose, norint atlikti klasifikavimo uždavinį yra naudojami kiti konvoliuciniai neuroniniai tinklai.

1.3.2. „VGG-16“, „VGG-19“ konvoliucinis neuroninis tinklas

Kai kurie neuroniniai tinklai yra iš karto išmokyti, o tokio neuroninio tinklo pavyzdys būtų „VGG-16“ arba „VGG-19“ neuroninis tinklas. VGG modeliai, kurie yra su šešiolika sluoksnių, vadinami „VGG-16“, o su devyniolika sluoksnių – „VGG-19“.

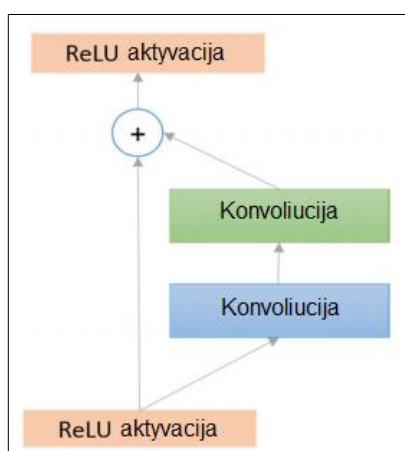


1.5 pav. „VGG-16“ struktūros pavyzdys [9]

Pateikiama „VGG-16“ neuroninio tinklo architektūrą (žr. 1.5 pav.). Struktūra pradeda nuo penkių konvoliucinio sluoksnių blokų, po kurių yra trys visiškai sujungti sluoksniai. Konvoliuciniuose sluoksniuose naudojami 3x3 branduoliai su vienu žingsniu ir vienu užpildu, kad būtų užtikrinta, jog kiekvienas funkcijų žemėlapis išlaiko tuos pačius erdvinis matmenis kaip ankstesnis sluoksnis. Po kiekvienos konvoliucijos yra aktyvinama ReLU funkcija ir kiekvieno bloko pabaigoje naudojama maksimalaus kaupimo operacija, siekiant sumažinti erdvinis matmenis. Maksimalus sutelkimo sluoksnis naudoja 2x2 branduolius su dviem žingsniais ir nė vienas blokas neužtikrina, kad kiekvienas ankstesnio sluoksnio funkcijų žemėlapio erdvinis matmuo yra perpus mažesnis [9].

1.3.3. „ResNet“ neuroninis tinklas

„ResNet“ tinklą sudaro keletas pagrindinių likutinių blokų. Tačiau operacijos likutiniuose blokuose gali priklausyti nuo skirtingos „ResNet“ neuroninio tinklo struktūros. Pateikiama pagrindinė „ResNet“ architektūros blokų diagrama (žr. 1.6 pav.).



1.6 pav. „ResNet“ architektūros blokų diagrama [10]

Likutinis sluoksnis remiasi $(l - 1)^{th}$ išėjimais, kurie gaunami iš ankstesnio sluoksnio x_{l-1} . $F(x_{l-1})$. Ankstesnis sluoksnis gaunamas atliekant įvairias operacijas, pavyzdžiui, konvoliucija su skirtingo dydžio filtrais, grupės normalizavimas, po kurio aktyvinama ReLU funkcija. Galutinis išėjimas gali būti apibrėžiamas žemiau pateikiama funkcija [10]:

$$x_l = F(x_{l-1}) + x_{l-1}. \quad (2)$$

Pagal M. Ferguson'o, R. Ako, Y. T. T. Lee ir K. H. Law atliktą tyrimą yra nurodoma, kad „ResNet“ neuroninis tinklas tinkamesnis defektams aptikti, nei „VGG-16“. Tai nestebina, nes „ResNet“ architektūra lenkia VGG architektūrą, atlikdama daug skirtingų užduočių, nors dauguma šių užduočių apima bendrų objektų aptikimą, pavyzdžiui, automobilio, lėktuvo ar dviračio. Taip pat „ResNet“ neuroninis tinklas turi daug didesnę sluoksnių skaičių lyginant su „VGG-16“ neuroniniu tinklu. Dėl šių priežasčių nebuvo tikimasi, kad defektų aptikimas su „VGG-16“ neuroniniu tinklu pateiks geresnius rezultatus, nei su „ResNet“ [11].

1.3.4. „MobileNet“, „Inception-v3“ neuroniniai tinklai

„MobileNet“ modelio idėja yra pakeisti brangius konvoliucinius sluoksnius į giliai atskirtus konvoliucinius blokus, kur kiekvieną bloką sudaro 3x3 gilus konvoliucinis sluoksnis, kuris filtruoja įvestį pasiremiant 1x1 taško konvoliuciniu sluoksniu, kuris sujungia filtruojamas reikšmes, kad būtų sukurtos naujos funkcijos. Tai yra atliekama daug greičiau ir gaunamas panašus rezultatas lyginant

su paprastu konvoliuciniu neuroniniu tinklu. Standartiniai konvoliuciniai tinklai naudoja $h_i \cdot w_i \cdot d_i$ įvesties daviklį L_i ir konvoliucinį branduolį $K \in R^{k \cdot k \cdot d_i \cdot d_j}$, norint gauti $h_i \cdot w_i \cdot d_j$ išvesties daviklį L_j turi būti apskaičiuojamas formulė $h_i \cdot w_i \cdot d_j \cdot k \cdot k$. Gilieji konvoliuciniai sluoksniai veikia beveik taip pat kaip paprastieji konvoliuciniai sluoksniai, bet yra apskaičiuojami pagal formulę $h_i \cdot w_i \cdot d_i \cdot (k^2 + d_j)$, kuri yra giliųjų ir taškinių 1x1 sluoksnių suma. Skaičiavimai sumažėja beveik per k^2 karto, kai yra lyginami gilieji konvoliuciniai su paprastaisiais konvoliuciniais sluoksniais [12].

„Inception-v3“ yra iš „Inception“ neuroninio tinklų modelių, kurie yra naudojami didesniuose modeliuose. „Inception“ modelio architektūra buvo naudojama „GoogleNet“ modelyje, kuris 2014 metais buvo pripažintas moderniausias vaizdo atpažinimo tinklas. „Inception-v3“ neuroniniam tinklui nereikia nustatyti konvoliucinių sluoksnių kiekio, nes modelis atlieka visas konvoliucijas ir išsirenka geriausią. Be to, ši architektūra leidžia modeliui atkurti mažai išsiskiriančias savybes dėl mažesnės konvoliucijos ir aukštos abstrakcijos savybes dėl didesnės konvoliucijos [13].

1.3.5. „U-Net“ neuroninis tinklas

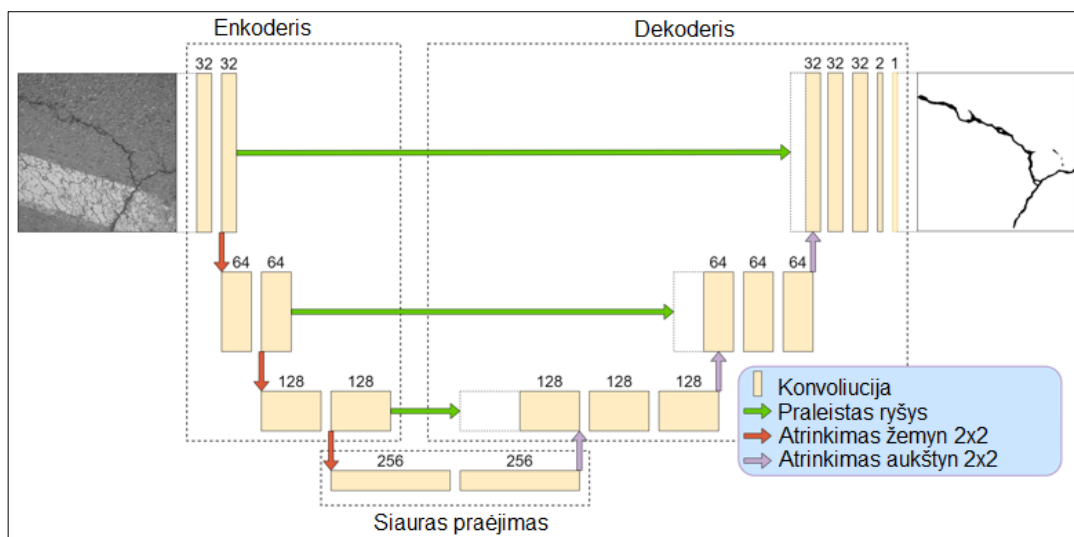
Paprasta „U-Net“ architektūra yra sudaryta iš atšakų, kurios užfiksuoja kontekstą ir išplečia šaką, kurios pagalba tiksliau galima nustatyti segmentavimo kaukes. Atšakos sudarytos iš standartinės konvoliucinės architektūros su kintančiomis konvencijomis, apjungimo operacijomis ir palaipsniui nuskaitytais funkcijų žemėlapiais. Kiekvienas ekspansyvus žingsnis atlieka srovės atranką funkcijų žemėlapyje, po kurios seka konvoliucija. Tokiu būdu palaipsniui yra didinama produkcijos skiriamoji geba. Siekiant lokalizuoti padidėjusias ypatybes, ekspansyvi atšaka jas sujungia su didelės skiriamosios gebos funkcijomis, naudojant praleistus ryšius [7].

Pateikiame klasių suskirstymo pavyzdį pagal aukščiau aprašytą „U-Net“ neuroninį tinklą (žr. 1.2 lentelė). Iš pateikto pavyzdžio galime matyti, kad aplinkos objektai gali būti suskirstomi į septynias klases pagal „U-Net“ neuroninį tinklą. Šiuo atveju pikselių klasifikavimas yra atliekamas pagal spalvas.

1.2 lentelė. Septynių klasių aprašymo pavyzdys „U-Net“ tinkle [7]

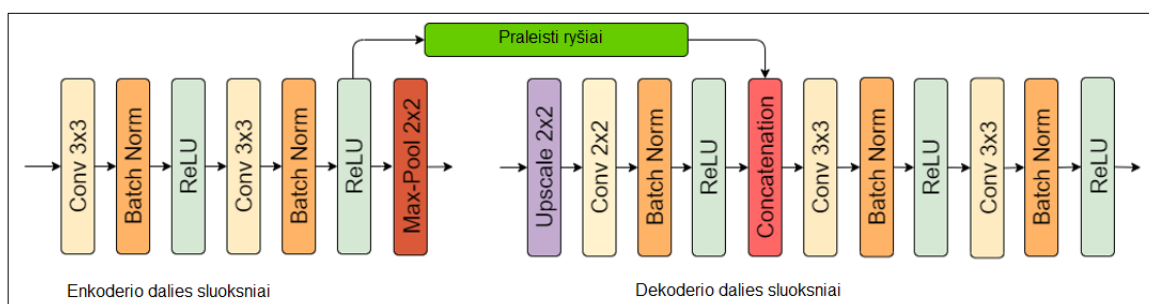
Eil. Nr.	Klasė	Spalva	Aprašymas
1.	Miesto žemė	Žalsvai mėlyna	Žmogaus sukurtose vietose, sukurtų vietovių su žmogaus artefaktais
2.	Žemdirbystės žemė	Geltona	Ūkiai, bet kokios planuojamos (t. y. įprastiniai) plantacijos, pasėliai, vaismedžių sodai, vynuogynai, daigynai ir dekoratyviniai sodininkystės plotai
3.	Ganyklos	Rausvai raudona	Bet kokia ne miško, ne ūkio žalioji žemė ir žolė
4.	Miško žemė	Žalia	Bet kokia žemė su medžio vainiko tankiu ir iškirstos vietos
5.	Vanduo	Mėlyna	Upės, vandenys, ežerai, pelkės, tvenkiniai
6.	Nederlinga žemė	Balta	Kalnai, žemė, akmenys, dykumos, paplūdimiai, žemė be augmenijos
0.	Nežinomas	Juoda	Debesys ir kiti

„U-Net“ neuroninis tinklas gali turėti įvairių struktūrų, kurios didina mokyto neuroninio tinklo tikslumą. Pateikiame vieną iš galimų „U-Net“ neuroninio tinklo modelių (žr. 1.7 pav.).



1.7 pav. „U-Net“ neuroninio tinklo struktūra [14]

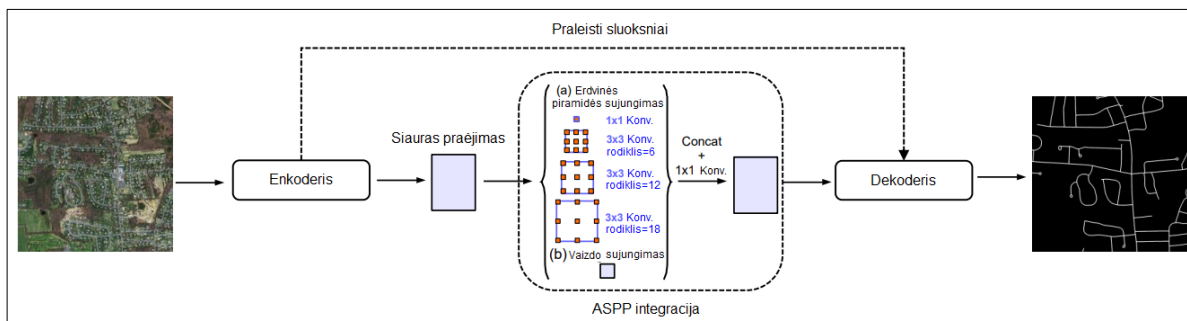
Pagal anksčiau pateiktą „U-Net“ struktūrą, enkoderio dalyje kiekviena konvoliucinė operacija atliekama pagal 3x3 branduolį (angl. *kernel*) su vieno pikselio žingsniu. Kiekvieną kartą po dviejų konvoliucinių operacijų dimensijos sumažinamos du kartus pagal 2x2 atrinkimo žemyn (angl. *max-pool*) operaciją, iki kol yra pasiekama 256 dimensija, kitaip sakant siauras praėjimas. Tokiu atveju atitinkamai funkcijų skaičius yra dvigubinamas. Siauro praėjimo dalis žymi latentinę erdvę ir turi daugiausiai konvoliucinių branduolių. Toliau seka dekoderio arba rekonstrukcijos dalis, kur su kiekvienu sluoksniu tenzorio plotis ir aukštis yra padidinamas du kartus. Po to yra atliekama 2x2 konvoliucinė operacija, kuri pakoreguoja ir interpretuoja padidintos vertės duomenis su išmoktais parametrais. Iš dalies iššifruoti duomenys (dekoderio) sujungiami su koduotaisiais duomenimis (enkoderio), kurie perduoda aukštesnio lygio ypatybes iš enkoderio (žr. 1.8 pav.). Kol visuose konvoliuciniuose sluoksniuose yra atliekamas tiesinis aktyvinimas (ReLU), neuroninio tinklo išėjimas turi sigmoidinę aktyvinimo funkciją, kuri pateikia ar viename pikselėje yra defektas ir tikimybė svyruoja nuo 0 iki 1. Aštuonių bitų pilkos spalvos skalėje tai atitinka diapazoną nuo 0 iki 255. Didesnė pikselių vertė nurodo didesnę tikimybę, kad vaizde yra defektas [14].



1.8 pav. Enkoderio ir dekoderio dalies sluoksniai [14]

„U-Net“ neuroninis tinklas gali būti patobulinamas panaudojant kitokias struktūras. Vienas iš tokių atvejų yra aprašytas analizuotame šaltinyje [15]. Minimame šaltinyje yra nurodoma kaip „U-Net“ neuroninio tinklo patobulinimui panaudojamas „ASPP“ modulis, kuris susideda iš keturių lygiagrečių konvoliucijų su skirtingais rodikliais. „ASPP“ modulis sudarytas iš vienos 1x1 konvoliucijos ir trijų

lygiagrečių 3x3 konvoliucijų su atitinkamais rodikliais 6, 12 ir 18 bei vaizdo lygio funkcijos, kurią sukuria bendras sujungimas. Gaunamos savybės iš visų sluoksnių yra padvigubinamos iki įvesties dydžio ir sujungiant pereinama į kitą 1x1 konvoliuciją. Enkoderio dalyje „ASPP“ pritaikomas kuriamam objektų žemėlapiui, o gaunamas objektų žemėlapis įtraukiamas į dekoderio dalį (žr. 1.9 pav.).



1.9 pav. „U-Net“ neuroninio tinklo struktūra, patobulinta su „ASPP“ [15]

Liekamasis ryšys, kuris sudaro „ResNet“ neuroninį tinklą, gali būti panaudojamas „U-Net“ struktūrai pakeisti. Tokiu atveju liekamasis ryšys padeda išvengti gradiento problemos, tikslumo pablogėjimo ir pagerina neuroninio tinklo veikimą. Praleistos operacijos leidžia netrikdomai perduoti duomenų srautą per visą neuroninį tinklą. Įgyvendinant liekamąjį ryšį su 1x1 konvoliucija yra pakoreguojamas funkcijų skaičius, nes kiekviename enkoderyje arba dekoderyje skaičius keičiasi du kartus [14].

1.4. Aptikimo kokybės įverčiai

Kokybės įverčiai yra apskaičiuojami iš pasiskirstymo matricos (angl. *Confusion matrix*), kuri yra gaunama atlikus validavimą. Pateikiame pasiskirstymo matricą, kurioje galima matyti, kaip tiriami egzemplioriai yra paskirstomi pagal tikras ir prognozuojamas klases (žr. 1.3 lentelė).

1.3 lentelė. Pasiskirstymo matrica [16]

	Prognozuojama klasė	
Tikra klasė	Teisinga teigiama (TP) (angl. <i>True Positive</i>)	Neteisinga neigiama (FN) (angl. <i>False Negative</i>)
	Neteisinga teigiama (FP) (angl. <i>False Positive</i>)	Teisinga neigiama (TN) (angl. <i>True Negative</i>)

Santrumpų paaiškinimai:

1. TP – reikšmių skaičius, kuriame nurodomas teisingas prognozių kiekis, kad defektas yra;
2. FP – reikšmių skaičius, kuriame nurodomas neteisingas prognozių kiekis, kai yra klasifikuojama kaip defektas, bet defekto nėra;
3. TN – reikšmių skaičius, kuriame nurodomas neteisingas prognozių kiekis, kai nėra klasifikuojama kaip defektas, bet defektas yra;
4. FN – reikšmių skaičius, kuriame nurodomas teisingas prognozių kiekis, kad defekto nėra.

Jautrumas (angl. *Sensitivity*) taip pat žinomas kaip tikrasis teigiamas rodiklis (TPR). Tai yra tikimybė, kuri apskaičiuoja, koks kiekis teigiamų atvejų bus teisingai nustatytų. Tikimybė apskaičiuojama pagal žemiau pateikiamą formulę:

$$Jautrumas = \frac{TP}{TP + FN} \quad (1)$$

PPV (angl. *Precision*) – teigiama nuspėjamoji vertė (PPV). Tai yra tikimybė, kad teigiami atvejai buvo teisingai prognozuojami visoms teigiamoms klasėms. Rodiklis apskaičiuojamas pagal žemiau pateikiamą formulę:

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

Tikslumas (angl. *Accuracy*) – tikimybė, kuri nurodo, kad bendras prognozių skaičius yra teisingas. Tikimybė apskaičiuojama pagal žemiau pateikiamą formulę:

$$Tikslumas = \frac{TP + TN}{TP + FN + FP + TN} \quad (3)$$

F1 matas (angl. *F1-measure*) – tikimybė, kuri apibrėžiama kaip PPV ir jautrumo vidurkis. Tikimybė apskaičiuojama pagal žemiau pateikiamą formulę:

$$F1 = 2 \cdot \frac{Jautrumas \cdot PPV}{Jautrumas + PPV} \quad (4)$$

1.5. Skirtingų paviršių defektų aptikimo metodo naudotojai

Skirtingų paviršių defektų aptikimo sistemos naudotojai būtų tie žmonės, kurie dirba gamyboje su defektų aptikimu arba analizuoja neuroninius tinklus ir jų pritaikymo galimybes.

Defektų aptikimas yra svarbus gamybos įmonėse, kur yra gaminama skirtingų paviršių produkcija ir jai yra keliami aukšti kokybės reikalavimai. Skirtinguose paviršiaus struktūrose vieni vaizdai gali būti atpažįstami kaip defektai kito vaizdo klasėje. Dėl šių atvejų reikalingas metodas, kuris gamybos įmonėms padėtų nustatyti defektus skirtinguose paviršiuose, kai nėra žinoma vaizdo klasė. Iširtu geriausiu metodu galėtų pasinaudoti gamybos įmonės, o sukurta skirtingų paviršių defektų aptikimo sistema žmonės, kurie domisi neuroniniais tinklais. Sistemos naudotojas, kuris domisi neuroniniais tinklais, galėtų peržiūrėti ir išbandyti metodų tikslumą skirtingų paviršių defektų aptikimo sistemoje. Taip pat galėtų peržiūrėti aptikimo metodų kokybės įverčius, kurie nurodo kaip yra mokytai neuroniniai tinklai.

1.6. Esamų defektų aptikimo metodų analizė

Tyrimai su neuroniniais tinklais yra paplitę ir daug mokslininkų tiria neuroninių tinklų struktūras, kurios geriausiai aptiktų defektus ar atpažintų objektus. Kadangi neuroninių tinklų panaudojimas yra platus, šiame skyriuje pristatomi kitų mokslininkų darbai, kurie susiję su defektų aptikimu „DAGM“ duomenų bazėje.

Pagal nagrinėtą šaltinį [17], atliekamas defektų aptikimas iš „DAGM“ duomenų bazėje esančių šešių vaizdo klasių. Neuroninio tinklo mokymas yra atliekamas kiekvienai vaizdo klasei atskirai, tačiau naudojant skirtingus vaizdų padalijimus į dalis: 7x7, 20x20, 32x32. Pagal atlikto tyrimo rezultatus yra nustatoma, kad pirmai ir šeštai vaizdo klasei skirtingas suskaidymas į vaizdo dalis neturi didelės įtakos defektų aptikimo rezultatui. Priešingai nei antrai ir ketvirtai vaizdo klasei, kurių defekto aptikimo rezultatas sumažėjo, naudojant 7x7 vaizdo suskaidymą į dalis. Tai patvirtina, kad naudojant statistiškai reikšmingą vaizdų suskirstymą, yra pagerinamas defekto aptikimas.

Pagal [1], tiriamas defektų aptikimas iš „DAGM“ duomenų bazėje esančių dešimt vaizdų klasių. Norint padidinti mokymo vaizdų kiekį yra atliekama dviejų tipų augmentacija. Pirmos augmentacijos metu yra pakeičiami vaizdų dydžiai: 512x512, 256x256, 128x128, 64x64. Antro tipo duomenų papildinimui yra dirbtinai sugadinami kai kurie tos pačios klasės pavyzdžiai su Gauso triukšmu ir gauti rezultatai pažymimi kaip klasės pavyzdžiai. Atlikus vaizdų kiekio padidinimą neuroninis tinklas mokomas kiekvienai klasei atskirai, pakeičiant neuroninio tinklo parametrus. Tyrime neuroninio tinklo mokymui keičiami branduolių kiekiai: $h=16$ arba $h=32$. Pagal gautus rezultatus yra nustatoma, kad pagal tirtus neuroninio tinklo parametrus nėra randamas aiškus skirtumas.

Pagal [18], atliekamas defektų aptikimo metodas dviejose skirtingose paviršiaus duomenų bazėse. Defektas yra ieškomas vienoje iš „DAGM“ vaizdų klasių ir geležinkelio bėgių vaizdų („RSDDsI“) duomenų bazėse. Defektų aptikimo rezultatų palyginimui yra naudojamas *F1* kokybės įvertis, kurio dydis su „DAGM“ duomenų baze yra pasiekiamas iki 0,96, o su „RSDDsI“ – 0,81. Šio tyrimo rezultatai nurodo, kad „DAGM“ duomenų bazės paviršiaus vaizduose defektas yra aptinkamas tiksliau.

Aprašyti sprendimai išnagrinėti nustatytais kriterijais, kurie gali būti naudingi tolimesniems tiriamojo darbo etapams (žr. 1.4 lentelė).

1.4 lentelė. Esamų sprendimų palyginimas

Palyginimo kriterijus	Tekstūruotų paviršių defektų klasifikavimas [17]	Anomalių aptikimas su konvoliuciniu neuroniniu tinklu [1]	Pusiau prižiūrimas anomalių aptikimas [18]
Tyrimo tikslas	Palyginti defektų aptikimo rezultatus su skirtingais vaizdų suskaidymo į dalis dydžiais.	Palyginti defektų aptikimo rezultatus su skirtingais neuroninio tinklo parametrais.	Palyginti defektų aptikimą dviejose skirtingose duomenų bazėse.
Duomenų bazė	„DAGM“.	„DAGM“.	„DAGM“.
Duomenų bazėje esančių vaizdų klasių skaičius	6.	10.	1.
Vaizdų paruošimas	-	Augmentacija.	-
Vaizdo klasių mokymas	Mokoma kiekviena klasė atskirai ir vertinami aptikimo rezultatai kiekvienai klasei.	Mokoma kiekviena klasė atskirai ir vertinami aptikimo rezultatai kiekvienai klasei.	Mokoma ir vertinami rezultatai iš vienos vaizdo klasės.
Neuroninis tinklas	Neuroninio tinklo struktūra, kuri naudoja atsitiktiniu būdu sugeneruotas vaizdų dalis.	Gilusis liekamasis mokymas.	Automatinio kodavimo neuroninis tinklas.
Aptikimo kokybės vertinimas	ROC kreivė.	ROC kreivės rodiklis AUC.	F1.
Rezultatai	Naudojant statistiškai reikšmingą pilko vaizdo verčių pasiskirstymą yra pagerinamas aptikimo rezultatas.	Naudojant skirtingus neuroninio tinklo parametrus ($h=16$, $h=32$), nerandamas aiškus skirtumas tarp gaunamų rezultatų.	Tikslesni defektų aptikimo kokybės įverčiai yra gaunami, kai defektas aptinkamas „DAGM“ duomenų bazėje.

1.7. Siekiamo sprendimo apibrėžimas

Tyrimo siekiamas sprendimas yra metodas, kuris nurodytų tinkamiausia būdą, kaip aptikti defektą skirtinguose paviršiuose. Skirtingų paviršių defektus gali būti sudėtinga aptikti, naudojant išmokytus neuroninius tinklus, nes vienos klasės ne defektas gali būti kitos klasės defektu.

Mokant neuroninį tinklą reikia tinkamai nustatyti vaizdų aibę, su kuria turi būti atliekamas neuroninio tinklo mokymas. Neuroninis tinklas gali būti mokinamas su visa duomenų aibe, tai yra neatsižvelgiant į skirtingo paviršiaus vaizdą, arba gali būti mokinamas su kiekviena klase atskirai. Todėl siekiama palyginti skirtingus neuroninio tinklo mokymo principus, kurie apibrėžiami kaip defektų aptikimo metodai. Defektų aptikimo metodai remiasi mokytais neuroniniais tinklais ir pagal juos aptinkami defektai. Palyginant galimus defektų aptikimo metodus, būtų surandamas tiksliausias metodas, kuris gali aptikti skirtingų paviršių defektą.

1.8. Analizės išvados

Atlikus probleminę srities analizę gautos šios išvados:

1. Kontekstinei vaizdų analizei šiuo metu dažniausiai taikomi gilieji konvoliuciniai neuroniniai tinklai.
2. Išmokinti konvoliuciniai neuroniniai tinklai vaizdų analizavimui gali būti naudojami tik klasifikavimo uždaviniui spręsti arba atlikti kontekstinę semantinę segmentaciją, suskaidant vaizdą į prasmines sritis.
3. Gilusis „U-Net“ neuroninis tinklas, dėl savo ypatybės, gali aptikti reikiamus objektus pikselio lygmenyje. Vaizdinė informacija yra suspaudžiama U formos kaklelyje ir esminė informacija yra ištraukiama išsiplėtimo dalyje.
4. Naudojant aptikimo kokybės įverčius, galima patikrinti neuroninio tinklo mokymo rezultatą ir nustatyti kokia dalis vaizdų klasifikuojama teisingai arba klaidingai.
5. Skirtingų paviršių vaizdai mokomi atskirai, siekiant tiksliau nustatyti kiekvieno paviršiaus defektą, nes vieno vaizdo defektas yra kito paviršiaus tipinis raštas.

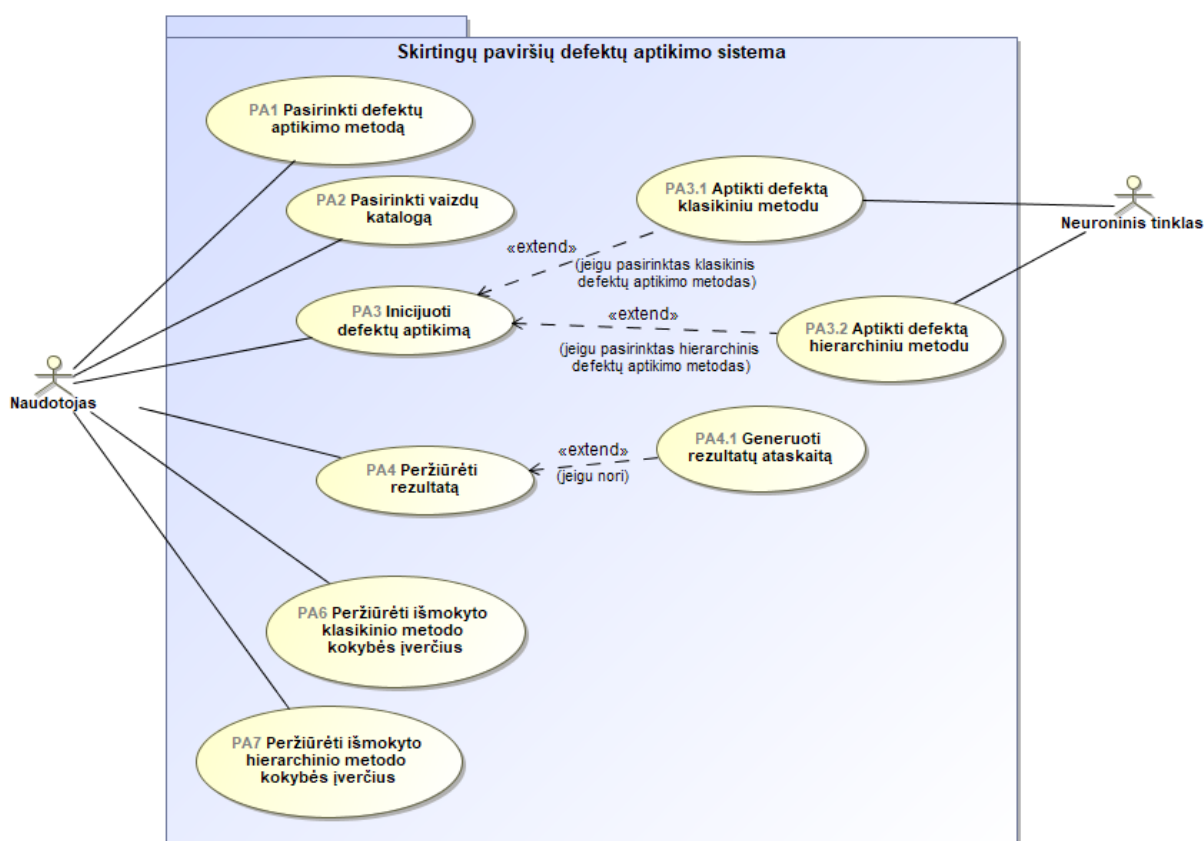
2. Skirtingų paviršių defektų aptikimo sistemos reikalavimų specifikacija ir projektas, formalus aprašas

Šiame skyriuje pateikiama skirtingų paviršių defektų aptikimo reikalavimų specifikaciją, kurią sudaro panaudojimo atvejų diagrama, veiklos ir procesų diagramos, dalykinės srities modelis ir naudotojų sąsajos modelis.

2.1. Reikalavimų specifikacija

Reikalavimų specifikacijoje pateikiami funkciniai reikalavimai skirtingų paviršių defektų aptikimo sistemai. Funkciniai reikalavimai kuriamai sistemai pateikiami panaudojimo atvejų, veiklos ir procesų diagramomis.

Panaudos atvejų diagrama nurodo, kokius veiksmus naudotojas galės atlikti kuriamos sistemos naudotojo sąsajoje. Kuriamos sistemos aktorius atitinka rolę „Naudotojas“, kuris galės atlikti visus galimus veiksmus skirtingų paviršių defektų aptikimo sistemoje (žr. 2.1 pav.).



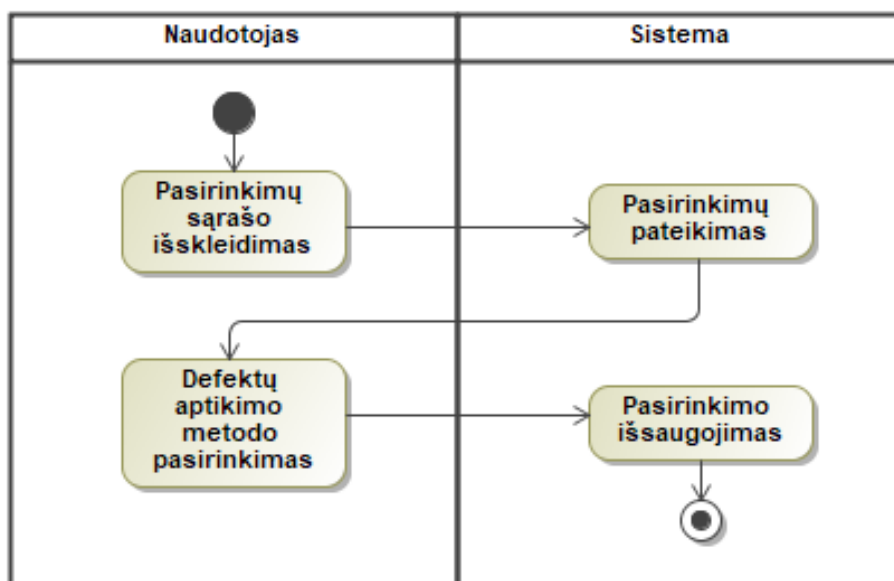
2.1 pav. Skirtingų paviršinių defektų aptikimo sistemos panaudojimo atvejų diagrama

Sistema turi du aktorius:

- Naudotojas – pagrindinis sistemos aktorius, kuris galėtų atlikti visus veiksmus sistemoje.
- Neuroninis tinklas – atsakingas už defektų aptikimą vaizde. Atitinkamai išmokytas neuroninis tinklas nustato ar tikrinamame vaizde yra defektas ir pateikia rezultatus.

Naudotojo tikslas yra pradėti defektų tikrinimą, bet prieš tai būtina pasirinkti defektų aptikimo metodą ir tikrinamų vaizdų katalogą. Defektų aptikimo metodo ir vaizdų katalogo pasirinkimo eiliškumas

nėra svarbus. Detaliau panaudojimo atvejis „Pasirinkti defektų aptikimo metodą“ yra pateikiamas veiklos diagramoje (žr. 2.2 pav.).

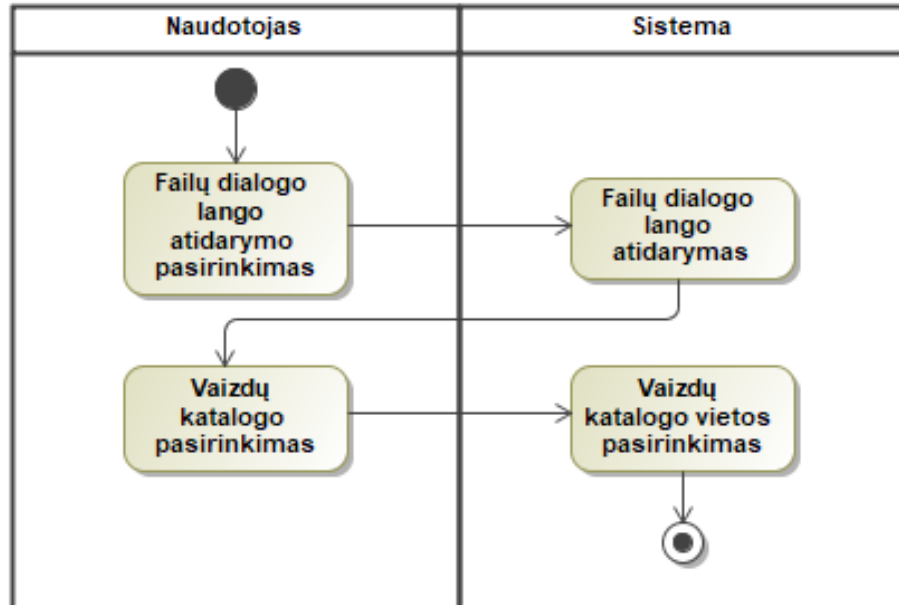


2.2 pav. „Pasirinkti defektų aptikimo metodą“ veiklos diagrama

2.1 lentelė. PA „Pasirinkti defektų aptikimo metodą“ aprašymas

PA „Pasirinkti defektų aptikimo metodą“.		
Tikslas. Pasirinkti defektų aptikimo metodą.		
Aprašymas. Vykdamas šį PA galima pasirinkti vieną iš dviejų defektų aptikimo metodų: klasikinį arba hierarchinį.		
Prieš sąlyga	Naudotojas turi atidaryti skirtingų paviršių defektų aptikimo sistemą.	
Aktorius	Naudotojas.	
Sužadinimo sąlyga	Naudotojas nori pasirinkti defektų aptikimo metodą.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas	Sistemos reakcija ir sprendimai	
1. Naudotojas pradeda PA.	Sistema pateikia defektų aptikimo metodus.	
2. Naudotojas pasirenka vieną iš defektų aptikimo metodų.	Sistema grįžta į būseną, kurioje buvo prieš šio PA pasirinkimą.	
Po sąlyga:	Pasirinktas defektų aptikimo metodas.	
Alternatyvūs scenarijai		
-	-	

Naudotojas turi pasirinkti tikrinamų vaizdų katalogą, kuriame esančius vaizdus sistema tikrintų. Detaliau panaudojimo atvejis „Pasirinkti vaizdų katalogą“ yra pateikiamas veiklos diagramoje (žr. 2.3 pav.).



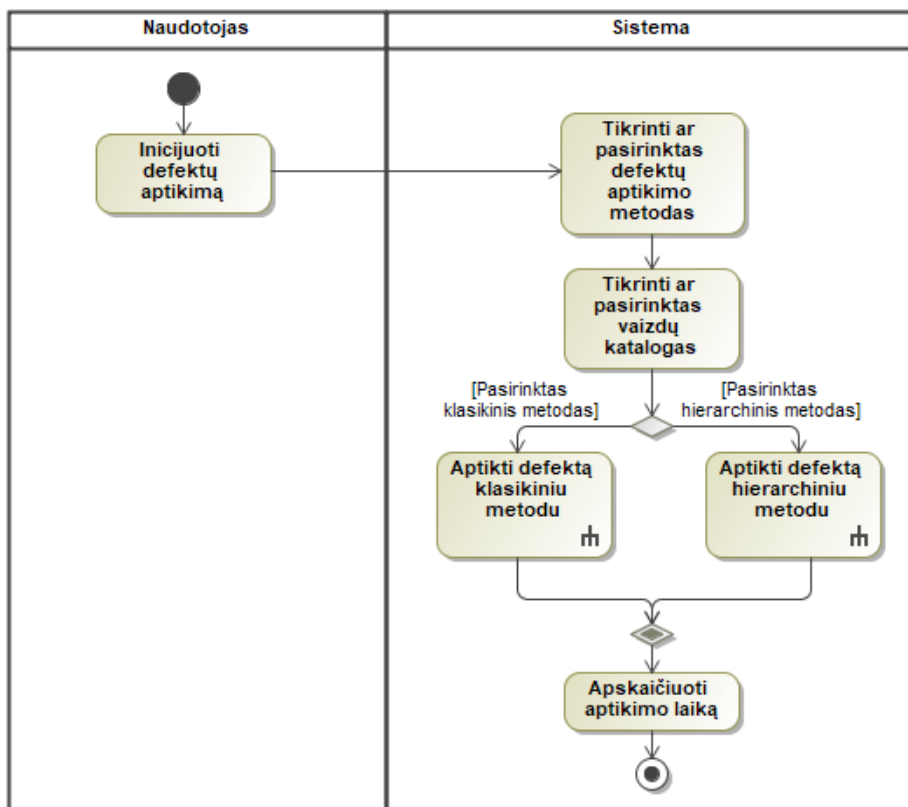
2.3 pav. „Pasirinkti vaizdų katalogą“ veiklos diagrama

2.2 lentelė. PA „Pasirinkti vaizdų katalogą“ aprašymas

PA „Pasirinkti vaizdų katalogą“.		
Tikslas. Pasirinkti vaizdų katalogo vietą iš kompiuterio.		
Aprašymas. Vykdam šį PA galima pasirinkti vaizdų katalogų vietą, iš kurios vaizdai būtų naudojami defektų aptikimui.		
Prieš sąlygą	Naudotojas turi atidarys skirtingų paviršių defektų aptikimo sistemą.	
Aktorius	Naudotojas.	
Sužadavimo sąlyga	Naudotojas nori pasirinkti vaizdų katalogą.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas	Sistemos reakcija ir sprendimai	
1. Naudotojas pradeda PA.	Sistema atidaro kompiuterio failų pasirinkimo dialogo langą.	
2. Naudotojas pasirenka vaizdų katalogą.	Sistema išsaugo pasirinktą vaizdų katalogo vietą.	
3.	Sistema grįžta į būseną, kurioje buvo prieš šio PA pasirinkimą.	
Po sąlyga:	Pasirinktas vaizdų katalogas.	
Alternatyvūs scenarijai		
A1. Naudotojas nepasirenka vaizdų katalogo.	Sistema neišsaugo vaizdų katalogo vietos.	

Naudotojas gali inicijuoti defekto aptikimą po to, kai yra pasirinktas defekto aptikimo metodas ir tikrinamų vaizdų katalogas. Atitinkamai defektų aptikimas yra atliekamas sistemos pagal pasirinktą

defektų aptikimo metodą. Defektų aptikimo inicijavimas yra pateikiamas veiklos diagramoje (žr. 2.4 pav.).



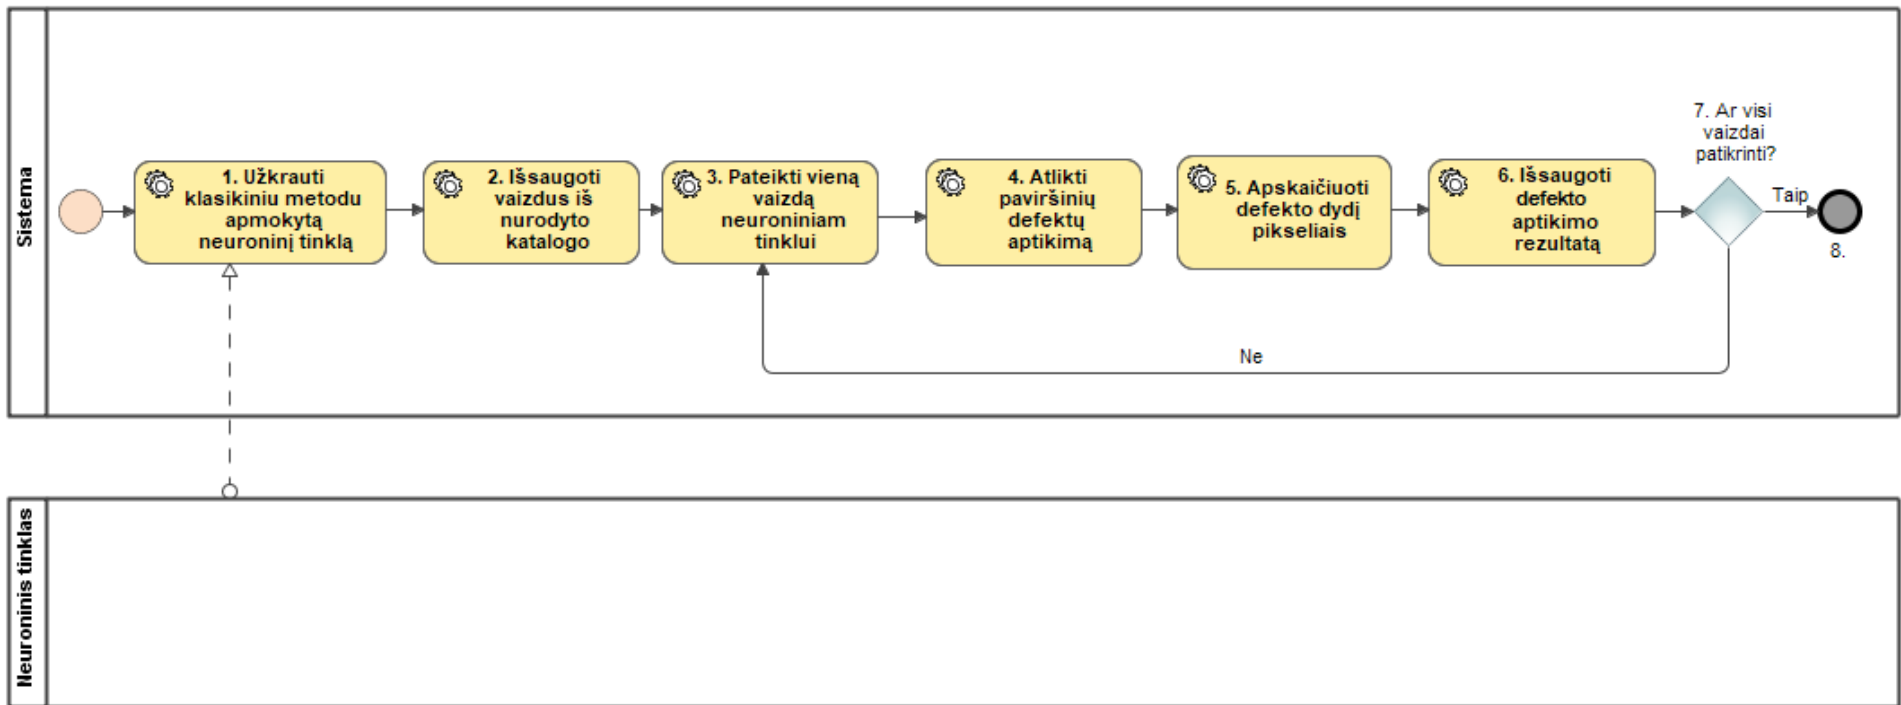
2.4 pav. PA „Inicijuoti defektų aptikimą“ veiklos diagrama

2.3 lentelė. PA „Inicijuoti defektų aptikimą“ aprašymas

PA „Inicijuoti defektų aptikimą“.		
Tikslas. Inicijuojamas defektų aptikimas.		
Aprašymas. Vykiant šį PA yra inicijuojamas defektų aptikimas nurodytam vaizdų katalogui pagal pasirinktą defektų aptikimo metodą.		
Prieš sąlygą	Pasirinktas defektų aptikimo metodas ir vaizdų katalogas.	
Aktorius	Naudotojas.	
Sužadavimo sąlyga	Naudotojas nori inicijuoti defektų aptikimą.	
Susiję panaudojimo atvejai	Išplečia PA	PA „Aptikti defektą klasikiniu metodu“; PA „Aptikti defektą hierarchiniu metodu“.
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas		
Sistemos reakcija ir sprendimai		
1. Naudotojas pradeda PA.	Sistema tikrina ar yra pasirinktas defekto aptikimo metodas.	
2.	Sistema tikrina ar yra pasirinktas vaizdų katalogas.	
3.	Sistema aptinka defektą pasirinktu defektų aptikimo metodu.	
4.	Sistema apskaičiuoja defektų aptikimo laiką.	

5.	Sistema grįžta į būseną, kurioje buvo prieš šio PA pasirinkimą.
Po sąlyga:	Kataloge esantiems vaizdams inicijuotas defekto aptikimas.
Alternatyvūs scenarijai	
A1. Naudotojas nepasirenka defektų aptikimo metodo.	Sistema pateikia klaidos pranešimą „Nepasirinktas aptikimo metodas“.
B1. Naudotojas nepasirenka vaizdų katalogo.	Sistema pateikia klaidos pranešimą „Nepasirinktas vaizdų katalogas“.
C1. Naudotojas pasirenka vaizdų katalogą, kuriame nėra nė vieno vaizdo.	Sistema pateikia klaidos pranešimą „Vaizdų katalogas yra tuščias“.

Naudotojui pasirinkus klasikinį defekto aptikimo metodą, tuomet sistema atlieka defekto tikrinimą kiekvienam vaizdui atskirai. Pateikiame defekto aptikimo klasikiniu metodu veiklos procesą BPMN procesų diagrama (žr. 2.5 pav.).

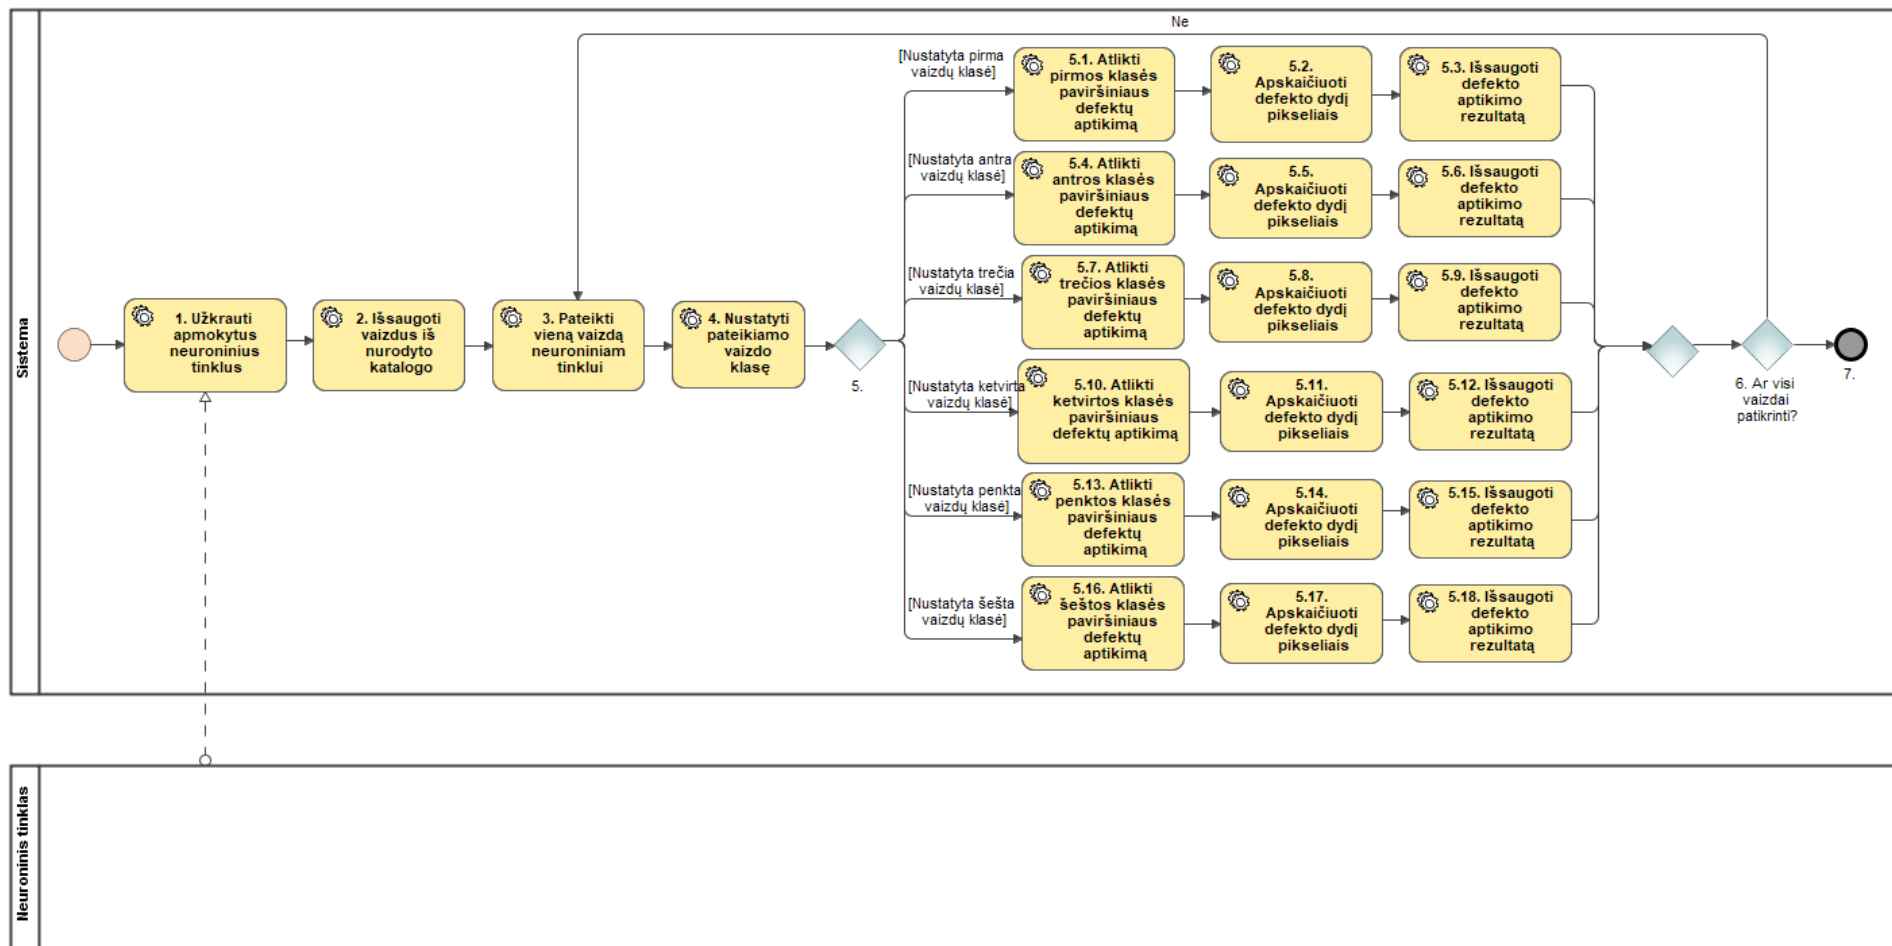


2.5 pav. PA „Aptikti defektą klasikiniu metodu“ proceso diagrama

2.4 lentelė. PA „Aptikti defektą klasikiniu metodu“ aprašymas

Nr.	Aktorius	Aprašymas
1.	Sistema	Užkrauna klasikiniu metodu išmokytą neuroninį tinklą.
2.	Sistema	Išsaugo vaizdus iš naudotojo nurodyto katalogo.
3.	Sistema	Pateikia vieną vaizdą į klasikiniu metodu mokytą neuroninį tinklą.
4.	Sistema	Atlieka paviršiaus defekto aptikimą.
5.	Sistema	Apskaičiuoja defekto dydį pikseliais.
6.	Sistema	Išsaugo defekto aptikimo rezultata.
7.	Sistema	Nustato ar visi užkrauti vaizdai iš katalogo buvo pateikti į klasikiniu metodu mokytą neuroninį tinklą: Jeigu visi vaizdai buvo pateikti į klasikiniu metodu mokytą neuroninį tinklą, toliau žiūrėti žingsnį Nr. 8.; Jeigu ne visi vaizdai buvo pateikti į klasikiniu metodu mokytą neuroninį tinklą, grįžtama į žingsnį Nr. 3..
8.	Sistema	Proceso pabaiga.

Naudotojui pasirinkus hierarchinio defekto aptikimo metodą, tuomet sistema atlieka defekto tikrinimą kiekvienam vaizdui atskirai. Pirmiausiai yra nustatoma paviršiaus struktūrą ir atitinkamai pasirenkama paviršiaus klasė, pagal kurią yra ieškomas defektas. Pateikiame defekto aptikimo hierarchiniu metodu veiklos procesą BPMN procesų diagrama (žr. 2.6 pav.).



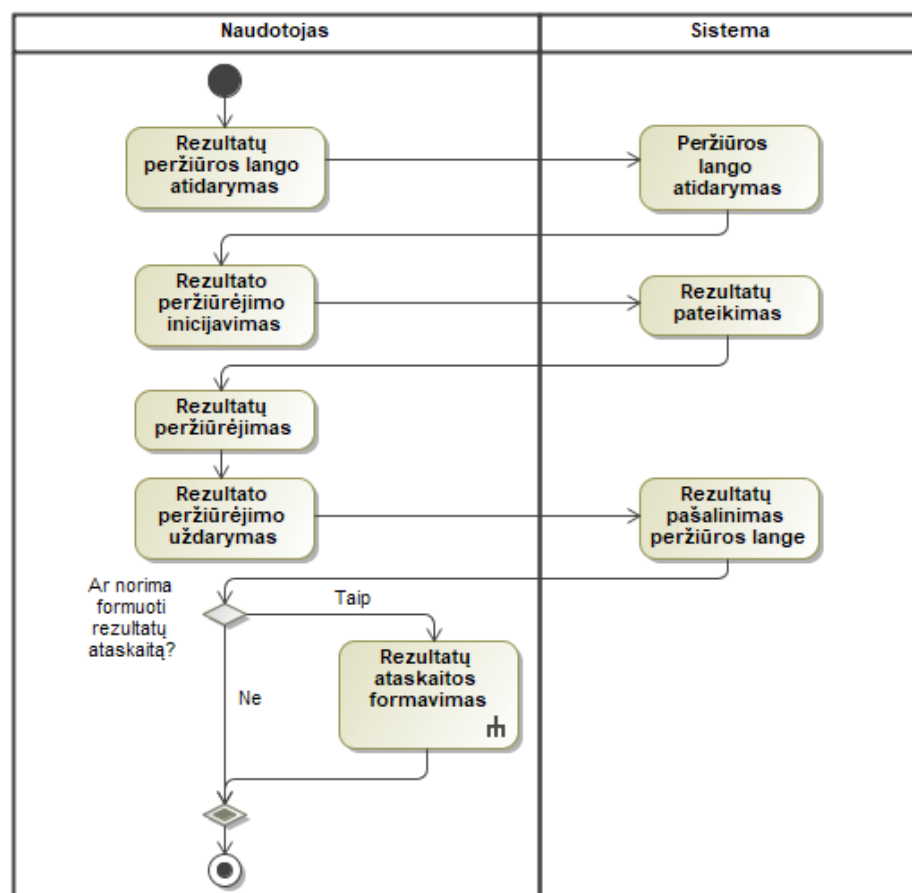
2.6 pav. PA „Aptikti defektą hierarchiniu metodu“ veiklos diagrama

2.5 lentelė. PA „Aptikti defektą hierarchiniu metodu“ aprašymas

Nr.	Aktorius	Aprašymas
1.	Sistema	Užkrauna išmokytus neuroninius tinklus: Išmokytas neuroninis tinklas klasių atpažinimui; Išmokytas neuroninis tinklas pirmos klasės vaizdų paviršiniams defektams aptikti; Išmokytas neuroninis tinklas antros klasės vaizdų paviršiniams defektams aptikti; Išmokytas neuroninis tinklas trečios klasės vaizdų paviršiniams defektams aptikti; Išmokytas neuroninis tinklas ketvirtos klasės vaizdų paviršiniams defektams aptikti; Išmokytas neuroninis tinklas penktos klasės vaizdų paviršiniams defektams aptikti; Išmokytas neuroninis tinklas šeštos klasės vaizdų paviršiniams defektams aptikti.
2.	Sistema	Užkrauna vaizdus iš naudotojo nurodyto katalogo.
3.	Sistema	Pateikia vieną vaizdą į išmokytą neuroninį tinklą vaizdo klasei atpažinti.
4.	Sistema	Atlieka vaizdo klasės nustatymą.
5.	Sistema	Nustato, kokia vaizdo klasė buvo atpažinta: Jeigu vaizdas atpažintas kaip pirmos klasės, toliau žiūrėti žingsnį Nr. 5.1.; Jeigu vaizdas atpažintas kaip antros klasės, toliau žiūrėti žingsnį Nr. 5.2.; Jeigu vaizdas atpažintas kaip trečios klasės, toliau žiūrėti žingsnį Nr. 5.3.; Jeigu vaizdas atpažintas kaip ketvirtos klasės, toliau žiūrėti žingsnį Nr. 5.4.; Jeigu vaizdas atpažintas kaip penktos klasės, toliau žiūrėti žingsnį Nr. 5.5.; Jeigu vaizdas atpažintas kaip šeštos klasės, toliau žiūrėti žingsnį Nr. 5.6..
5.1.	Sistema	Atlieka pirmos klasės vaizdo paviršiaus defekto aptikimą. Toliau žiūrėti žingsnį Nr. 5.2..
5.2.	Sistema	Apskaičiuoja defekto dydį pikseliais. Toliau žiūrėti žingsnį Nr. 5.3..
5.3.	Sistema	Išsaugo defekto aptikimo rezultatą. Toliau žiūrėti žingsnį Nr. 6..
5.4.	Sistema	Atlieka antros klasės vaizdo paviršiaus defekto aptikimą. Toliau žiūrėti žingsnį Nr. 5.5..
5.5.	Sistema	Apskaičiuoja defekto dydį pikseliais. Toliau žiūrėti žingsnį Nr. 5.6..
5.6.	Sistema	Išsaugo defekto aptikimo rezultatą. Toliau žiūrėti žingsnį Nr. 6..
5.7.	Sistema	Atlieka trečios klasės vaizdo paviršiaus defekto aptikimą. Toliau žiūrėti žingsnį Nr. 5.8..
5.8.	Sistema	Apskaičiuoja defekto dydį pikseliais. Toliau žiūrėti žingsnį Nr. 5.9..
5.9.	Sistema	Išsaugo defekto aptikimo rezultatą. Toliau žiūrėti žingsnį Nr. 6..
5.10.	Sistema	Atlieka ketvirtos klasės vaizdo paviršiaus defekto aptikimą. Toliau žiūrėti žingsnį Nr. 5.11..
5.11.	Sistema	Apskaičiuoja defekto dydį pikseliais. Toliau žiūrėti žingsnį Nr. 5.12..
5.12.	Sistema	Išsaugo defekto aptikimo rezultatą. Toliau žiūrėti žingsnį Nr. 6..
5.13.	Sistema	Atlieka penktos klasės vaizdo paviršiaus defekto aptikimą. Toliau žiūrėti žingsnį Nr. 5.14..
5.14.	Sistema	Apskaičiuoja defekto dydį pikseliais. Toliau žiūrėti žingsnį Nr. 5.15..

Nr.	Aktorius	Aprašymas
5.15.	Sistema	Išsaugo defekto aptikimo rezultata. Toliau žiūrėti žingsnį Nr. 6..
5.16.	Sistema	Atlieka šeštos klasės vaizdo paviršiaus defekto aptikimą. Toliau žiūrėti žingsnį Nr. 5.17..
5.17.	Sistema	Apskaičiuoja defekto dydį pikseliais. Toliau žiūrėti žingsnį Nr. 5.18..
5.18.	Sistema	Išsaugo defekto aptikimo rezultata. Toliau žiūrėti žingsnį Nr. 6..
6.	Sistema	Nustato ar visi užkrauti vaizdai iš katalogo buvo pateikti į klasikiniu metodu mokytą neuroninį tinklą: Jeigu visi vaizdai buvo pateikti į klasikiniu metodu mokytą neuroninį tinklą, toliau žiūrėti žingsnį Nr. 7.; Jeigu ne visi vaizdai buvo pateikti į klasikiniu metodu mokytą neuroninį tinklą, grįžtama į žingsnį Nr. 3..
7.	Sistema	Proceso pabaiga.

Po atlikto defektų aptikimo naudotojas gali peržiūrėti rezultatus, kurie yra pateikiami kiekvienam vaizdui atskirai arba gali būti pateikiamas bendras rezultatas visam tikrintam vaizdų katalogui (žr. 2.7 pav.).



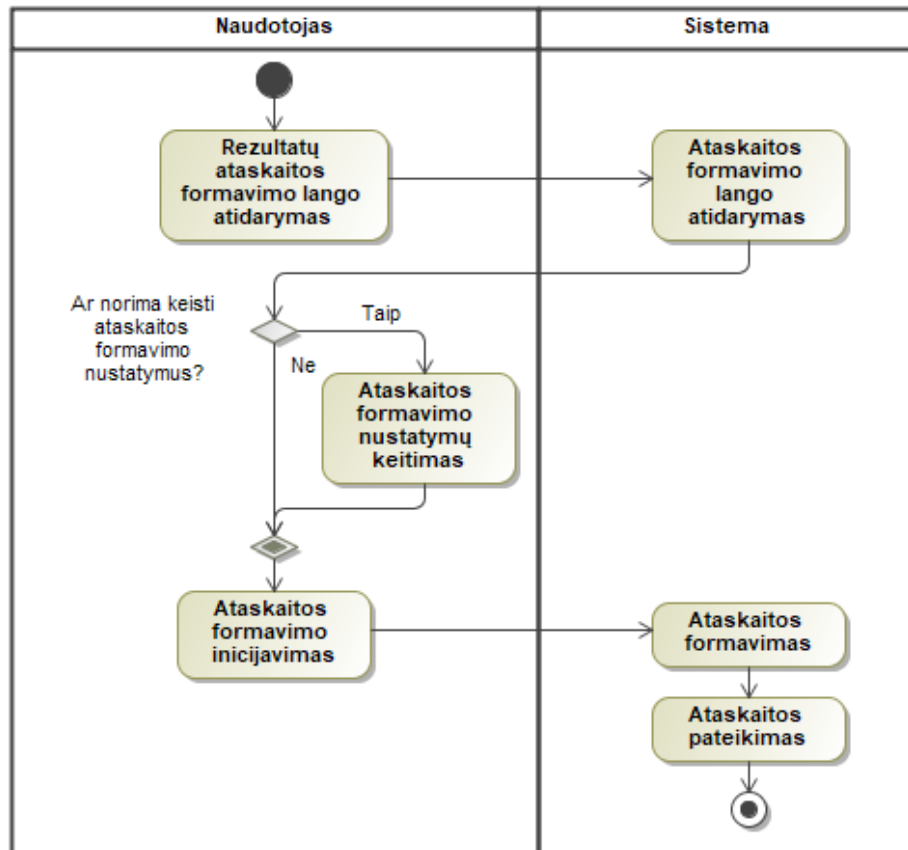
2.7 pav. PA „Peržiūrėti rezultatą“ veiklos diagrama

2.6 lentelė. PA „Peržiūrėti rezultatą“ aprašymas

PA „Peržiūrėti rezultatą“.
Tikslas. Peržiūrėti gautą defektų aptikimo rezultata.

Aprašymas. Vykdam šį PA yra peržiūrimas skirtingų paviršių defektų aptikimo rezultatas.		
Prieš sąlyga	Atliktas vaizdo tikrinimas.	
Aktorius	Naudotojas.	
Sužadavimo sąlyga	Naudotojas nori peržiūrėti defektų aptikimo rezultata.	
Susiję panaudojimo atvejai	Išplečia PA	PA „Generuoti rezultatų ataskaitą“; PA „Peržiūrėti bendrą rezultatą“.
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas	Sistemos reakcija ir sprendimai	
1. Naudotojas pradeda PA.	Sistema atidaro rezultatų peržiūros langą.	
2. Naudotojas inicijuoja rezultatų peržiūrą.	Sistema pateikia rezultatus.	
3. Naudotojas peržiūri rezultatus.		
4. Naudotojas inicijuoja rezultatų uždarymą.	Sistema panaikina rezultatus iš peržiūros lango.	
5. Naudotojas, jeigu nori, formuoja rezultatų ataskaitą.		
6. Naudotojas baigia PA.		
Po sąlyga:	Peržiūrėtas gautas skirtingų paviršių defektų aptikimo rezultatas.	
Alternatyvūs scenarijai		
-	-	

Naudotojas gali pasirinkti formuoti rezultatų ataskaitą, pagal pasirinktus ataskaitos formavimo nustatymus. Ataskaitos formavimo nustatymuose būtų galima pasirinkti kokį rezultatą pateikti (kiekvieno vaizdo atskirai ar viso vaizdų katalogo) ir nustatyti ar ataskaitoje pateikti klasikinio ir hierarchinio metodų rezultatus, kad būtų galima palyginti. Panaudojimo atvejis „Generuoti rezultatų ataskaitą“ detalizuojamas veiklos diagrama (žr. 2.8 pav.).



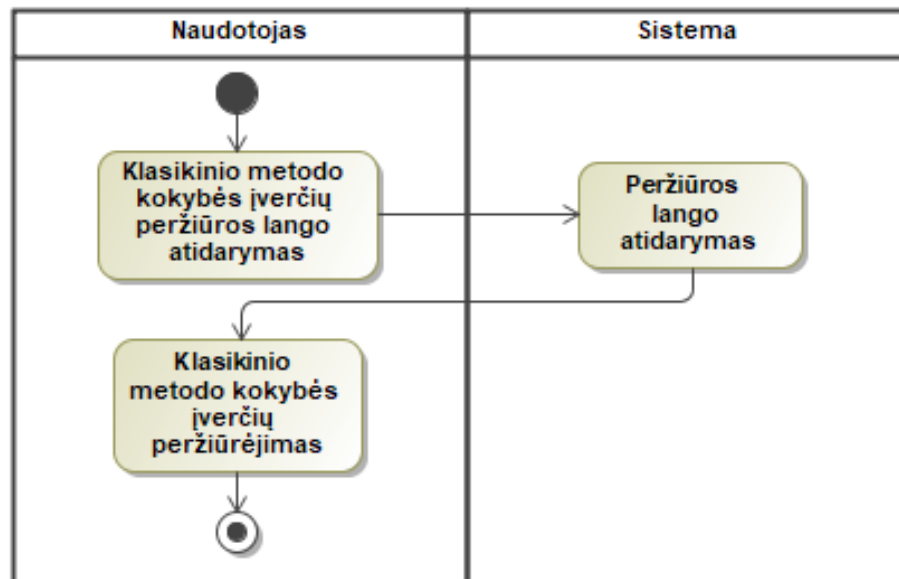
2.8 pav. PA „Generuoti rezultatų ataskaitą“ veiklos diagrama

2.7 lentelė. PA „Generuoti rezultatų ataskaitą“ aprašymas

PA „Generuoti ataskaitą“.		
Tikslas. Formuoti rezultatų ataskaitą.		
Aprašymas. Vykdam šį PA galima suformuoti rezultatų ataskaitą, kuri pateiktų vieno vaizdo rezultatą ir / arba viso vaizdų katalogo rezultatą.		
Prieš sąlyga	Atidarytas rezultatų peržiūros langas.	
Aktorius	Naudotojas.	
Sužadinimo sąlyga	Naudotojas nori suformuoti rezultatų ataskaitą.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas		
Sistemos reakcija ir sprendimai		
1. Naudotojas pradeda PA.	Sistema atidaro rezultatų ataskaitos formavimo langą.	
2. Naudotojas, jeigu nori ataskaitos metodų palyginimui, tuomet keičia ataskaitos formavimo nustatymus.		
3. Naudotojas inicijuoja rezultatų ataskaitos formavimą.	Sistema formuoja rezultatų ataskaitą.	
4.	Sistema pateikia suformuotą rezultatų ataskaitą.	

5.	Sistema grįžta į būseną, kurioje buvo prieš šio PA pasirinkimą.
Po sąlyga:	Suformuota rezultatų ataskaita.
Alternatyvūs scenarijai	
A1. Naudotojas pasirenka ataskaitą metodų palyginimui ir tam pačiam katalogui nėra atliktas aptikimas su dviem metodais.	Sistema pateikia klaidos pranešimą „Nėra atliktas to pačio vaizdų katalogo defektų aptikimas“.

Naudotojas gali peržiūrėti klasikinio defekto aptikimo metodo kokybės įverčius. Kokybės įverčiai nurodo, kokių tikslumu yra atliekamas defektų aptikimas, pasirinkus klasikinį metodą (žr. 2.15 pav.).



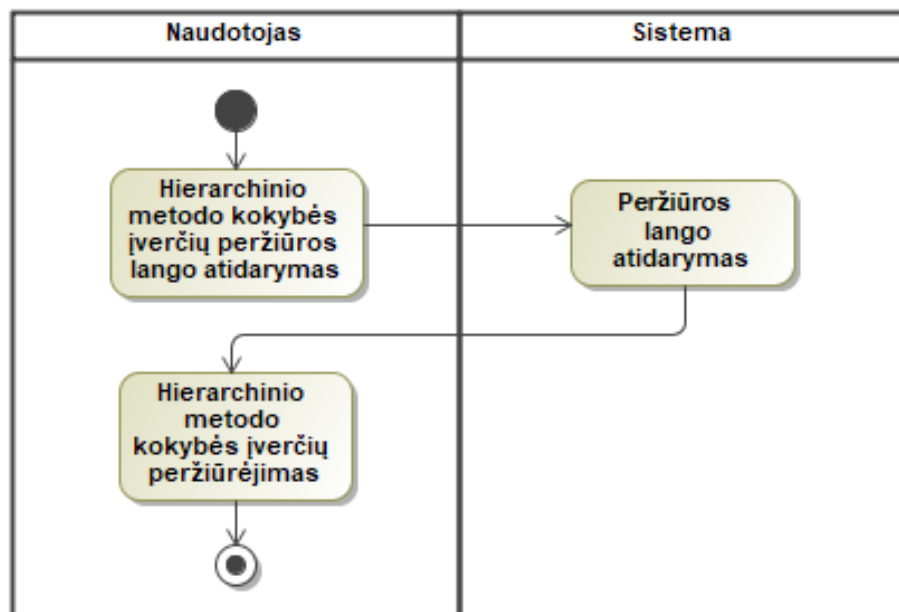
2.9 pav. PA „Peržiūrėti išmokyto klasikinio metodo kokybės įverčius“ veiklos diagrama

2.8 lentelė. PA „Peržiūrėti išmokyto klasikinio metodo kokybės įverčius“ aprašymas

PA „Peržiūrėti išmokyto klasikinio metodo kokybės įverčius“.		
Tikslas. Peržiūrėti išmokyto klasikinio metodo kokybės įverčius.		
Aprašymas. Vykdamas šį PA galima peržiūrėti išmokyto klasikinio metodo kokybės įverčius: F1, tikslumą, jautrumą ir PPV.		
Prieš sąlygą	Pasirinkta neuroninio tinklo klasikinio metodo kokybės įverčių peržiūra.	
Aktorius	Naudotojas.	
Sužadinimo sąlyga	Naudotojas nori peržiūrėti klasikinio metodo kokybės įverčius.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas	Sistemos reakcija ir sprendimai	
1. Naudotojas pradeda PA.	Sistema pateikia neuroninio tinklo klasikinio metodo kokybės įverčius: F1, tikslumą, jautrumą ir PPV.	

2. Naudotojas peržiūri klasikinio metodo aptikimo kokybės įverčius.	
3. Naudotojas baigia PA.	Sistema grįžta į būseną, kurioje buvo prieš šio PA pasirinkimą.
Po sąlyga:	Peržiūrėti klasikinio metodo aptikimo kokybės įverčiai.
Alternatyvūs scenarijai	
-	-

Naudotojas gali peržiūrėti hierarchinio defekto aptikimo metodo kokybės įverčius. Kokybės įverčiai nurodo, kokių tikslumu yra atliekamas defektų aptikimas, pasirinkus hierarchinį metodą. Hierarchinio metodo kokybės įverčiai yra pateikiami bendri visam metodui ir kiekvienai skirtingo vaizdo klasei (žr. 2.15 pav.).



2.10 pav. PA „Peržiūrėti išmokyto hierarchinio metodo kokybės įverčius“ veiklos diagrama

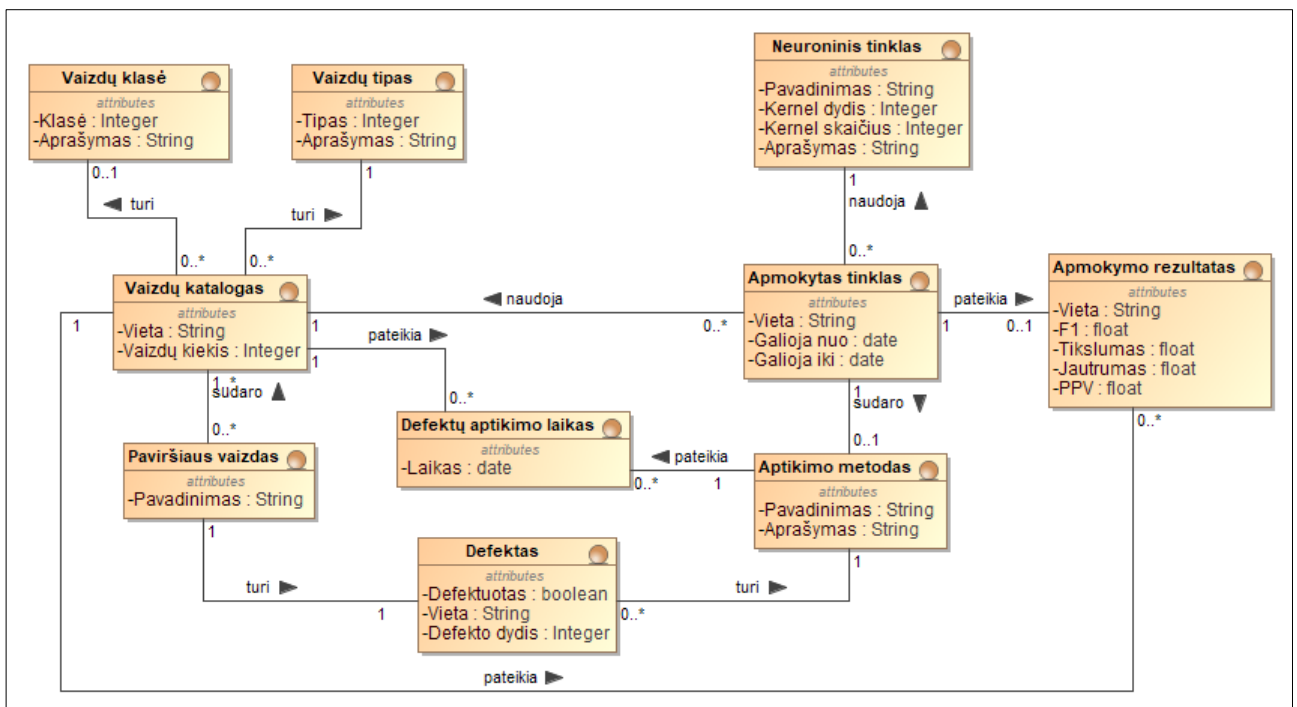
2.9 lentelė. PA „Peržiūrėti išmokyto hierarchinio metodo kokybės įverčius“ aprašymas

PA „Peržiūrėti išmokyto hierarchinio metodo kokybės įverčius“.		
Tikslas. Peržiūrėti išmokyto hierarchinio metodo kokybės įverčius.		
Aprašymas. Vykdamas šį PA galima peržiūrėti išmokyto hierarchinio metodo kokybės įverčius: F1, tikslumą, jautrumą ir PPV.		
Prieš sąlygą	Pasirinkta neuroninio tinklo hierarchinio metodo kokybės įverčių peržiūra.	
Aktorius	Naudotojas.	
Sužadinimo sąlyga	Naudotojas nori peržiūrėti hierarchinio metodo kokybės įverčius.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas	Pagrindinis įvykių srautas	

1. Naudotojas pradeda PA.	Sistema pateikia neuroninio tinklo hierarchinio metodo kokybės įverčius: F1, tikslumą, jautrumą ir PPV.
2. Naudotojas peržiūri hierarchinio metodo aptikimo kokybės įverčius.	
3. Naudotojas baigia PA.	Sistema grįžta į būseną, kurioje buvo prieš šio PA pasirinkimą.
Po sąlyga:	Peržiūrėti hierarchinio metodo aptikimo kokybės įverčiai.
Alternatyvūs scenarijai	
-	-

2.2. Dalykinės srities modelis

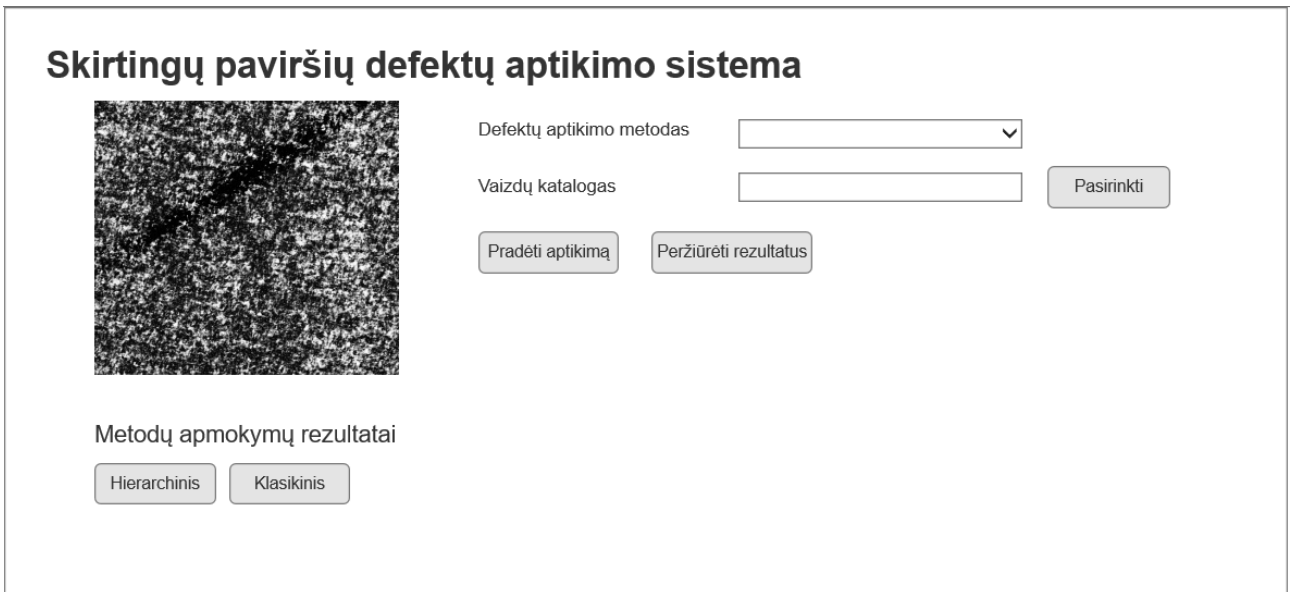
Dalykinės srities modelį sudaro dešimt esybių, kurios yra susietos asociacijos ryšiais. Pateikto modelio pagrindu kuriama skirtingų paviršių defektų aptikimo sistema (žr. 2.11 pav.).



2.11 pav. Dalykinės srities modelis

2.3. Naudotojų sąsajos modelis

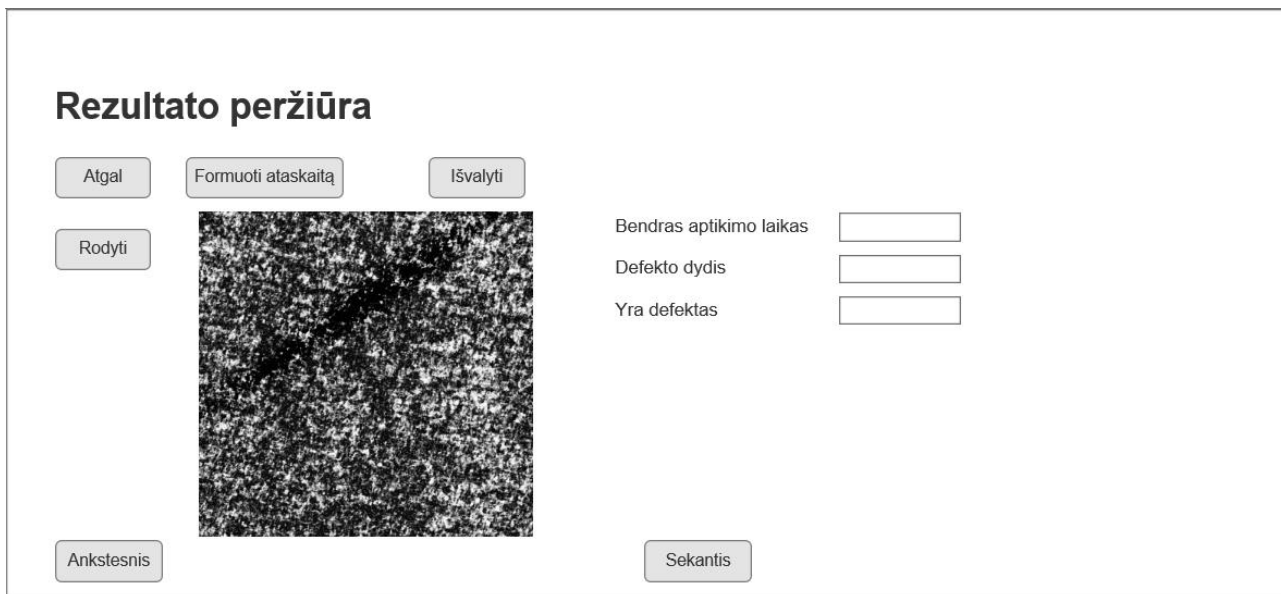
Naudotojo sąsajos modelyje pateikiami visi skirtingų paviršių defektų aptikimo sistemos langai su aprašymais. Kuriamą sistemą sudarys penki langai sistemos langai. Pateikiame suprojektuotus visus sistemos langus (žr. 2.12 pav., 2.13 pav., 2.14 pav., 2.15 pav., 2.16 pav.). Atitinkamai kiekvienam sistemos langui pateikiamas aprašymas lentelėse (žr. 2.10 lentelė, 2.11 lentelė, 2.12 lentelė, 2.13 lentelė, 2.14 lentelė).



2.12 pav. Skirtingų paviršių defektų aptikimo sistemos pagrindinis langas

2.10 lentelė. Skirtingų paviršių defektų aptikimo sistemos pagrindinio lango aprašymas

Lango pasiekiamumas	Langas pasiekiamas, kai yra atidaroma skirtingų paviršių defektų aptikimo sistema.
Lango paskirtis	<p>Langas skirtas atlikti defekto aptikimo metodo pasirinkimą, vaizdų katalogo pasirinkimą, inicijuoti defektų aptikimą ir atidaryti rezultatų langą.</p> <p>Pasirenkamasis laukas „Defektų aptikimo metodas“ pateikia du defektų aptikimo metodus: klasikinį ir hierarchinį.</p> <p>Lauke „Vaizdų katalogas“ atvaizduojama pasirinkto katalogo vieta.</p> <p>Mygtukas [Pasirinkti] atidaro failų katalogo langą, kuriame galima pasirinkti vaizdų katalogą iš kompiuterio.</p> <p>Mygtukas [Pradėti aptikimą] aktyvus, kai lauke „Defektų aptikimo metodas“ pasirinktas vienas iš dviejų aptikimo metodų ir lauke „Vaizdų katalogas“ pasirinktas vaizdų katalogas. Paspaudus mygtuką atliekamas defektų aptikimas iš pasirinkto katalogo vaizdų pagal pasirinktą defektų aptikimo metodą.</p> <p>Mygtukas [Peržiūrėti rezultatus] yra aktyvus, jeigu sistemos sesijos metu buvo atliktas defektų aptikimas. Paspaudus mygtuką yra atidaromas rezultatų peržiūros langas, kuriame pateikiami paskutiniai sistemoje išsaugoti defektų aptikimo rezultatai.</p> <p>Mygtukas [Hierarchinis] yra aktyvus visada. Paspaudus mygtuką yra atidaromas hierarchinio metodo kokybės įverčių peržiūros langas.</p> <p>Mygtukas [Klasikinis] yra aktyvus visada. Paspaudus mygtuką yra atidaromas klasikinio metodo kokybės įverčių peržiūros langas.</p>
Susiję panaudos atvejai	<p>PA „Pasirinkti defektų aptikimo metodą“;</p> <p>PA „Pasirinkti vaizdų katalogą“;</p> <p>PA „Inicijuoti defektų aptikimą“;</p> <p>PA „Aptikti defektą klasikiniu metodu“;</p> <p>PA „Aptikti defektą hierarchiniu metodu“.</p>



2.13 pav. Rezultatų peržiūros langas

2.11 lentelė. Rezultatų peržiūros lango aprašymas

Lango pasiekiamumas	Langas pasiekiamas, kai yra atidarytas skirtingų paviršių defektų aptikimo sistemos pagrindinis langas ir atliktas bent vienas defektų aptikimas.
Lango paskirtis	<p>Langas skirtas peržiūrėti defekto aptikimo rezultatą kiekvienam tikrintam vaizdui.</p> <p>Lauke „Bendras aptikimo laikas“ pateikiamas aptikimo laikas, per kurį buvo aptinkami defektai iš viso pasirinkto vaizdų katalogo. Laikas pateikiamas sekundėmis.</p> <p>Lauke „Defekto dydis“ pateikiamas aptikto defekto dydis. Defekto dydis pateikiamas pikseliais.</p> <p>Lauke „Yra defektas“ pateikiama „Taip“ arba „Ne“:</p> <p>Jeigu pateikiama „Taip“, tuomet vaizde yra aptiktas defektas;</p> <p>Jeigu pateikiama „Ne“, tuomet vaizde nėra aptiktas defektas;</p> <p>Mygtukas [Atgal] aktyvus visada. Paspaudus mygtuką sugrįžtama į sistemos pagrindinį langą.</p> <p>Mygtukas [Formuoti ataskaitą] aktyvus visada. Paspaudus mygtuką atidaromas ataskaitos formavimo langas.</p> <p>Mygtukas [Rodyti] yra rodomas tik tada, kai yra atidaromas rezultatų peržiūros langas arba išvalomi pateikiami rezultatai. Paspaudus mygtuką yra pateikiami defektų aptikimo rezultatai. Neatvaizduojamas po mygtuko paspaudimo.</p> <p>Mygtukas [Išvalyti] aktyvus visada. Paspaudus mygtuką yra išvalomas rezultatų peržiūros langas ir pateikiamas mygtukas [Rodyti]. Išvalytame peržiūros lange pateikiamas tik bendras defektų aptikimo laikas.</p> <p>Mygtukas [Ankstesnis] yra aktyvus, kai yra atvaizduojamas ne pirmas tikrintas vaizdas. Paspaudus mygtuką yra pateikiamas ankstesnio vaizdo defekto aptikimo rezultatai.</p> <p>Mygtukas [Sekantis] yra aktyvus, kai yra atvaizduojamas ne paskutinis tikrintas vaizdas. Paspaudus mygtuką yra pateikiamas sekančio vaizdo defekto aptikimo rezultatai.</p>
Susiję panaudos atvejai	PA „Peržiūrėti rezultatą“.

Ataskaitos formavimas

Atgal
Formuoti

Ar palyginti metodus? Ne ▼

2.14 pav. Ataskaitos formavimo langas

2.12 lentelė. Ataskaitos formavimo lango aprašymas

Lango pasiekiamumas	Langas pasiekiamas, kai yra atidarytas skirtingų paviršių defektų aptikimo sistemos rezultatų peržiūros langas.
Lango paskirtis	<p>Langas skirtas inicijuoti rezultatų ataskaitos formavimą.</p> <p>Pasirenkamasis laukas „Ar pateikti metodų palyginimą?“, kuriame galima pasirinkti reikšmes „Taip“ arba „Ne“. Numatyta reikšmė „Ne“:</p> <p>Jeigu pasirenkama reikšmė „Taip“, tuomet ataskaitoje bus pateikiamas klasikinio ir hierarchinio metodo aptikimo rezultatai paskutiniam pasirinktam vaizdų katalogui. Jeigu paskutiniam pasirinktam vaizdų katalogui nėra atlikta aptikimo su vienu iš metodų, tada pateikiamas klaidos pranešimas „Nėra atliktas to pačio vaizdų katalogo defektų aptikimas“.</p> <p>Jeigu pasirenkama reikšmė „Ne“, tuomet ataskaitoje bus pateikiami tik paskutiniai gauti aptikimo rezultatai.</p> <p>Mygtukas [Atgal] aktyvus visada. Paspaudus mygtuką sugrįžtama į rezultatų peržiūros langą.</p> <p>Mygtukas [Formuoti] aktyvus visada. Paspaudus mygtuką sistema pradeda formuoti rezultatų ataskaitą iš paskutinių atliktų vaizdų defektų aptikimo ir pagal ataskaitos formavimo lange pasirinktus kriterijus.</p>
Susiję panaudos atvejai	PA „Generuoti rezultatų ataskaitą“.

Klasikinio metodo kokybės įverčiai

Atgal

F1 Jautrumas

Tikslumas PPV

2.15 pav. Klasikinio metodo defektų aptikimo kokybės įverčių peržiūros langas

2.13 lentelė. Klasikinio metodo defektų aptikimo kokybės įverčių peržiūros lango aprašymas

Lango pasiekiamumas	Langas pasiekiamas, kai yra atidarytas skirtingų paviršių defektų aptikimo sistemos rezultatų peržiūros langas.
Lango paskirtis	<p>Langas skirtas peržiūrėti klasikinio metodo aptikimo kokybės įverčius.</p> <p>Lauke „F1“ pateikiamas aptikimo kokybės įvertis <i>FI</i>, kuris yra suapvalintas iki keturių skaitmenų po kablelio.</p> <p>Lauke „Tikslumas“ pateikiamas aptikimo kokybės įvertis <i>tikslumas</i>, kuris yra suapvalintas iki keturių skaitmenų po kablelio.</p> <p>Lauke „Jautrumas“ pateikiamas aptikimo kokybės įvertis <i>jautrumas</i>, kuris yra suapvalintas iki keturių skaitmenų po kablelio.</p> <p>Lauke „PPV“ pateikiamas aptikimo kokybės įvertis <i>PPV</i>, kuris yra suapvalintas iki keturių skaitmenų po kablelio.</p> <p>Mygtukas [Atgal] aktyvus visada. Paspaudus mygtuką sugrįžtama į skirtingų paviršių defektų aptikimo sistemos pagrindinį langą.</p>
Susiję panaudos atvejai	PA „Peržiūrėti išmokyto klasikinio metodo kokybės įverčius“.

Hierarchinio metodo kokybės įverčiai

Atgal

Klasių klasifikavimas	Pirma klasė	Antra klasė	Trečia klasė	Ketvirta klasė	Penkta klasė	Šešta klasė
F1	<input type="text"/>		Jautrumas	<input type="text"/>		
Tikslumas	<input type="text"/>		PPV	<input type="text"/>		

2.16 pav. Hierarchinio metodo defektų aptikimo kokybės įverčių peržiūros langas

2.14 lentelė. Hierarchinio metodo defektų aptikimo kokybės įverčių peržiūros lango aprašymas

Lango pasiekiamumas	Langas pasiekiamas, kai yra atidarytas skirtingų paviršių defektų aptikimo sistemos rezultatų peržiūros langas
Lango paskirtis	<p>Langas skirtas peržiūrėti hierarchinio metodo aptikimo kokybės įverčius.</p> <p>Lauke „F1“ pateikiamas aptikimo kokybės įvertis <i>FI</i> kortelėse „Klasių klasifikavimas“, „Pirma klasė“, „Antra klasė“, „Trečia klasė“, „Ketvirta klasė“, „Penkta klasė“, „Šešta klasė“.</p> <p>Lauke „Tikslumas“ pateikiamas aptikimo kokybės įvertis <i>tikslumas</i> kortelėse „Klasių klasifikavimas“, „Pirma klasė“, „Antra klasė“, „Trečia klasė“, „Ketvirta klasė“, „Penkta klasė“, „Šešta klasė“.</p> <p>Lauke „Jautrumas“ pateikiamas aptikimo kokybės įvertis <i>jautrumas</i> kortelėse „Klasių klasifikavimas“, „Pirma klasė“, „Antra klasė“, „Trečia klasė“, „Ketvirta klasė“, „Penkta klasė“, „Šešta klasė“.</p> <p>Lauke „PPV“ pateikiamas aptikimo kokybės įvertis <i>PPV</i> kortelėse „Klasių klasifikavimas“, „Pirma klasė“, „Antra klasė“, „Trečia klasė“, „Ketvirta klasė“, „Penkta klasė“, „Šešta klasė“.</p> <p>Kortelėje „Klasių klasifikavimas“ pateikiami išmokyto neuroninio tinklo, kuris aptinka paviršiaus struktūrą, aptikimo kokybės įverčiai.</p> <p>Kortelėje „Pirma klasė“ pateikiami išmokyto neuroninio tinklo, kuris aptinka defektą pirmoje klasėje, aptikimo kokybės įverčiai.</p> <p>Kortelėje „Antra klasė“ pateikiami išmokyto neuroninio tinklo, kuris aptinka defektą antroje klasėje, aptikimo kokybės įverčiai.</p> <p>Kortelėje „Trečia klasė“ pateikiami išmokyto neuroninio tinklo, kuris aptinka defektą trečioje klasėje, aptikimo kokybės įverčiai.</p> <p>Kortelėje „Ketvirta klasė“ pateikiami išmokyto neuroninio tinklo, kuris aptinka defektą ketvirtoje klasėje, aptikimo kokybės įverčiai.</p> <p>Kortelėje „Penkta klasė“ pateikiami išmokyto neuroninio tinklo, kuris aptinka defektą penktoje klasėje, aptikimo kokybės įverčiai.</p> <p>Kortelėje „Šešta klasė“ pateikiami išmokyto neuroninio tinklo, kuris aptinka defektą šeštoje klasėje, aptikimo kokybės įverčiai.</p> <p>Mygtukas [Atgal] aktyvus visada. Paspaudus mygtuką sugrįžtama į skirtingų paviršių defektų aptikimo sistemos pagrindinį langą.</p>
Susiję panaudos atvejai	PA „Peržiūrėti išmokyto hierarchinio metodo kokybės įverčius“.

3. Skirtingų paviršių defektų aptikimo sistemos realizacijos projektas

Pateikiamas kuriamos skirtingų paviršių defektų aptikimo sistemos realizacijos projektas, kuriame nurodoma realizacijos priemonė, sistemos architektūra, duomenų bazės modelis ir diegimo diagrama.

3.1. Skirtingų paviršių defektų aptikimo sistemos realizacijos priemonė

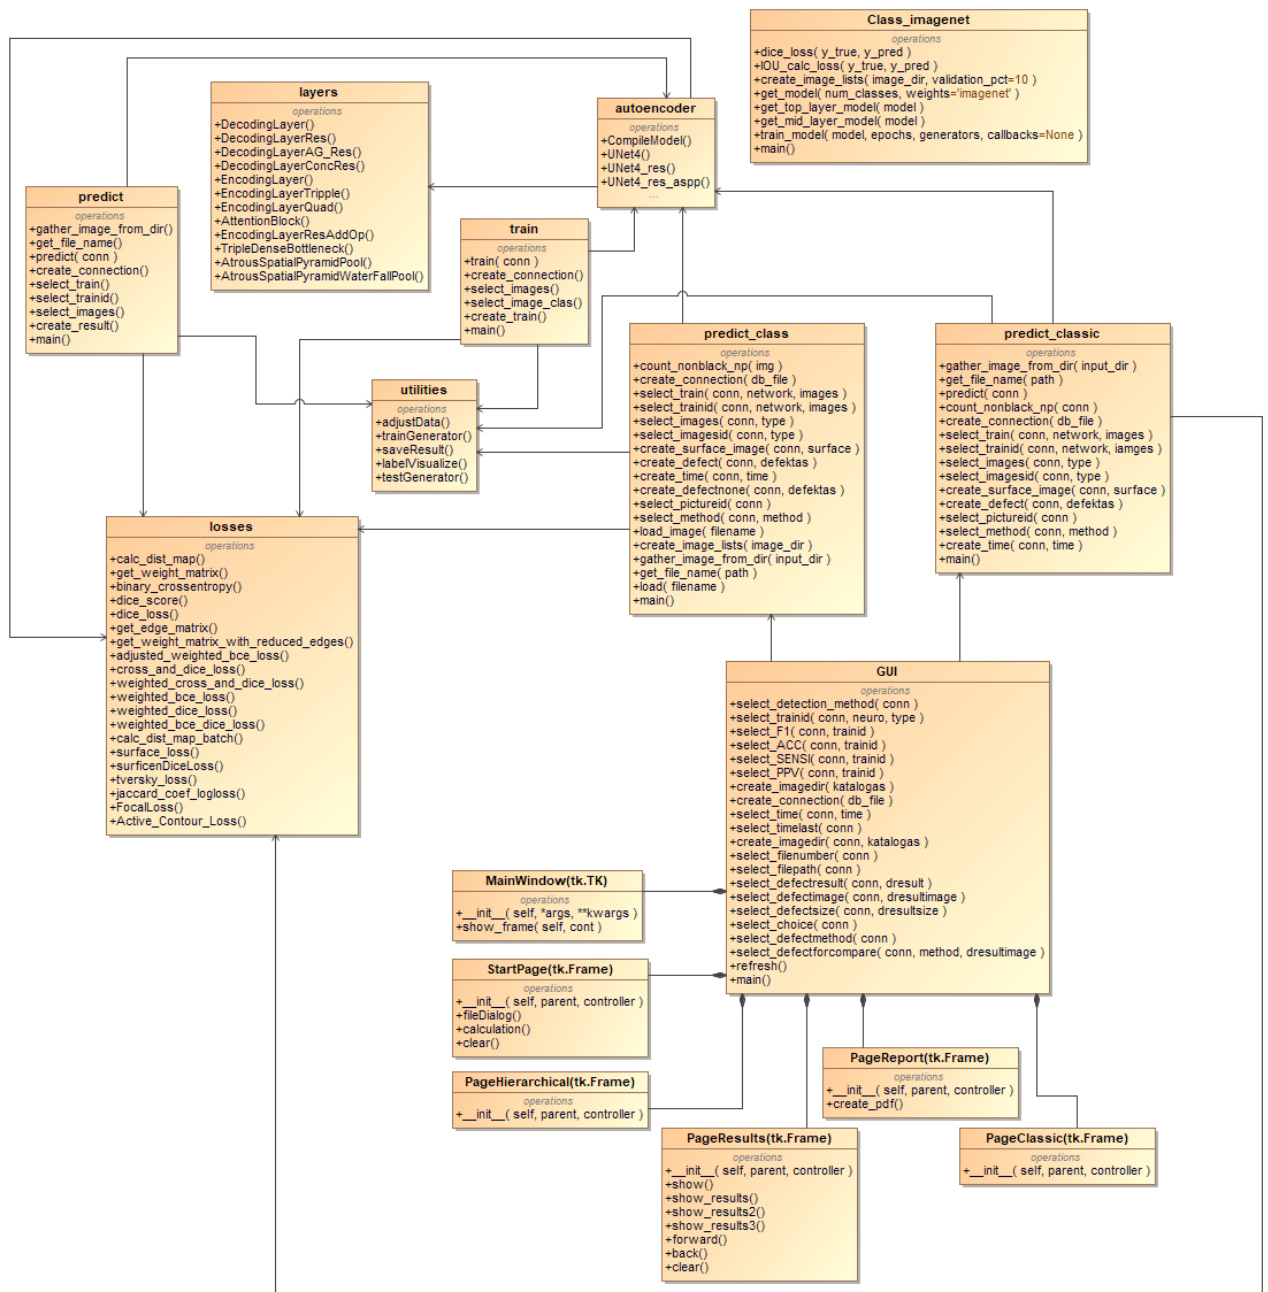
Sprendimo realizacijai pasirinkta „Python“ programavimo kalba. Programavimo kalbos pasirinkimą lėmė tai, kad „Python“ programavimo kalba yra draugiška pradedantiesiems, lengvai suprantama ir lanksti. Programavimo kalba pasižymi lankstumu, nes nėra apibrėžtų griežtų taisyklių, pagal kurias turėtų būti užrašomas vienas ar kitas metodas. Tai reiškia, kad paviršinių defektų aptikimo sistemai sukurti nėra apibrėžto vieno konkretaus metodo, o eksperimentuojant ir kuriant informacinę sistemą, galima atrasti kiekvienam tinkamiausią metodą.

3.2. Skirtingų paviršių defektų aptikimo sistemos architektūra

Skirtingų paviršių defektų aptikimo sistemos architektūrą pateikiame diagramoje, kurioje atvaizduojame sukurtos sistemos funkcijas ir sąsajas tarp „Python“ duomenų failų (žr. 3.1 pav.).

Diagramos žymėjimų paaiškinimas:

- Klasė – „Python“ duomenų failas arba klasė „Python“ duomenų faile;
- Operacija – „Python“ duomenų faile arba klasėje esanti funkcija;
- Kryptingoji asociacija – kryptis nurodo, kuris „Python“ duomenų failas naudoja kito „Python“ duomenų failo funkciją (-as);
- Kompozicija – nurodo, kad „Python“ duomenų failas susideda iš klasių.



3.1 pav. Skirtingų paviršių defektų aptikimo sistemos architektūros modelis

Pateikiami aprašyti visi „Python“ duomenų failai, kurių dalis yra naudojama neuroninio tinklo mokymui, o kita dalis skirtingų paviršių defektų aptikimo sistemai (žr. 3.1 lentelė).

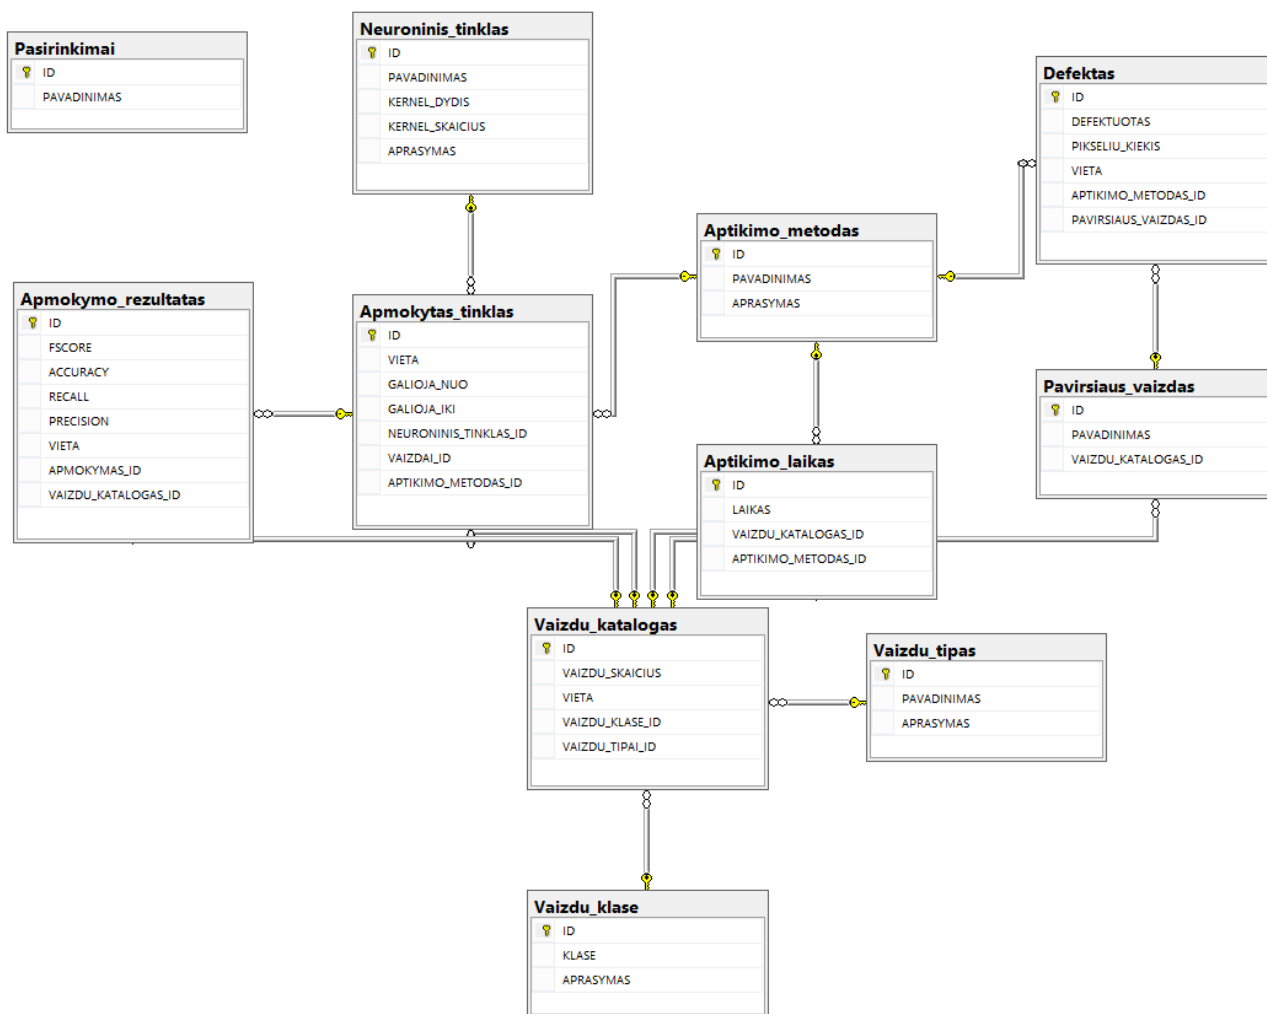
3.1 lentelė. „Python“ duomenų failų aprašymas

Duomenų failas	Tikslas	Aprašymas
Neuroninio tinklo mokymo „Python“ duomenų failai		
Train	Neuroninio tinklo mokymas defektų aptikimui	Moko neuroninį tinklą pagal nustatytą vaizdų klasę ir išsaugo išmokyto neuroninio tinklo svorius. Mokymui yra reikalingos funkcijos, kurios pateikiamos kituose duomenų failuose: autoencoder, losses, utilities. Neuroninis tinklas mokomas aptikti defektą skirtingose vaizdų klasėse.

Duomenų failas	Tikslas	Aprašymas
Utilities	Neuroninio tinklo mokymo funkcijų aprašymas	Funkcijose aprašomas neuroninio tinklo mokymui ir testavimui reikalingų duomenų paruošimas.
Autoencoder	Neuroninių tinklų aprašymas	Funkcijose aprašomos skirtingos neuroninio tinklo struktūros, kurios naudojamos mokymams ir defektų aptikimui.
Losses	Praradimo funkcijų aprašymas	Aprašomos praradimo funkcijos, kurios naudojamos neuroninio tinklo mokymui ir defektų aptikimui.
Layers	Neuroninio tinklo sluoksnių aprašymas	Aprašomi neuroninių tinklų sluoksniai, kuriuos naudoja neuroniniai tinklai.
Predict	Neuroninio tinklo validavimas	Atlieka mokytų neuroninių tinklų validaciją, norint patikrinti aptikimo kokybę.
Class_Imagenet	Neuroninio tinklo mokymas vaizdų klasių klasifikavimui	Moko neuroninį tinklą aptikti vaizdo klasę ir išsaugo neuroninio tinklo svorius.
Sistemos „Python“ duomenų failai		
GUI	Skirtingų paviršių defektų aptikimo sistema	Aprašyta skirtingų paviršiaus defektų aptikimo sistema, kurioje atliekamas defektų aptikimas pagal pasirinktą aptikimo metodą ir vaizdų katalogą. Kiekvienas sistemos langas aprašomas atskiroje klasėje: PageReport – aprašomas ataskaitos generavimo langas; PageClassic – aprašomas klasikinio metodo aptikimo kokybės įverčių peržiūros langas; PageHierarchical – aprašomas hierarchinio metodo aptikimo kokybės įverčių peržiūros langas; Pagesults – aprašomas rezultatų peržiūros langas; StartPage – aprašomas pagrindinis sistemos langas, kuriame galima pasirinkti aptikimo metodą, vaizdų katalogą, inicijuoti defektų aptikimą ir atidaryti rezultatų peržiūros langą. Defektų aptikimas atliekamas kreipiantis į duomenų failą predict_class arba predict_classic, kuris pasiima pasirinkto metodo neuroninius tinklus. Duomenų faile esančios bendros funkcijos aprašytos klasėje GUI, o unikalios funkcijos aprašytos prie atitinkamos klasės.
Predict_class	Defektų aptikimas hierarchiniu metodu	Pagal nustatytus išmokyto neuroninio tinklo svorius ir vaizdus, atlieka defektų aptikimą. Defektų aptikimas yra atliekamas hierarchiniu metodu, kurio metu yra kreipiamasi į du neuroninius tinklus. Pirmą kartą kreipiantis į neuroninį tinklą yra aptinkama vaizdo klasė, o antrą kartą kreipiantis yra aptinkamas defektas.
Predict_classic	Defektų aptikimas klasikiniu metodu	Pagal nustatytus išmokyto neuroninio tinklo svorius ir vaizdus, atlieka defektų aptikimą. Defektų aptikimas yra atliekamas su neuroniniu tinklu, kuris yra mokytas klasikiniu metodu.

3.3. Duomenų bazės modelis

Sistemos duomenų bazės kūrimui pasirinktas „SQLite“ reliacinė duomenų bazių valdymo sistema, kurios vienas iš privalumų, kad yra nemokamai platinama. Taip pat duomenų bazė yra sukuriama duomenų faile ir nėra reikalingas duomenų bazės serveris. Duomenų bazę sudaro dešimt lentelių, kurios sujungtos ryšiais (žr. 3.2 pav.).



3.2 pav. Skirtingų paviršių defektų aptikimo sistemos duomenų bazės schema

Pateikiami duomenų bazėje esančių lentelių aprašymai su atributų sąrašu, pirminiu raktu ir išoriniais raktais. „SQLite“ valdymo sistemoje nėra visų reikalingų atributų tipų, todėl pateikiame atributų tipų paaiškinimus:

- Nėra datos tipo, todėl naudojamas tekstinis tipas (angl. *text*);
- Nėra loginio tipo, todėl naudojamas skaitinis tipas (angl. *integer*), kur reikšmės yra:
 - 0 – taip;
 - 1 – ne.

Lentelė „Apmokymo_rezultatas“ pateikia validacijos rezultatus, kurie yra saugomi kompiuterio kataloge. Mokymo rezultatus sudaro kokybės įverčiai: F1, tikslumas, jautrumas ir PPV (žr. 3.2 lentelė).

Pirminis raktas: ID.

Išorinis raktas: APMOKYMAS_ID, VAIZDU_KATALOGAS_ID.

3.2 lentelė. Lentelės „Apmokymo_rezultatas“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalūs identifikatorius.

Atributo kodas	Atributo tipas	Atributo pavadinimas
FSCORE	REAL	Vieta, kurioje saugomi rezultatai su vaizdais.
ACCURACY	REAL	Aptikimo kokybės įvertis F1.
RECALL	REAL	Aptikimo kokybės įvertis tikslumas.
PRECISION	REAL	Aptikimo kokybės įvertis jautrumas.
VIETA	TEXT	Aptikimo kokybės įvertis PPV.
APMOKYMO_ID	INTEGER	Išorinis raktas į lentelę „Apmokytas_tinklas“.
VAIZDU_KATALOGAS_ID	INTEGER	Išorinis raktas į lentelę „Vaizdu_katalogas“.

Lentelė „Apmokytas_tinklas“ pateikia mokyto neuroninio tinklo svorių saugojimo vietą. Kiekvieno išsaugoto neuroninio tinklo svorio vieta turi galiojimo nuo ir galiojimo iki datas, kad būtų saugoma neuroninio tinklo svorių vieta ir iš naujo mokant neuroninį tinklą būtų tik viena galiojanti svorių saugojimo vieta (žr. 3.3 lentelė).

Pirminis raktas: ID.

Išorinis raktas: NEURONINIS_TINKLAS_ID, VAIZDAI_ID, APTIKIMO_METODAS_ID.

3.3 lentelė. Lentelės „Apmokytas_tinklas“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
VIETA	TEXT	Geriausiai išmokyto neuroninio tinklo svorių saugojimo vieta.
GALIOJA_NUO	TEXT	Galiojimo nuo data.
GALIOJA_IKI	TEXT	Galiojimo iki data.
NEURONINIS_TINKLAS_ID	INTEGER	Išorinis raktas į lentelę „Neuroninis_tinklas“.
VAIZDAI_ID	INTEGER	Išorinis raktas į lentelę „Vaizdu_katalogas“.
APTIKIMO_METODAS_ID	INTEGER	Išorinis raktas į lentelę „Aptikimo_metodas“.

Lentelė „Aptikimo_laikas“ pateikia defektų aptikimo laiką iš vaizdų kataloge esančių vaizdų (žr. 3.4 lentelė).

Pirminis raktas: ID.

Išorinis raktas: APMOKYMAS_ID, VAIZDU_KATALOGAS_ID.

3.4 lentelė. Lentelės „Aptikimo_laikas“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
LAIKAS	INTEGER	Vaizdų kataloge esančių vaizdų aptikimo laikas.
VAIZDU_KATALOGAS_ID	INTEGER	Išorinis raktas į lentelę „Vaizdu_katalogas“.
APTIKIMO_METODAS_ID	INTEGER	Išorinis raktas į lentelę „Aptikimo_metodas“.

Lentelė „Aptikimo_metodas“ pateikia galimus aptikimo metodus (žr. 3.5 lentelė).

Pirminis raktas: ID.

Išorinis raktas: -.

3.5 lentelė. Lentelės „Aptikimo_metodas“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
PAVADINIMAS	TEXT	Skirtingų paviršių defektų aptikimo metodas: Klasikinis; Hierarchinis.
APRASYMAS	TEXT	Skirtingų paviršių defektų aptikimo metodo aprašymas.

Lentelė „Defektas“ pateikia vieno paviršiaus vaizdo defekto aptikimo rezultatus (žr. 3.6 lentelė).

Pirminis raktas: ID.

Išorinis raktas: APTIKIMO_METODAS_ID, PAVIRSIAUS_VAIZDAS_ID.

3.6 lentelė. Lentelės „Defektas“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
DEFEKTUOTAS	INTEGER	Nurodo ar paviršiaus vaizde yra aptiktas defektas: 0 – taip, defektas aptiktas; 1 – ne, defektas neaptiktas.
PIKSELIU_KIEKIS	INTEGER	Defekto dydis pikseliais.
VIETA	TEXT	Vieta, kurioje saugomi vaizdo rezultatai.
APTIKIMO_METODAS_ID	INTEGER	Išorinis raktas į lentelę „Aptikimo_metodas“.
PAVIRSIAUS_VAIZDAS_ID	INTEGER	Išorinis raktas į lentelę „Paviršiaus_vaizdas“.

Lentelė „Neuroninis tinklas“ pateikia galimų neuroninių tinklų struktūrų pavadinimus su aprašymais (žr. 3.7 lentelė).

Pirminis raktas: ID.

Išorinis raktas: -.

3.7 lentelė. Lentelės „Neuroninis tinklas“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
PAVADINIMAS	TEXT	Neuroninio tinklo struktūros pavadinimas: „Unet4“; „Unet_res“; „Unet_res_aspp“.
KERNEL_DYDIS	INTEGER	Neuroniniame tinkle naudojamas (angl. <i>kernel</i>) dydis.
KERNEL_SKAICIUS	INTEGER	Neuroniniame tinkle naudojamas (angl. <i>kernel</i>) skaičius.
APRASYMAS	TEXT	Neuroninio tinklo struktūros aprašymas.

Lentelė „Pasirinkimai“ pateikia galimas reikšmes išskleidžiamam pasirinkimų laukui (žr. 3.8 lentelė).

Pirminis raktas: ID.

Išorinis raktas: -.

3.8 lentelė. Lentelės „Pasirinkimai“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
PAVADINIMAS	TEXT	Pasirinkimo reikšmės pavadinimas.

Lentelė „Pavirsiaus_vaizdas“ pateikia vieno vaizdo, kuriame yra ieškoma defekto, pavadinimą (žr. 3.9 lentelė).

Pirminis raktas: ID.

Išorinis raktas: VAIZDU_KATALOGAS_ID, DEFEKTAS_ID.

3.9 lentelė. Lentelės „Pavirsiaus_vaizdas“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
PAVADINIMAS	TEXT	Skirtingų paviršių defektų aptikimo metodas.
VAIZDU_KATALOGAS_ID	INTEGER	Išorinis raktas į lentelę „Vaizdu_katalogas“.

Lentelė „Vaizdu_katalogas“ pateikia „DAGM“ vaizdų katalogų vietas. Vaizdų kataloge yra saugomos tam tikros klasės ir tipo vaizdai (žr. 3.10 lentelė).

Pirminis raktas: ID.

Išorinis raktas: VAIZDU_KLASE_ID, VAIZDU_TIPAI_ID.

3.10 lentelė. Lentelės „Vaizdu_katalogas“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
VAIZDU_SKAICIUS_ID	INTEGER	Vaizdų kataloge esantis vaizdų skaičius.
VIETA	TEXT	Vaizdu saugojimo vieta kompiuteryje.
VAIZDU_KLASE_ID	INTEGER	Išorinis raktas į lentelę „Vaizdu_klase“.
VAIZDU_TIPAI_ID	INTEGER	Išorinis raktas į lentelę „Vaizdu_tipas“.

Lentelė „Vaizdu_klase“ pateikia galimas vaizdų klases su aprašymais. Kiekviena vaizdo klasė atitinka skirtingus vaizdų paviršius (žr. 3.11 lentelė).

Pirminis raktas: ID.

Išorinis raktas: -.

3.11 lentelė. Lentelės „Vaizdu_klase“ atributai

Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.

Atributo kodas	Atributo tipas	Atributo pavadinimas
KLASE	INTEGER	Vaizdų klasės: 0 – visos šešios klasės kartu; 1 – pirma klasė; 2 – antra klasė; 3 – trečia klasė; 4 – ketvirta klasė; 5 – penkta klasė; 6 – šešta klasė.
APRASYMAS	TEXT	Vaizdų klasės aprašymas.

Lentelė „Vaizdu_tipas“ pateikia galimus vaizdų tipus su aprašymais (žr. 3.12 lentelė).

Pirminis raktas: ID.

Išorinis raktas: -.

3.12 lentelė. Lentelės „Vaizdu_tipas“ atributai

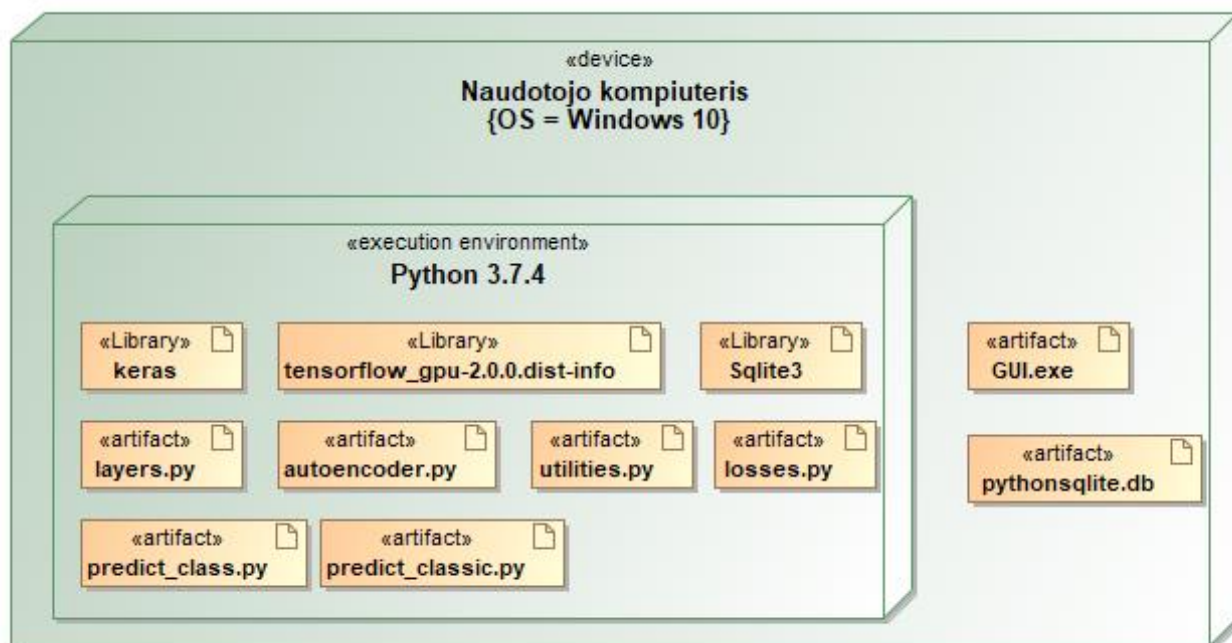
Atributo kodas	Atributo tipas	Atributo pavadinimas
ID	INTEGER	Unikalius identifikatorius.
PAVADINIMAS	TEXT	Vaizdų tipas: Mokymo; Validavimo; Testavimo.
APRASYMAS	TEXT	Vaizdų tipo aprašymas.

3.4. Diegimo diagrama

Skirtingų paviršių defektų aptikimo sistemai įdiegti rekomenduojama turėti kompiuterį, kurio parametrai nėra žemesni nei nurodyti:

- Operacinė sistema – Windows 10;
- Vaizdo plokštė – NVIDIA GeForce GTX 1080;
- Procesorius – AMD Ryzen 7 2700X Eight-Core Processor.

Pateikiamas artefaktų pasiskirstymas naudotojo kompiuteryje (žr. 3.3 pav.).



3.3 pav. Skirtingų paviršių defektų aptikimo sistemos diegimo diagrama

4. Skirtingų paviršių defektų aptikimo metodų ir sistemos realizacija ir testavimas

Sistemos realizaciją apima „DAGM“ duomenų bazės vaizdų paruošimas ir neuroninio tinklo mokymų tyrimas. Neuroninis tinklas mokomas skirtingos struktūromis, norint atrasti tiksliausiai išmokytą neuroninį tinklą kiekvienam iš defektų aptikimo metodui. Taip pat yra testuojamas sukurtos skirtingų paviršių defektų aptikimo sistemos veikimas naudojant atsitiktinius „DAGM“ duomenų bazės vaizdus.

4.1. Duomenų paruošimas

Skirtingų paviršių defektų aptikimo sistemai sukurti naudojama „DAGM“ duomenų bazės šešios vaizdo klasės. Pagal „DAGM“ duomenų bazę yra išmokomas neuroninis tinklas ir testuojami rezultatai, norint nustatyti defekto aptikimo tikslumą. „DAGM“ duomenų bazėje esantys vaizdai yra padalijami į mokymo ir testavimo imtis. Atitinkamai testavimo imtis papildomai padalijama, kad su dalimi duomenų būtų galima atlikti išmokyto neuroninio tinklo validaciją, o su likusia dalimi atlikti eksperimentinį testavimą.

Atrinkti mokymo vaizdai turi būti paruošiami, kad juos būtų galima naudoti neuroniniam tinklui mokyti. Kadangi „DAGM“ duomenų bazėje vaizdų su defektu yra daugiau nei vaizdų be defekto, nuspręsta mokymo vaizdus su defektu augmentuoti. Vaizdų augmentavimas atliekamas norint padidinti vaizdų su defektu kiekį, kad jis sutaptų su vaizdų be defekto kiekiu. Vienam vaizdui augmentavimas atliekamas septynis kartus: pasukant 90°, pasukant 180°, pasukant 270°, apverčiant 0°, apverčiant 90°, apverčiant 180°, apverčiant 270°. Pateikiame lentelę su vaizdų kiekiais, kurie naudojami neuroninio tinklo mokymui ir validavimui (žr. 4.1 lentelė).

4.1 lentelė. Vaizdų kiekis neuroninio tinklo mokymui ir validavimui

Vaizdų klasė	Mokymui		Validavimui	
	Su defektu	Be defekto	Su defektu	Be defekto
Pirma	553	575	71	505
Antra	462	575	84	491
Trečia	462	575	84	491
Ketvirta	574	575	68	507
Penka	490	575	80	495
Šešta	581	575	67	509

4.2. Neuroninio tinklo mokymo rezultatai

Pateikiami kiekvieno iš metodų mokymo kokybės įverčiai ir defekto aptikimo vaizdo rezultatai. Klasikinis mokymo metodas remiasi tuo, kad vaizdai su kaukėmis iš šešių skirtingų „DAGM“ duomenų bazių yra dedami į vieną vietą. Tada mokant neuroninį tinklą yra naudojami visi vaizdai, neatsižvelgiant į vaizdo klasę. Hierarchinio mokymo metodas yra priešingas klasikiniam metodui. Hierarchiniame metode su kiekviena „DAGM“ duomenų bazės klase yra mokomas neuroninis tinklas. Taip pat papildomai yra mokomas neuroninis tinklas, kad galėtų atpažinti įkelto vaizdo klasę ir pagal nustatytai klasei priskirtą neuroninio tinklo mokymą atlikti defekto nustatymą.

Metodams mokyti pasirinktas „U-Net“ neuroninis tinklas, kuris gali aptikti defektą pikselio lygyje. Palyginimui pasirinktos kelios skirtingos „U-Net“ neuroninio tinklo struktūros, kurių mokymo rezultatai lyginami tarpusavyje.

Sistema sukurta pagal geriausiai defektams aptikti išmokytus neuroninius tinklus. Sistemos tikslas naudotojui leisti palyginti skirtingus mokymo metodus, inicijuojant defektų aptikimą pasirinktiems vaizdams.

4.2.1. Hierarchinio metodo sukūrimo kokybės įverčiai

Tinkamam metodo funkcionavimui turi būti atliekamas tikrinimas nustatant, kuris neuroninis tinklas pateikia tiksliausių defektų aptikimo rezultatus. Atitinkamai klasių klasifikavimui ir kiekvienos vaizdo klasės defektų aptikimui pateikiami rezultatai su skirtingais neuroniniais tinklais. Rezultatai vertinami atsižvelgiant į aptikimo kokybės įverčius ir aptinkamą defektą vaizde.

Šiame skyriuje pateikiamo defektų aptikimo metodui yra reikalingas vaizdo klasės klasifikavimas, pagal kurį sistema nuspręstų, kuriai vaizdo klasei priklauso tikrinamas vaizdas. Klasės klasifikavimas yra labai svarbus, nes nuo to priklauso viso metodo defektų aptikimo kokybė. Vaizdų klasių klasifikavimui naudojamas „MobileNet“ ir „Inception-v3“ neuroniniai tinklai, kurių mokymų rezultatai pateikiami lentelėje (žr. 4.2 lentelė). Atitinkamai kiekvienas neuroninis tinklas buvo mokomas su skirtingu imties dydžiu, kuris turi įtakos mokymų rezultatams. Tačiau imties dydis yra priklausomas nuo technikos resursų, todėl pasirinktas didžiausias imties dydis, kuris yra lygus 60, ir palyginimui pasirinktas imties dydis 40. Žalia spalva išskiriami aukščiausi kokybės įverčiai.

4.2 lentelė. Vaizdo klasių klasifikavimo kokybės įverčiai

	MobileNet		Inception-v3	
	Imtis = 40	Imtis = 60	Imtis = 40	Imtis = 60
F1	0,355	0,515	0,42	0,7
Tikslumas	0,43	0,57	0,52	0,75
Jautrumas	0,4283	0,565	0,5133	0,7433
PPV	0,3717	0,5483	0,6917	0,8633

Kaip galima matyti iš vaizdo klasių klasifikavimo rezultatų, geriausi įverčiai yra tada, kai imties dydis yra didesnis. Lyginant „MobileNet“ ir „Inception-v3“, geresni aptikimo rezultatai yra pasiekiami su „Inception-v3“ neuroniniu tinklu. Tačiau klasifikavimo kokybės įverčiai nėra labai aukšti, tai reiškia, kad kai kurios klasės nėra suklasifikuojamos tinkamai. Pateikiame geriausiai išmokyto neuroninio tinklo pasiskirstymo matricą, kurioje galima matyti klaidingai klasifikuojamas klases (žr. 4.3 lentelė).

4.3 lentelė. „Inception-v3“ neuroninio tinklo mokymo pasiskirstymo matrica

		Prognozuojama klasė					
		1 klasė	2 klasė	3 klasė	4 klasė	5 klasė	6 klasė
Tikra klasė	1 klasė	281	186	0	0	3	40
	2 klasė	0	481	0	0	2	0
	3 klasė	0	0	20	0	2	461
	4 klasė	0	0	0	516	0	0

	5 klasė	0	0	0	0	429	63
	6 klasė	0	0	0	0	0	519


Pagal pateiktą pasiskirstymo matricą galima pastebėti, kad daugiausiai pirmos ir trečios klasės vaizdai yra klasifikuojami klaidingai. Klaidingas klasifikavimas atsiranda dėl to, kad vaizdų šių klasių vaizdų paviršiai yra labai panašūs tarpusavyje. Priešingai yra su ketvirta vaizdų klase, kurioje paviršiaus vaizdas yra išsiskiriantis ir tokiu atveju neuroninis tinklas teisingai suklasifikuoja visus vaizdus iš ketvirtos klasės.

Hierarchinio mokymo metodas remiasi tuo, kad neuroninis tinklas yra mokomas tik su konkrečios klasės vaizdu. Su kiekviena vaizdo klase yra mokytos skirtingos „U-Net“ neuroninio tinklo struktūros. Mokytų neuroninių tinklų aptikimo kokybės įverčius pateikiame lentelėje, kur žalia spalva išskirtas geriausio kokybės įverčio rezultatas tarp skirtingų „U-Net“ neuroninio tinklo struktūrų vienoje vaizdų klasėje (žr. 4.4 lentelė).


4.4 lentelė. Šešių vaizdo klasių aptikimo kokybės įverčiai

	1 klasė			2 klasė			3klasė		
	Unet4	Unet4_re s	Unet4_r es_aspp	Unet4	Unet4_r es	Unet4_re s_aspp	Unet4	Unet4_r es	Unet4_r es_aspp
F1	0,8772	0,9594	0,9855	0,9771	0,9734	0,9789	0,9848	0,9833	0,988
Tikslumas	0,9954	0,9952	0,999	0,9995	0,9995	0,9996	0,9996	0,9995	0,9996
Jautrumas	0,8769	0,985	0,9895	0,9706	0,9765	0,9815	0,9841	0,9803	0,9899
PPV	1	0,9614	0,9859	0,9892	0,9791	0,9813	0,9894	0,9896	0,988
	4 klasė			5klasė			6klasė		
	Unet4	Unet4_re s	Unet4_r es_aspp	Unet4	Unet4_r es	Unet4_re s_aspp	Unet4	Unet4_r es	Unet4_r es_aspp
F1	0,8909	0,9777	0,9799	0,9931	0,9909	0,9944	0,9943	0,9934	0,9963
Tikslumas	0,9989	0,9992	0,9994	0,9997	0,9998	0,9998	0,999	0,9992	0,9994
Jautrumas	0,9803	0,9764	0,9861	0,9899	0,9934	0,9931	0,999	0,9954	0,9955
PPV	0,898	0,9897	0,9844	0,9971	0,9922	0,9961	0,99	0,9932	0,9971

Pagal gautus aptikimo kokybės įverčius galima pastebėti, kad nė vienai klasei nėra tokios „U-Net“ neuroninio tinklo struktūros, kad visi įverčiai pateiktų aukščiausius rezultatus. Pirmos vaizdų klasės defektus tiksliausiai aptinka struktūra „Unet4_res_aspp“, nors su pirma struktūra „Unet4“ yra gaunamas aukščiausias galimas PPV kokybės įvertis. Pateikiami pirmos klasės vaizdo defekto aptikimo rezultatai su struktūra „Unet4“ ir „Unet4_res_aspp“ (žr. 4.1 pav., 4.2 pav.).



4.1 pav. Pirmos klasės defekto aptikimas su struktūra „Unet4“ hierarchiniame metode




4.2 pav. Pirmos klasės defekto aptikimas su struktūra „Unet4_res_aspp“ hierarchiniame metode

Nors su struktūra „Unet4“ aptikimo kokybės įvertis PPV buvo aukščiausias, bet pagal pateiktą defekto aptikimo rezultatą matoma, kad defektas nėra aptinkamas. Aukštą PPV įvertį lemia tai, kad jo apskaičiavimui yra naudojama tik teigiamos klasės rezultatas iš pasiskirstymo matricos. Kadangi ne defekto (teigiama klasė) plotas yra didesnis už defekto plotą, todėl teisingai aptinkama ne defekto sritis padidina PPV įvertį, neatsižvelgiant į neaptinkamą defekto sritį. Struktūra „Unet4_res_aspp“ tiksliausiai aptinka defektą iš pirmos klasės vaizdų, tai galima pastebėti ir iš pateikto defekto aptikimo vaizde (žr. 4.2 pav.).


Pagal aptikimo kokybės įverčių lentelę galima pastebėti, kad antros klasės vaizdams kokybės įvertis PPV yra didesnis struktūrai „Unet4“. Tačiau kaip buvo išsiaiškinta prie pirmos klasės vaizdų, tai

lema PPV įverčio apskaičiavimo taisyklės, todėl galima teigti, kad antroje klasėje defektas geriausiai aptinkamas su struktūra „Unet4_res_aspp“.


Trečios klasės vaizdams visose trijose struktūrose yra bent po vieną aptikimo kokybės įvertį, kuris yra aukščiausias. Todėl palyginimui pateikiame defekto aptikimo rezultatą su kiekviena iš struktūrų (žr. 4.3 pav., 4.4 pav., 4.5 pav.).



4.3 pav. Trečios klasės defekto aptikimas su struktūra „Unet4“ hierarchiniame metode



4.4 pav. Trečios klasės defekto aptikimas su struktūra „Unet4_res“ hierarchiniame metode



4.5 pav. Trečios klasės defekto aptikimas su struktūra „Unet4_res_aspp“ hierarchiniame metode

Peržiūrint trečios klasės defekto aptikimo rezultatus kiekvienai iš „U-Net“ neuroninio tinklo struktūrų pastebima, kad vizualiai defekto aptikimas nesiskiria. Kiekviena iš struktūrų aptinka defektą, sumažindama defekto sritį. Sumažinta defekto sritis yra tikslingesnė naudotojui, tačiau neuroninis tinklas, tai traktuoja kaip klaidingą aptikimą, nes pateikta vaizdo kaukė buvo didesnė. Dėl to gali būti apskaičiuojami mažesni aptikimo kokybės įverčiai, nors pats defektas vaizde aptinkamas tiksliau. Norint parinkti geriausią struktūrą trečios klasės vaizdams aptikti vertiname pagal aukščiausių aptikimo kokybės įverčių kiekį tam tikroje struktūroje. Trečios klasės vaizdams defektą tiksliausiai aptinka struktūra „Unet4_res_aspp“.

Ketvirtos klasės vaizdų defekto aptikimo kokybės įverčiai parodo, kad tiksliausiai defektas aptinkamas su struktūra „Unet4_res_aspp“, nors struktūra „Unet4“ pateikia aptikimo kokybės įverčio PPV aukščiausių rezultatą. Tačiau kaip ir su pirma bei antra vaizdų klase, tai yra dėl to, kad yra vertinama tik be defekto srities aptikimas.

Gautuose defektų aptikimo rezultatuose iš penktos ir šeštos klasės pastebima, kad nėra vaizdo, kurio defekto aptikimas būtų netikslus. Tai galima pastebėti ir iš aptikimo kokybės įverčių, kuriuose penktos ir šeštos vaizdo klasės visi įverčiai yra didesni už 0,993 (žr. 2.13 lentelė). Kitoms vaizdo klasėms daugiausiai du aptikimo kokybės įverčiai yra didesni už 0,9993. Tokiu atveju vertiname pagal kurio neuroninio tinklo struktūrą yra didžiausi aptikimo kokybės įverčiai. Penktai ir šeštai klasei aukščiausi aptikimo kokybės įverčiai yra gaunami su „U-Net“ neuroninio tinklo struktūra „Unet4_res_aspp“.

4.2.2. Klasikinio metodo sukūrimo kokybės įverčiai

Klasikinio metodo mokymas remiasi tuo, kad neuroninis tinklas yra mokomas atpažinti defektus iš visų klasių iš karto, nepriklausomai nuo paviršiaus vaizdo klasės. Atitinkamai neuroninis tinklas yra mokomas pagal tris „U-Net“ struktūras: „Unet4“, „Unet4_res“ ir „Unet4_res_aspp“. Neuroninis tinklas mokytas iš karto su visais skirtingų paviršių vaizdais, validacija yra atliekama kiekvienai skirtingo paviršiaus vaizdo klasei atskirai. Kiekvienos vaizdų klasės aptikimo kokybės įverčius


pateikiame lentelėje ir žalia spalva paryškintas langelis, kurio kokybės įvertis yra aukščiausias tam tikroje vaizdo klasėje (žr. 4.5 lentelė).

4.5 lentelė. Kiekvienos vaizdo klasės aptikimo kokybės įverčiai, kai neuroninis tinklas mokytas iš karto su visų klasių vaizdais


	1 klasė			2 klasė			3klasė		
	Unet4	Unet4 _res	Unet4 _res_a spp	Unet4	Unet4 _res	Unet4 _res_a spp	Unet4	Unet4 _res	Unet4 _res_a spp
F1	0,9823	0,9365	0,9877	0,9746	0,948	0,974	0,9789	0,9054	0,9836
Tikslumas	0,9986	0,9968	0,9991	0,9995	0,9993	0,9996	0,9994	0,9994	0,9995
Jautrumas	0,9804	0,9226	0,9924	0,9714	0,9371	0,9729	0,9729	0,9794	0,9893
PPV	0,9891	0,9934	0,9857	0,9847	0,9922	0,983	0,9903	0,9104	0,9808
	4 klasė			5klasė			6klasė		
	Unet4	Unet4 _res	Unet4 _res_a spp	Unet4	Unet4 _res	Unet4 _res_a spp	Unet4	Unet4 _res	Unet4 _res_a spp
F1	0,9832	0,9023	0,9741	0,9913	0,9882	0,9936	0,9922	0,9839	0,9918
Tikslumas	0,9993	0,9982	0,9994	0,9997	0,9997	0,9998	0,9986	0,9977	0,9986
Jautrumas	0,9825	0,9363	0,9852	0,9874	0,989	0,9937	0,9984	0,9723	0,9957
PPV	0,9899	0,9456	0,9788	0,9964	0,9918	0,994	0,9869	0,9998	0,9883

Pagal pateiktus aptikimo kokybės įverčius galima pastebėti, kad nuo pirmos iki penktos klasės imtinai aukščiausios kokybės įverčių reikšmės yra gaunamos su struktūra „Unet4_res_aspp“. Šeštos klasės paviršių vaizdams geriausiai išmokytas neuroninis tinklas yra su struktūra „Unet4“.

Vertinant neuroninio tinklo kokybę atsižvelgiama į pačių defektų aptikimą vaizde. Pirmos klasės vaizdams geriausius aptikimo kokybės įverčius pateikia struktūros „Unet4_res“ ir „Unet4_res_aspp“. Pateikiamo vieno vaizdo su defektu aptikimo rezultatai nurodyti „U-Net“ neuroninio tinklo struktūroms (žr. 4.6 pav., 4.7 pav.).



4.6 pav. Pirmos klasės defekto aptikimas su struktūra „Unet4_res“ klasikiniame metode

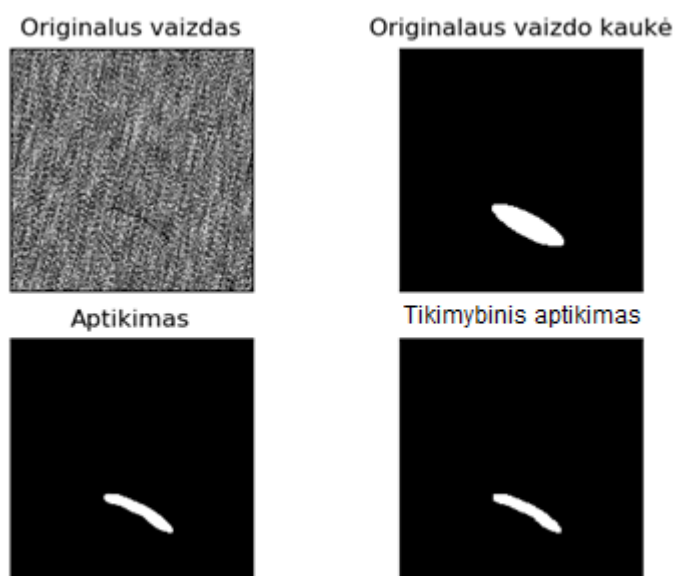


4.7 pav. Pirmos klasės defekto aptikimas su struktūra „Unet4_res_aspp“ klasikiniame metode

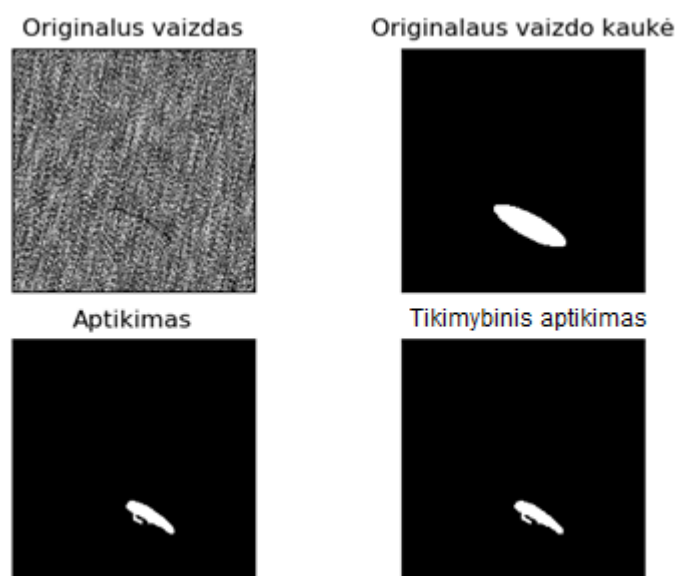
Pirmos klasės defektų aptikimas su neuroninio tinklo struktūra „Unet4_res“ pateikia nepilną defekto aptikimą, tai galima matyti iš defekto aptikimo rezultato. Nors aptikimo kokybės įvertis PPV yra aukščiausias, bet kai kuriose vietose defektas nėra aptinkamas ryškiai. Tai yra todėl, kad neuroninis tinklas stengiasi aptikti defekto vidų, o ne akiai išmokti defektą pagal pateiktą vaizdo kaukę. Priešingas defektų aptikimas yra su neuroninio tinklo struktūra „Unet4_res_aspp“, kur visas pažymėtas defektas yra beveik pilnai aptinkamas vaizde.

Pagal antros klasės vaizdus pastebėta, kad visoms „U-Net“ neuroninio tinklo struktūroms defektas yra aptinkamas reikiamoje vietoje, tačiau kai kurios struktūros defekto aptikimą pateikia mažesnėje srityje. Pagal pateiktą vaizdo aptikimo pavyzdį, struktūra „Unet4“ defektą pateikia tiksliau ir galima išvelgti pačią defekto formą (žr. 4.8 pav.). Su struktūra „Unet4_res“ aptinkamas defektas, bet daugiau

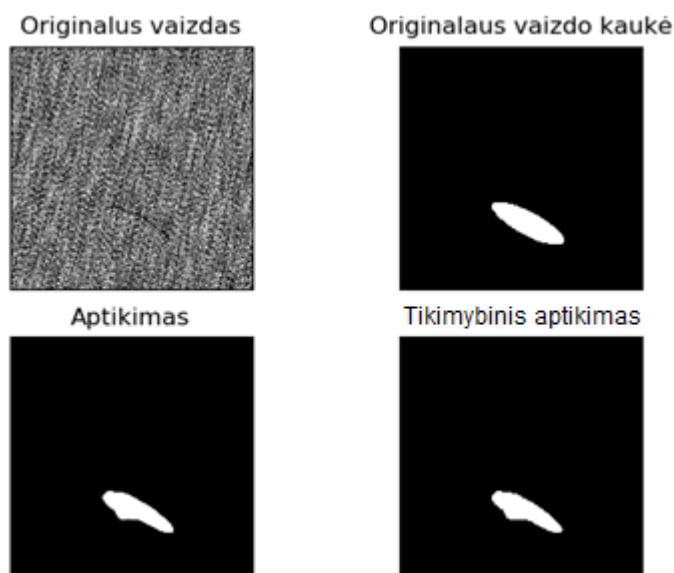
yra pateikiama ir be defekto vaizdo (žr. 4.9 pav.). Daugiausiai paviršiaus vaizdo aptinkama ir mažiausiai matosi defekto forma su neuroninio tinklo struktūra „Unet4_res_aspp“ (žr. 4.10 pav.).



4.8 pav. Antros klasės defekto aptikimas su struktūra „Unet4“ klasikiniame metode



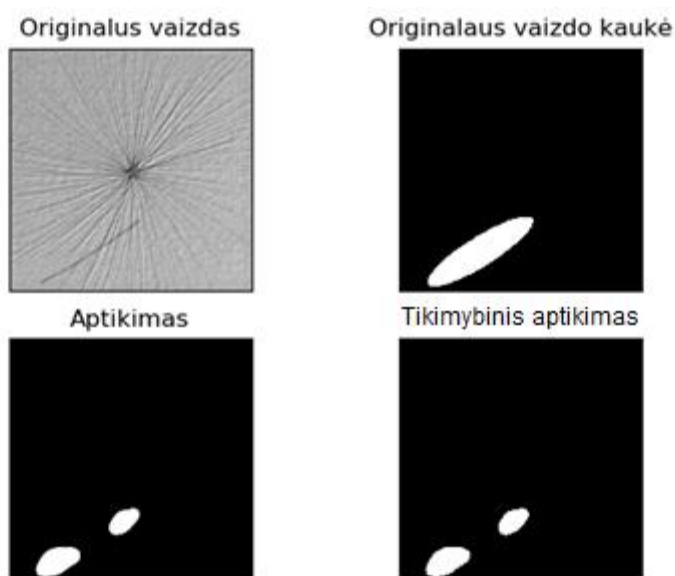
4.9 pav. Antros klasės defekto aptikimas su struktūra „Unet4_res“ klasikiniame metode



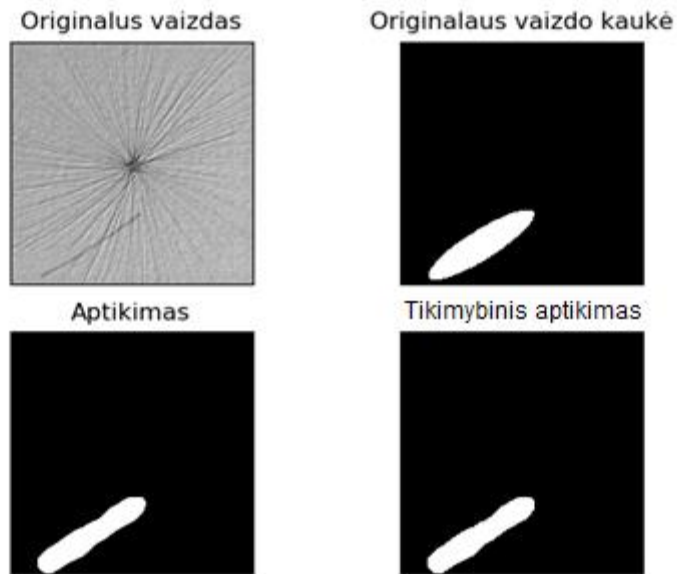
4.10 pav. Antros klasės defekto aptikimas su struktūra „Unet4_res_aspp“ klasikiniame metode

Pagal aptikimo kokybės įverčius su struktūra „Unet4_res_aspp“ yra daugiau įverčių, kurie yra aukštesni lyginant defekto aptikimą su kitomis struktūromis. Aptikimo kokybės įverčiai remiasi vaizdo kaukės pateiktais duomenimis, kadangi pagal struktūrą „Unet4_res_aspp“ yra aptinkama didesnė kaukės dalis, todėl dalis įverčių yra didesni.

Ketvirtos klasės vaizdai yra išskirtinio paviršiaus, lyginant su kitomis penkiomis klasėmis, todėl jų paviršiaus defektas gali būti priskiriamas prie paviršiaus arba priešingai. Pateikiame defekto aptikimo pavyzdžių su struktūromis „Unet4“ ir „Unet4_res_aspp“ (žr. 4.11 pav., 4.12 pav.).

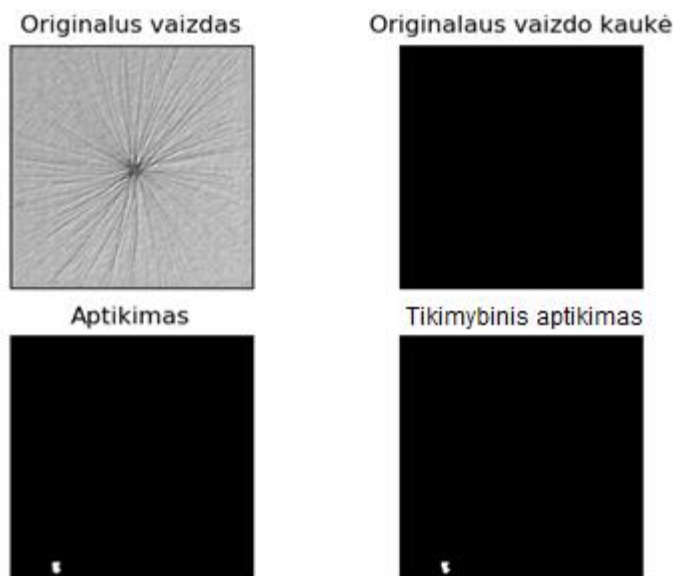


4.11 pav. Ketvirtos klasės defekto aptikimas su struktūra „Unet4“ klasikiniame metode



4.12 pav. Ketvirtos klasės defekto aptikimas su struktūra „Unet4_res_aspp“ klasikiniame metode

Pagal defekto aptikimo su struktūra „Unet4“ rezultatą galima pastebėti, kad defektas yra padalijamas į dvi dalis ir dalis defekto yra priskiriama prie paviršiaus vaizdo. Tačiau mokytas „U-Net“ neuroninis tinklas su struktūra „Unet4_res_aspp“ aptinka visą defektą, nepriskiriant dalies defekto paviršiui arba priešingai. Taip pat su struktūra „Unet4“ pastebėta, kad pasitaiko atvejis, kai yra aptinkamas defektas, nors iš tikrųjų jo nėra (žr. 4.13 pav.).



4.13 pav. Ketvirtos klasės defekto aptikimas su struktūra „Unet4“ klasikiniame metode

Patikrintas neuroninio tinklo mokymas, kai validacijai nėra atskiriamos vaizdų klasės, t. y. validuojami visi visų klasių vaizdai iš karto. Validacijos rezultatus pateikiame lentelėje (žr. 4.6 lentelė).

4.6 lentelė. Bendri visų klasių aptikimo kokybės įverčiai, kai neuroninis tinklas mokytas iš karto su visų klasių vaizdais

	Unet4	Unet4_res	Unet4_res_aspp
F1	0,9837	0,9441	0,9841
Tikslumas	0,9992	0,9985	0,9993
Jautrumas	0,9822	0,9561	0,9882
PPV	0,9895	0,9722	0,9851

Aptikimo kokybės įverčiai iš visų vaizdų pateikia panašūs rezultatai kaip ir aptikimo kokybės įverčiai kiekvienai klasei atskirai. Pagal įverčius geriausias rezultatas yra pateikiamas su „U-Net“ neuroninio tinklo struktūra „Unet4_res_aspp“.

4.2.3. Neuroninio tinklo mokymų apibendrinimas

Atliktas skirtingų neuroninių tinklų mokymas pateikė neuroninius tinklus, kurie tiksliausiai aptinka norimą rezultatą. Iš mokytų neuroninių tinklų vaizdų klasių klasifikavimui tiksliausius rezultatus pateikia „Inception-v3“ neuroninis tinklas su imtimi 60. Hierarchiniame metode tiksliausius rezultatus pateikia „U-Net“ neuroninis tinklas su struktūra „Unet4_res_aspp“. Klasikiniam metodui vertinant neuroninio tinklo mokymą visoms klasėms ir kiekvienai klasei atskirai tiksliausius rezultatus pateikia „U-Net“ neuroninis tinklas su struktūra „Unet4_res_aspp“.

Atrastos tiksliausios neuroninio tinklo struktūros ir modifikacijos defektų aptikimui klasikiniam ir hierarchiniam metodui. Neuroninių tinklų pagalba sukurti metodai naudojami skirtingų paviršių defektų aptikimo sistemoje.

4.3. Testavimo scenarijai ir duomenys

Skirtingų paviršių defektų aptikimo sistema testuojama pagal aprašytus scenarijus, kiekvienam iš jų pateikiant testavimo rezultatus. Skyriuje aprašomi visi testavimo scenarijai, duomenys naudojami testavimui ir testavimo rezultatai pateikiami prieduose. Sistemos testavimui naudojami aprašyto testavimo scenarijai, kurie aprašomi atsižvelgiant į sistemos specifikaciją. Testavimo scenarijai su aprašymais pateikiami lentelėje (žr. 4.7 lentelė). Testavimo rezultatų su sistemos vaizdais yra pateikiami 1 priede.

4.7 lentelė Skirtingų paviršių defektų aptikimo sistemos testavimo scenarijai

TS	Pavadinimas	Nr.	Testavimo aprašymas	Turimas gauti rezultatas	Rezultatas
TS1.	Defektų aptikimo metodų pasirinkimas	1.1.	Pradinė sąlyga: * Atidarytas paviršinių defektų informacinės sistemos pagrindinis langas. 1. Išskleidžiami lauko „Defektų aptikimo metodas“ pasirinkimai. 2. Pasirenkamas defektų aptikimo metodas „Klasikinis“. 3. Pasirenkamas defektų aptikimo metodas „Hierarchinis“.	1. Pateikiami pasirinkimai „Klasikinis“ ir „Hierarchinis“. 2. Atvaizduojamas pasirinkimas „Klasikinis“. 3. Atvaizduojamas pasirinkimas „Hierarchinis“.	Sėkminga

TS	Pavadinimas	Nr.	Testavimo aprašymas	Turimas gauti rezultatas	Rezultatas
TS2.	Vaizdų katalogo pasirinkimas	2.1.	Pradinė sąlyga: * Atidarytas paviršinių defektų informacinės sistemos pagrindinis langas. 1. Paspaudžiamas mygtukas [Pasirinkti]. 2. Pasirenkamas vaizdų katalogas.	1. Atidaromas failų dialogo langas. 2. Atvaizduojama vaizdų katalogo vieta lauke „Vaizdų katalogas“.	Sėkminga
TS3.	Defektų aptikimas	3.1.	Pradinė sąlyga: * Atidarytas paviršinių defektų informacinės sistemos pagrindinis langas. * Pasirinktas defektų aptikimo metodas. 1. Spaudžiamas mygtukas [Pradėti aptikimą].	1. Pateikiamas klaidos pranešimas „Nepasirinktas vaizdų katalogas“.	Sėkminga
		3.2.	Pradinė sąlyga: * Atidarytas paviršinių defektų informacinės sistemos pagrindinis langas. * Pasirinktas vaizdų katalogas. 1. Spaudžiamas mygtukas [Pradėti aptikimą].	1. Pateikiamas klaidos pranešimas „Nepasirinktas aptikimo metodas“.	Sėkminga
		3.3.	Pradinė sąlyga: * Atidarytas paviršinių defektų informacinės sistemos pagrindinis langas. * Pasirinktas defektų aptikimo metodas. * Pasirinktas vaizdų katalogas. 1. Spaudžiamas mygtukas [Pradėti aptikimą].	1. Pradedamas defektų aptikimas, aptinkami defektai ir pateikiamas mygtukas [Peržiūrėti rezultatus].	Sėkminga
TS4.	Rezultatų peržiūra	4.1.	Pradinė sąlyga: * Atliktas defektų aptikimas. 1. Spaudžiamas mygtukas [Peržiūrėti rezultatus]. 2. Spaudžiamas mygtukas [Rodyti]. 3. Spaudžiamas mygtukas [Sekantis]. 4. Spaudžiamas mygtukas [Ankstesnis].	1. Atidaromas rezultatų peržiūros langas ir pateikiamas apskaičiuotas defektų aptikimo laikas. 2. Pateikiamas tikrintas vaizdas ir defekto dydis. 3. Pateikiamas sekančio vaizdo rezultatai. 4. Pateikiami prieš tai buvusio vaizdo rezultatai.	Sėkminga
		4.2.	Pradinė sąlyga: * Atidarytas rezultatų peržiūros langas. 1. Spaudžiamas mygtukas [Rodyti]. 2. Spaudžiamas mygtukas [Išvalyti].	1. Pateikiamas tikrintas vaizdas ir defekto dydis. 2. Neatvaizduojamas tikrintas vaizdas ir defekto dydis.	Sėkminga

TS	Pavadinimas	Nr.	Testavimo aprašymas	Turimas gauti rezultatas	Rezultatas
		4.3.	Pradinė sąlyga: * Atidarytas rezultatų peržiūros langas. 1. Spaudžiamas mygtukas [Atgal].	1. Atidaromas pagrindinis sistemos langas.	Sėkminga
		4.4.	Pradinė sąlyga: * Atidarytas rezultatų peržiūros langas. 1. Spaudžiamas mygtukas [Formuoti ataskaitą].	1. Atidaromas ataskaitos formavimo langas.	Sėkminga
TS5.	Ataskaitos formavimas	5.1.	Pradinė sąlyga: * Atidarytas ataskaitos formavimo langas. 1. Spaudžiamas mygtukas [Atgal].	1. Atidaromas rezultatų peržiūros langas.	Sėkminga
		5.2.	Pradinė sąlyga: * Atidarytas ataskaitos formavimo langas. 1. Peržiūrimas laukas „Ar palyginti metodus?“. 2. Išskleidžiamas laukas „Ar palyginti metodus?“.	1. Pateikiama nustatyta reikšmė „Ne“. 2. Pateikiami pasirinkimai „Taip“ ir „Ne“.	Sėkminga
		5.3.	Pradinė sąlyga: * Atidarytas ataskaitos formavimo langas. * Paskutinis defektų aptikimas atliktas klasikiniu metodu. 1. Spaudžiamas mygtukas [Formuoti].	1. Suformuojama klasikinio metodo defektų aptikimo ataskaita.	Sėkminga
		5.4.	Pradinė sąlyga: * Atidarytas ataskaitos formavimo langas. * Paskutinis defektų aptikimas atliktas hierarchiniu metodu. 1. Spaudžiamas mygtukas [Formuoti].	1. Suformuojama hierarchinio metodo defektų aptikimo ataskaita.	Sėkminga
		5.5.	Pradinė sąlyga: * Atidarytas ataskaitos formavimo langas. * Lauko „Ar palyginti metodus?“ reikšmė „Taip“. * Neatliktas defektų aptikimas klasikiniu arba hierarchiniu metodu. 1. Spaudžiamas mygtukas [Formuoti].	1. Pateikiamas klaidos pranešimas.	Sėkminga
		5.6.	Pradinė sąlyga: * Atidarytas ataskaitos formavimo langas.	1. Suformuojama ataskaita metodų palyginimui.	Sėkminga

TS	Pavadinimas	Nr.	Testavimo aprašymas	Turimas gauti rezultatas	Rezultatas
			<p>* Lauko „Ar palyginti metodus?“ reikšmė „Taip“.</p> <p>1. Spaudžiamas mygtukas [Formuoti].</p>		
TS6.	Klasikinio metodo kokybės įverčių peržiūra	6.1.	<p>1. Spaudžiamas mygtukas [Klasikinis].</p> <p>2. Peržiūrimi klasikinio metodo kokybės įverčiai.</p> <p>3. Spaudžiamas mygtukas [Atgal].</p>	<p>1. Atidaromas klasikinio metodo kokybės įverčių peržiūros langas.</p> <p>2. Pateikiami apskaičiuoti aptikimo kokybės įverčiai laukuose „F1“, „Tikslumas“, „Jautrumas“, „PPV“.</p> <p>3. Sugrįžtama į pagrindinį sistemos langą.</p>	Sėkminga
TS7.	Hierarchinio metodo kokybės įverčių peržiūra	7.1.	<p>Pradinė sąlyga:</p> <p>* Atidarytas hierarchinio metodo kokybės įverčių peržiūros langas.</p> <p>1. Peržiūrimi klasių klasifikavimo kokybės įverčiai.</p> <p>2. Spaudžiama kortelė „Pirma klasė“.</p> <p>3. Spaudžiama kortelė „Antra klasė“.</p> <p>4. Spaudžiama kortelė „Trečia klasė“.</p> <p>5. Spaudžiama kortelė „Ketvirta klasė“.</p> <p>6. Spaudžiama kortelė „Penkta klasė“.</p> <p>7. Spaudžiama kortelė „Šešta klasė“.</p> <p>8. Spaudžiamas mygtukas [Atgal].</p>	<p>1. Atidaromas hierarchinio metodo kokybės įverčių peržiūros langas ir pateikiami aptikimo kokybės įverčiai laukuose „F1“, „Tikslumas“, „Jautrumas“, „PPV“.</p> <p>2. Pateikiami aptikimo kokybės įverčiai pirmai klasei laukuose „F1“, „Tikslumas“, „Jautrumas“, „PPV“.</p> <p>3. Pateikiami aptikimo kokybės įverčiai antrai klasei laukuose „F1“, „Tikslumas“, „Jautrumas“, „PPV“.</p> <p>4. Pateikiami aptikimo kokybės įverčiai trečiai klasei laukuose „F1“, „Tikslumas“, „Jautrumas“, „PPV“.</p> <p>5. Pateikiami aptikimo kokybės įverčiai ketvirtai klasei laukuose „F1“, „Tikslumas“, „Jautrumas“, „PPV“.</p> <p>6. Pateikiami aptikimo kokybės įverčiai penktai klasei laukuose „F1“, „Tikslumas“, „Jautrumas“, „PPV“.</p> <p>7. Pateikiami aptikimo kokybės įverčiai šeštai klasei laukuose „F1“, „Tikslumas“, „Jautrumas“, „PPV“.</p> <p>8. Sugrįžtama į pagrindinį sistemos langą.</p>	Sėkminga

5. Eksperimentinis defektų aptikimo metodų tyrimas

Eksperimentiniu defektų aptikimo metodų tyrimu, tikrinama kokių tikslumu yra aptinkamas defektas kiekvienu metodu. Pateikiamas eksperimento planas, rezultatai, kokybės įvertinimas ir rekomendacijos.

5.1. Eksperimento planas

Eksperimentas atliekamas su dalimi „DAGM“ duomenų bazės vaizdų, kurie nebuvo naudojami neuroninio tinklo mokymams. „DAGM“ duomenų bazės vaizdai iš šešių klasių yra suskirstomi grupėmis, pagal kurias atliekamas defektų aptikimo eksperimentas. Sudaromos vaizdų grupės:

1. 60 vaizdų, kuriuose yra 10 vaizdų iš kiekvienos „DAGM“ vaizdų klasės. Iš kiekvienos vaizdų klasės yra pusė vaizdų su defektu;
2. 60 vaizdų, kuriuose yra 10 vaizdų iš kiekvienos „DAGM“ vaizdų klasės. Visi vaizdai yra be defekto;
3. 60 vaizdų, kuriuose yra 10 vaizdų iš kiekvienos „DAGM“ vaizdų klasės. Visi vaizdai yra su defektu;

Atlikus eksperimentinių duomenų paruošimą yra atliekamas defektų aptikimas kiekvienam metodui su kiekviena vaizdo grupe. Po defektų aptikimo su abiem metodais yra vertinami gaunami rezultatai.

5.2. Eksperimento rezultatai

Kiekvienai sudarytai vaizdo grupei pateikiame eksperimento rezultatus ir jų apibendrinimą. Eksperimentai numeruojami atitinkamai pagal sudarytas vaizdų grupes. Eksperimento rezultatai vertinami pagal kriterijus:

1. Aptikimo laiką;
2. Teisingai aptiktų vaizdų su defektais kiekį;
3. Klaidingai aptiktų vaizdų su defektais kiekį;
4. Neaptiktų vaizdų su defektu kiekį.


Pirmas eksperimentas

Atliktas eksperimentas su vaizdais, kuriuose yra vienodas kiekis vaizdų iš kiekvienos klasės ir atitinkamai vienodai vaizdų su defektu ir be defekto. Atliekant defektų aptikimą hierarchiniu metodu pasitaiko atveju, kai vaizdai nėra priskiriami teisingai vaizdo klasei. Tokiu atveju šie vaizdai yra skaičiuojami prie tų, kuriems nėra aptinkamas defektas. Pirmo eksperimento rezultatai pateikiami lentelėje (žr. 5.1 lentelė).

5.1 lentelė Pirmo eksperimento rezultatai


	Klasikinis metodas	Hierarchinis metodas
Aptikimo laikas	19,79 s.	310,65 s.
Teisingai aptikti defektai	30	16
Klaidingai aptikti defektai	0	2
Neaptikti defektai / neaptikta vaizdo klasė	0	28

Pagal pirmu eksperimentu gautus rezultatus galima pastebėti, kad klasikiniu metodu yra aptinkami visi vaizdai su defektu. Hierarchiniu metodu aptinkama tik pusę visų defektų. Gautiems rezultatams daro įtaką tai, kad 28 vaizdams nėra randama vaizdo klasė ir nėra atliekamas defekto aptikimas. Taip pat hierarchiniu metodu dviem vaizdams yra klaidingai aptinkamas vaizdas (žr. 5.1 pav., 5.2 pav.).



5.1 pav. Pirmu eksperimentu klaidingai aptiktas defektas hierarchiniu metodu 1

Aptiktas defektas paviršiaus vaizde ir nustatytas defekto dydis 22 pikseliai. Defektas yra pažymimas vaizde.



5.2 pav. Pirmu eksperimentu klaidingai aptiktas defektas hierarchiniu metodu 2

Pagal rezultatus aukščiau pateikiama vaizde yra aptinkamas defektas, nors jo pažymėto vaizde nesimato. Defekto dydis yra nustatytas du pikseliai, dėl šios priežasties vaizde nesimato pažymėto defekto. Abiem pateiktais atvejais hierarchinis metodas aptinka defektą vaizdo paviršiuje, nors klasikiniu metodu defektas nėra aptinkamas. Eksperimento metu sukurta metodų palyginimo ataskaita (žr. 3 priede).


Antras eksperimentas

Atliktas eksperimentas su vaizdais, kuriuose vienodas kiekis vaizdų iš kiekvienos vaizdų klasės ir visi vaizdai yra be defekto. Rezultatai pateikiami lentelėje (žr. 5.2 lentelė).


5.2 lentelė Antro eksperimento rezultatai

	Klasikinis metodas	Hierarchinis metodas
Aptikimo laikas	19,41 s.	313,12 s.
Teisingai aptikti defektai	0	0
Klaidingai aptikti defektai	2	0
Neaptikti defektai / neaptikta vaizdo klasė	0	27

Kadangi defektų nėra vaizduose, todėl yra nustatoma, kad teisingai aptikta nulis defektų abiem metodams. Klasikiniu metodu aptikti du defektai (žr. 5.3 pav., 5.4 pav.).



5.3 pav. Antru eksperimentu klaidingai aptiktas defektas klasikiniu metodu 1



5.4 pav. Antru eksperimentu klaidingai aptiktas defektas klasikiniu metodu 2

Abiem aukščiau pateikiamiems vaizdams yra aptinkamas defektas, tačiau jo dydis yra nedidelis, todėl vaizduose nėra matomas pažymėjimas. Nurodytais atvejais neuroninis tinklas vaizdo paviršių priskyre defektui.

Pastebima hierarchiniu metodo problema, kad 27-iems vaizdams yra nenustatoma vaizdų klasė ir dėl šios priežasties nėra atliekamas defekto aptikimas. Vertinant eksperimento rezultatus matoma, kad klasikinis metodas yra greitesnis ir tikslesnis, nes klaidingai aptinka tik du vaizdus, kai hierarchinis metodas beveik pusės vaizdų defektų netikrina. Defektų aptikimo metodų palyginimui sukurta .pdf formato ataskaita, kurios ekranvaizdžiai pateikiami priede (žr. 4 priede).


Trečias eksperimentas

Trečiam eksperimentui yra pasirinkti vaizdai, kurie visi yra su defektu. Vaizdų kiekis yra vienodas iš kiekvienos klasės (žr. 5.3 lentelė).

5.3 lentelė Trečio eksperimento rezultatai


	Klasikinis metodas	Hierarchinis metodas
Aptikimo laikas	19,53 s.	329,57 s.
Teisingai aptikti defektai	59	35
Klaidingai aptikti defektai	0	0
Neaptikti defektai / neaptikta vaizdo klasė	1	25

Eksperimente naudojami visi vaizdai su defektais, todėl nėra klaidingai aptinkamų defektų. Tačiau šiuo atveju svarbu, koks kiekis defektų yra neaptinkama. Pagal klasikinį metodą galima pastebėti, kad neaptinkamas yra tik vienas vaizdas su defektu. Pateikiame klasikiniu metodu neaptikto defekto vaizdą (žr. 5.5 pav.).



5.5 pav. Trečiu eksperimentu neaptiktas defektas klasikiniu metodu

Iš pateikto vaizdo galima pastebėti defektą, tačiau klasikiniu metodu neuroninis tinklas jo neaptiko. Tačiau to paties vaizdo defektas yra aptiktas hierarchiniu metodu (žr. 5.6 pav.).



5.6 pav. Trečiu eksperimentu aptiktas defektas hierarchiniu metodu

Vertinant viso eksperimento rezultatus yra pastebima ta pati problema dėl blogo vaizdų klasės aptikimo hierarchiniame metode. Visa eksperimento metodų palyginimo ataskaita yra pateikiama priede (žr. 5 priede).

5.3. Sprendimo veikimo ir savybių analizė

Atlikti trys eksperimentai, kurių metu atliktas klasikinio ir hierarchinio metodų palyginimas. Lyginant metodus atsižvelgta į teisingai aptinkamus, klaidingai aptinkamus, neaptinkamus defektus ir aptikimo laiką.

Teisingai aptiktų defektų didesnis kiekis yra klasikiniu metodu, nes šiuo metodu yra patikrinami visi vaizdų kataloge esantys vaizdai. Hierarchiniu metodu didelė dalis vaizdų yra netikrinama, dėl neatpažįstamos vaizdo klasės. Klaidingai aptinkamų vaizdų kiekis yra vienodas abiem metodais, tačiau skirtingų eksperimentų metu. Daugiausiai neaptinkamų defektų pasitaiko, kai aptikimui yra naudojamas hierarchinis metodas. Hierarchinis metodas klaidingai arba iš viso neranda vaizdų klasės, dėl ko nėra atliekamas defektų aptikimas. Visų eksperimentų klasikiniu metodu neaptinkamas tik vienas defektas.

Vertinant defektų aptikimo laiką galima pastebėti, kad hierarchiniu metodu defektų aptikimas yra ilgesnis. Klasikiniu metodu defektai aptinkami apie penkiolika kartų greičiau. Toks ilgas hierarchinio metodo aptikimas yra dėl to, kad vienas vaizdas nuosekliai yra paduodamas į du neuroninius tinklus norint gauti rezultatą.

Pagal eksperimentui nustatytus kokybės kriterijus pastebima, kad klasikinis metodas aptinka defektą greičiau ir tiksliau. Tačiau vertinant hierarchinį metodą verta pastebėti, kad klaidingai aptinkamų defektų nėra daug. Šio metodo blogas aptikimas yra gaunamas nesuklasifikuojant vaizdų klasės, dėl ko nėra atliekamas defekto tikrinimas. Tokį rezultatą lemia „Inception-v3“ neuroninis tinklas, kurio mokymo tikslumas 0,75 ir ne visos vaizdų klasės klasifikuojamos teisingai.

5.4. Sprendimo taikymo rekomendacijos

Klasikinio ir hierarchinio defektų aptikimo metodai aptinka defektus, tačiau jų tikslumas ir greitis skiriasi. Gamyboje, kurioje yra svarbi gaminamos produkcijos kokybė ir greitis, tinkamiausias būtų klasikinio defektų aptikimo metodas. Klasikiniu metodu defektai aptinkami keliolika kartų greičiau nei hierarchiniu metodu, kas sudaro privalumą tokį metodą taikyti gamyboje. Taip pat atsižvelgiant į teisingai aptinkamų defektų kiekį, klasikinio metodo naudojimas yra patikimesnis, norint surasti defektą.

Išvados

1. Atlikus „DAGM“ defektų duomenų bazės analizę, buvo nustatyta, kad nėra tirtas defektų aptikimo metodas, kuris aptiktų defektus iš skirtingų paviršių, kai nėra žinoma vaizdo klasė prieš aptinkant defektą.
2. Konvoliuciniai neuroniniai tinklai „MobileNet“ ir „Inception-v3“ gali būti naudojami tik klasifikavimo uždaviniui spręsti, todėl šie tinklai tinkami atlikti vaizdų klasių klasifikavimą. Defektų aptikimui tinkamiausias yra „U-Net“ neuroninis tinklas, kuris gali aptikti reikiamus objektus pikselio lygyje.
3. Vaizdų klasių klasifikavimui tiksliausias rezultatus pateikia „Inception-v3“ neuroninis tinklas su imtimi 60. Aukščiausias defektų aptikimo kokybės įvertis gaunamas pirmos vaizdo klasės defektų aptikimui su „U-Net“ neuroninio tinklo struktūra „Unet4_res_aspp“, kai neuroninis tinklas yra mokytas aptikti defektą tik konkrečioje klasėje.
4. Apjungiant išmokytą „MobileNet“ klasifikatorių ir „U-Net“ neuroninį tinklą, sukurti defektų aptikimo metodai, kurie naudojami realizuotoje skirtingų paviršių defektų aptikimo sistemoje.
5. Atlikus tris eksperimentinius tyrimus nustatyta, kad greičiausias ir tiksliausias defektų aptikimo metodas yra klasikinis. Hierarchinio defektų aptikimo metodo mažą tikslumą lemia tai, kad pateikiamo vaizdo klasė nėra teisingai atpažįstama.
6. „U-Net“ neuroninio tinklo struktūra „UNet4_res_aspp“ gali ne tik atpažinti individualios klasės defektus, bet aptikti visus galimus defektus vienu metu, nepriklausomai nuo vaizdų klasės.

Literatūros sąrašas

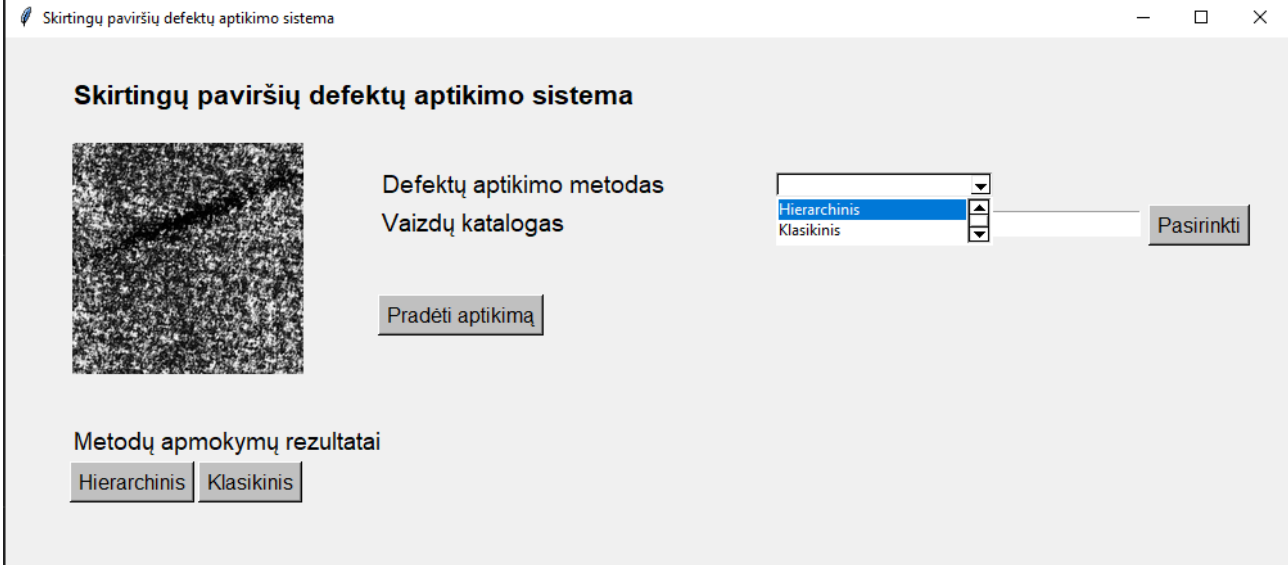
- [1] B. Staar, M. Lütjen ir M. Freitag, „Anomaly detection with convolutional neural networks for industrial surface inspection,“ *12th CIRP Conference on Intelligent Computation in Manufacturing Engineering, CIRP ICME '18*, 2018.
- [2] D. Racki, D. Tomazevic ir D. S. Sensum, „The effect of different CNN configurations on textured-surface defect segmentation and detection performance,“ 2018.
- [3] F. S. Panchal ir M. Panchal, „Review on Methods of Selecting Number of Hidden Nodes in Artificial Neural Network,“ *International Journal of Computer Science and Mobile Computing*, t. 3, nr. 11, 2014.
- [4] C. E. Nwankpa, W. Ijomah, A. Gachagan ir S. Marshall, „Activation Functions: Comparison of Trends in Practice and Research for Deep Learning,“ 2018.
- [5] P. Sibi, S. A. Jones ir P. Siddarth, „Analysis of Different Activation Functions Using Back Propagation Neural Networks,“ *Journal of Theoretical and Applied Information Technology*, t. 47, 2013.
- [6] Y. LeCun, K. Kavukcuoglu ir C. Farabet, „Convolutional Networks and Applications in Vision,“ *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, 2010.
- [7] A. Rakhlin, A. Davydow ir S. Nikolenko, „Land Cover Classification from Satellite Imagery With U-Net and Lovasz-Softmax Loss,“ 2018.
- [8] R. Girshick, „Fast R-CNN,“ *The IEEE International Conference on Computer Vision (ICCV)*, 2015.
- [9] E. Rezende, G. Ruppert, T. Carvalho, A. Theophilo ir A. Ramos, „Malicious Software Classification using VGG16 Deep Neural Network’s Bottleneck Features,“ *Information Technology-New Generations*, pp. 51-59, 2018.
- [10] M. Z. Alom, T. M. Taha, C. Yakopcic, S. Westberg, P. Sidike, M. S. Nasrin, M. Hasan, B. C. V. Essen, A. A. S. Awwal ir V. K. Asari, „A State-of-the-Art Survey on Deep Learning Theory,“ *Electronics*, 2019.
- [11] M. Ferguson, R. Ak, Y. T. T. Lee ir K. H. Law, „Automatic Localization of Casting Defects with Convolutional Neural Networks,“ įtraukta *2017 IEEE International Conference on Big Data (BigData 2017), 2nd Symposium on Data Analytics*, Boston, 2017.
- [12] A. Michele, V. Colin ir D. D. Santika, „MobileNet Convolution Neural Networks and Support Vector Machines for Palmprint Recognition,“ *ScienceDirect*, 2019.
- [13] J. Bankar ir N. R. Gavai, „Convolutional Neural Network based Inception v3 Model for Animal Classification,“ *International Journal of Advanced Research in Computer and Communication Engineering*, t. 7, nr. 5, 2018.
- [14] R. Augustauskas ir A. Lipnickas, „Improved Pixel-level Pavement Defects Segmentation Using Deep Auto-Encoder,“ *Sensors*, 2020.

- [15] H. He, D. Yang, S. Wang, S. Wang ir Y. Li, „Road Extraction by Using Atrous Spatial Pyramid Pooling Integrated Encoder-Decoder Network and Structural Similarity Loss,“ *Remote Sensing*, t. 11, nr. 9, 2019.
- [16] K. Thahira, J. Vanisequeira, Sameema and ir Z. Ansari, „Performance Evaluation of Neural Network Based Pattern Classification,“ *International Journal of Emerging Technologies and Applications in Engineering, Technology and Sciences*, nr. 0974-3588, 2014.
- [17] D. Weimer, H. Thamer ir B. Scholz-Reiter, „Learning defect classifiers for textured surfaces using neural networks and statistical feature representations,“ *Forty Sixth CIRP Conference on Manufacturing Systems 2013*, t. 7, pp. 347-352, 2013.
- [18] M. S. Minhas ir J. Zelek, „Semi-supervised Anomaly Detection using AutoEncoders,“ *JCVIS*, t. 5, 2020.

Priedai

1 priedas. Sistemos testavimo rezultatai

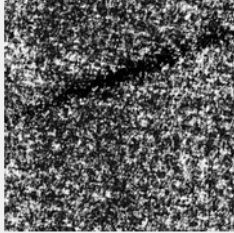
TS1. Defektų aptikimo metodų pasirinkimas

Nr.	Turimo gauti rezultato numeris	Rezultatas
1.1.	1.	 <p>Skirtingų paviršių defektų aptikimo sistema</p> <p>Defektų aptikimo metodas Vaizdų katalogas</p> <p>Pradėti aptikimą</p> <p>Metodų apmokymų rezultatai</p> <p>Hierarchinis Klasikinis</p>

2.

Skirtingų paviršių defektų aptikimo sistema

Skirtingų paviršių defektų aptikimo sistema



Defektų aptikimo metodas:

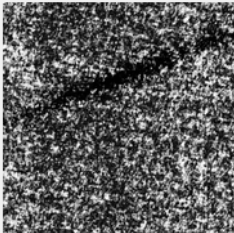
Vaizdų katalogas:

Metodų apmokymų rezultatai

3.

Skirtingų paviršių defektų aptikimo sistema

Skirtingų paviršių defektų aptikimo sistema

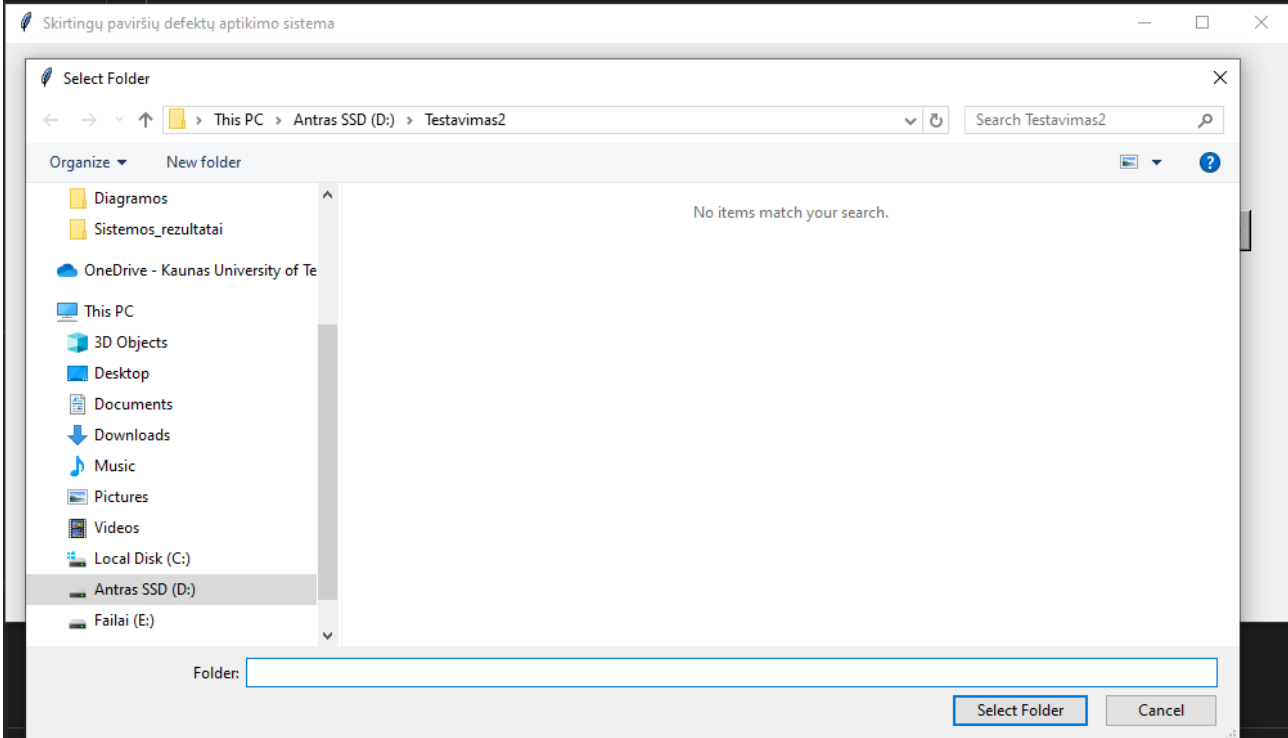


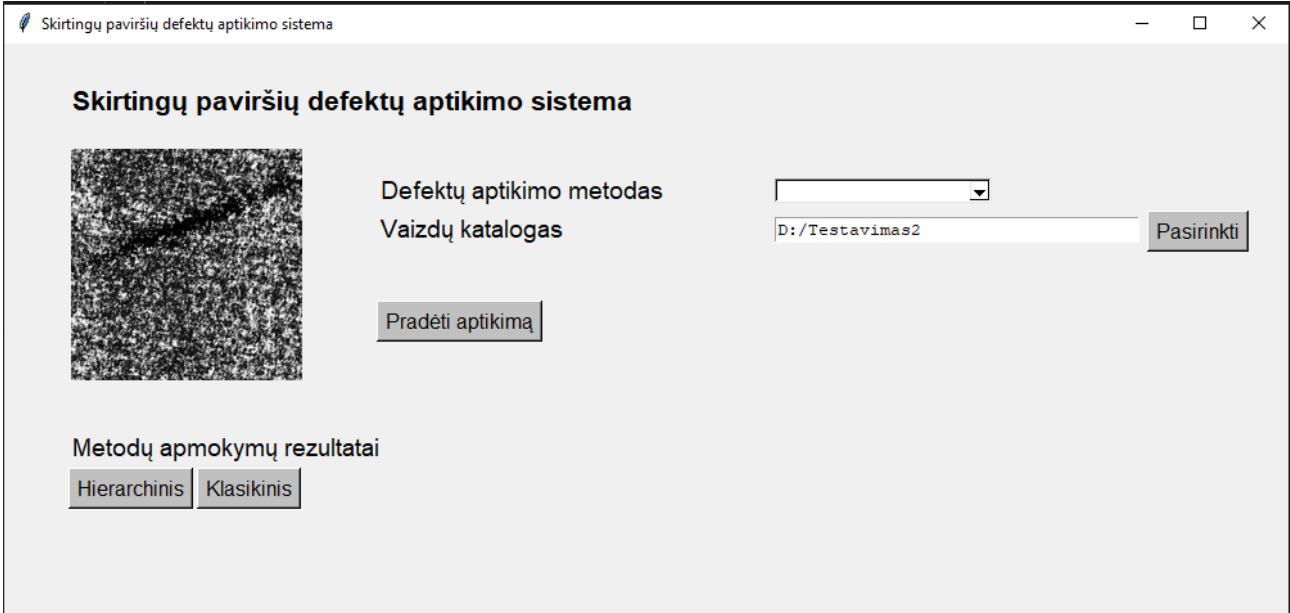
Defektų aptikimo metodas:

Vaizdų katalogas:

Metodų apmokymų rezultatai

TS2. Vaizdų katalogo pasirinkimas

Nr.	Turimo gauti rezultato numeris	Rezultatas
2.1.	1.	 <p>The screenshot shows a Windows File Explorer window titled "Skirtingų paviršių defektų aptikimo sistema". A "Select Folder" dialog box is open, displaying the path "This PC > Antras SSD (D:) > Testavimas2". The search bar contains "Testavimas2" and the message "No items match your search." is shown. The left sidebar lists various locations, with "Antras SSD (D:)" selected. The "Folder:" field at the bottom is empty, and the "Select Folder" button is highlighted.</p>

2.	
----	--

TS3. Defektų aptikimas

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

3.1.	1.	
------	----	--

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

3.2.	1.	
------	----	--

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

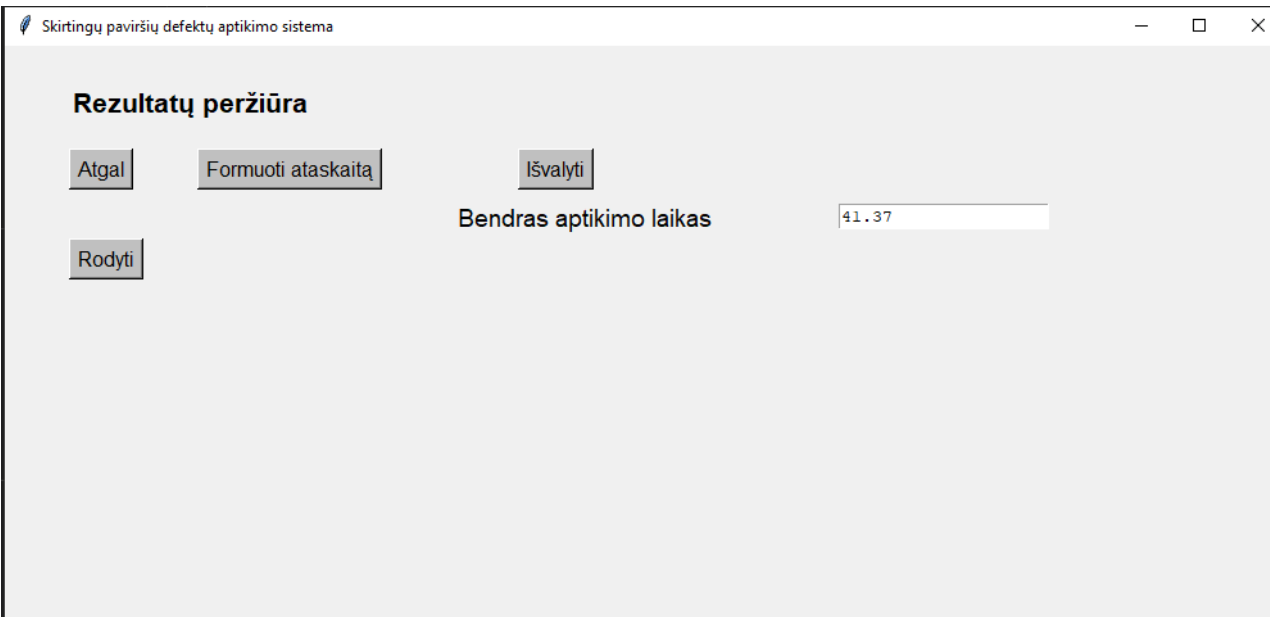
3.3.	1.	
------	----	--

TS4. Rezultatų peržiūra

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

4.1.

1.

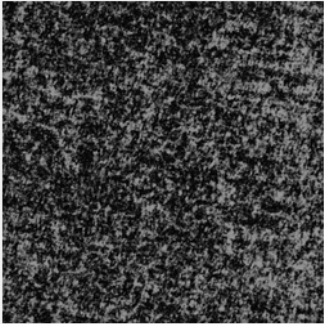


2.

Skirtingų paviršių defektų aptikimo sistema

Rezultatų peržiūra

Atgal Formuoti ataskaitą Išvalyti



Bendras aptikimo laikas 41.37

Yra defektas Ne

Defekto dydis 0

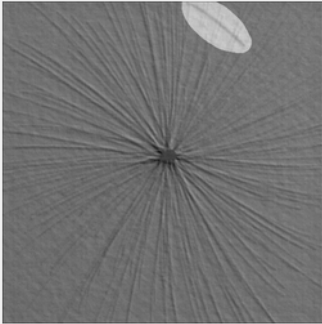
Ankstesnis Sekantis

3.

Skirtingų paviršių defektų aptikimo sistema

Rezultatų peržiūra

Atgal Formuoti ataskaitą Išvalyti



Bendras aptikimo laikas 41.37

Yra defektas Taip

Defekto dydis 83

Ankstesnis Sekantis

4.		
----	--	--

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

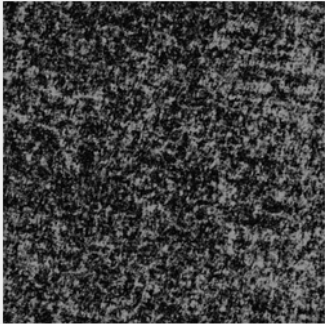
4.2.

1.

Skirtingų paviršių defektų aptikimo sistema

Rezultatų peržiūra

Atgal Formuoti ataskaitą Išvalyti



Bendras aptikimo laikas: 41.37


Yra defektas: Ne

Defekto dydis: 0

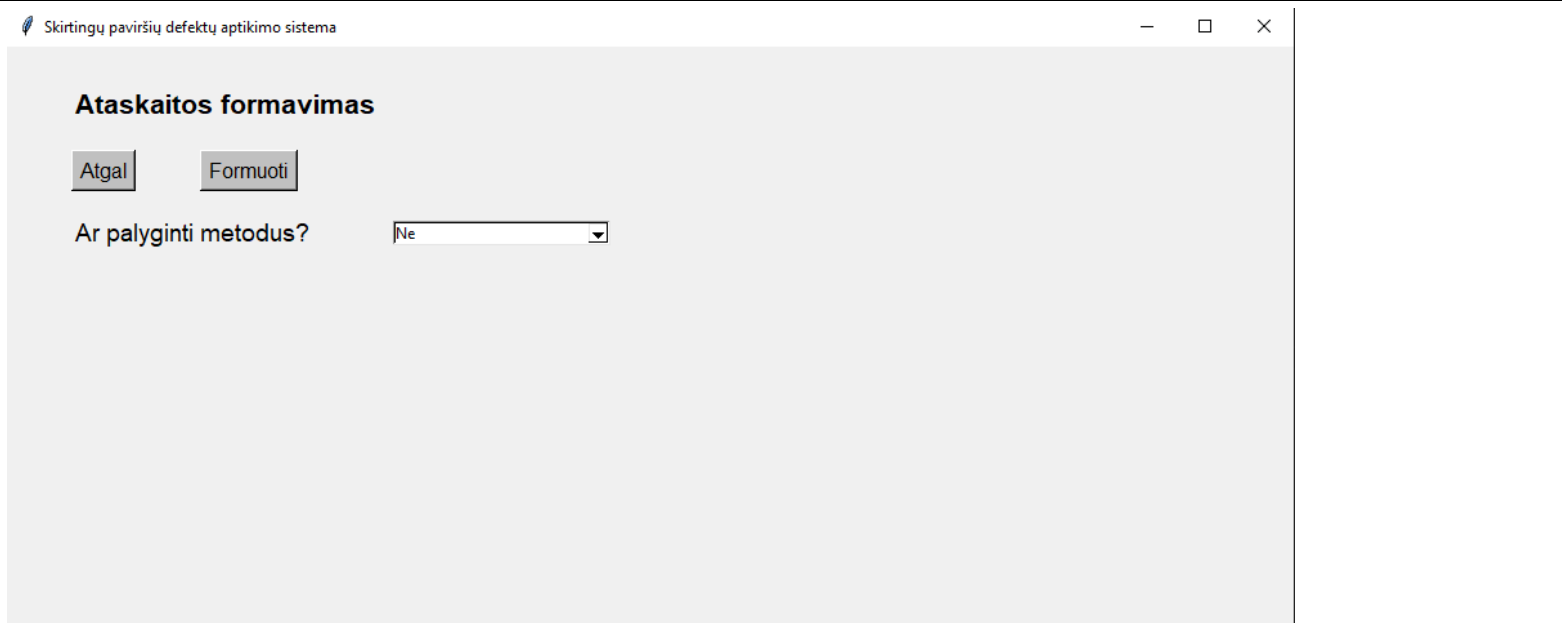
Ankstesnis Sekantis

	2.	
--	----	--

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

4.3.	1.	
------	----	--

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

4.4.	1.	
------	----	--

TS5. Ataskaitos formavimas

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

5.1.	1.	
------	----	--

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

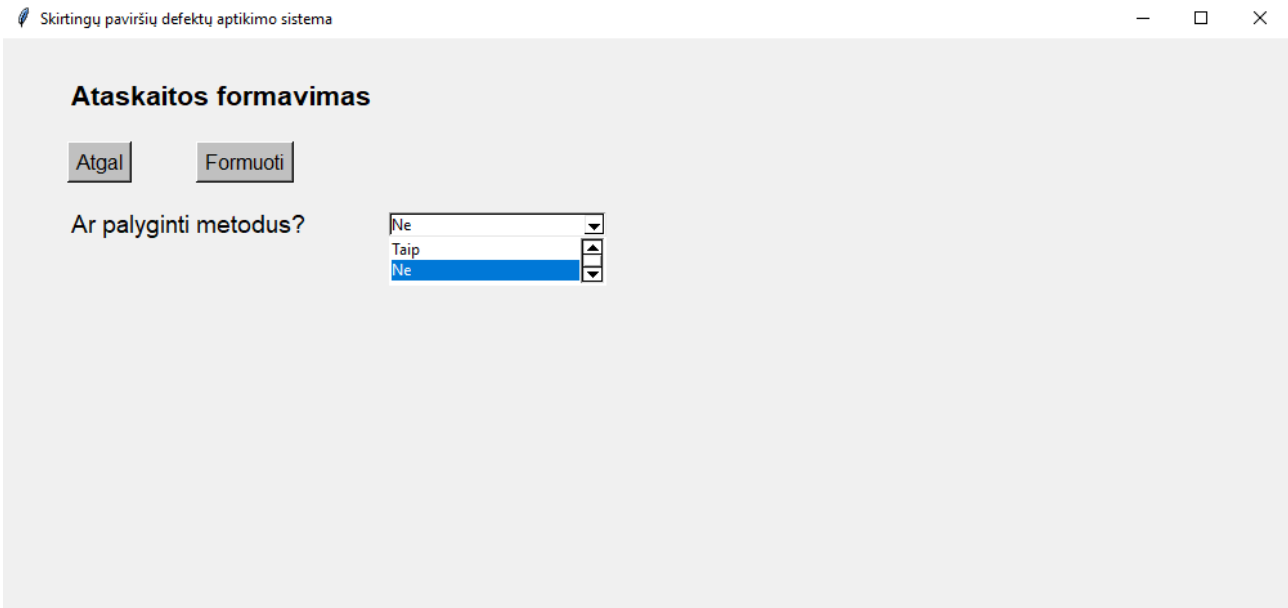
5.2.

1.

Skirtingų paviršių defektų aptikimo sistema

Ataskaitos formavimas

Ar palyginti metodus?

	2.	 <p>Skirtingų paviršių defektų aptikimo sistema</p> <p>Ataskaitos formavimas</p> <p>Atgal Formuoti</p> <p>Ar palyginti metodus? Ne Taip Ne</p>
--	----	---

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

5.3.


1.

Klasikinis defektų aptikimo metodas

Defektų aptikimo laikas: 10.3

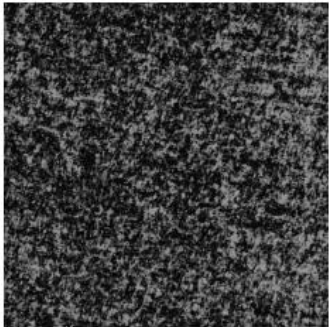
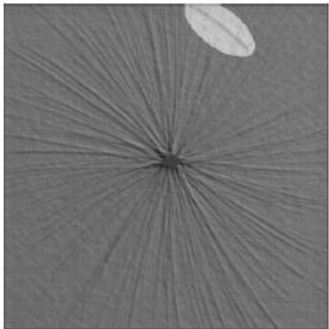


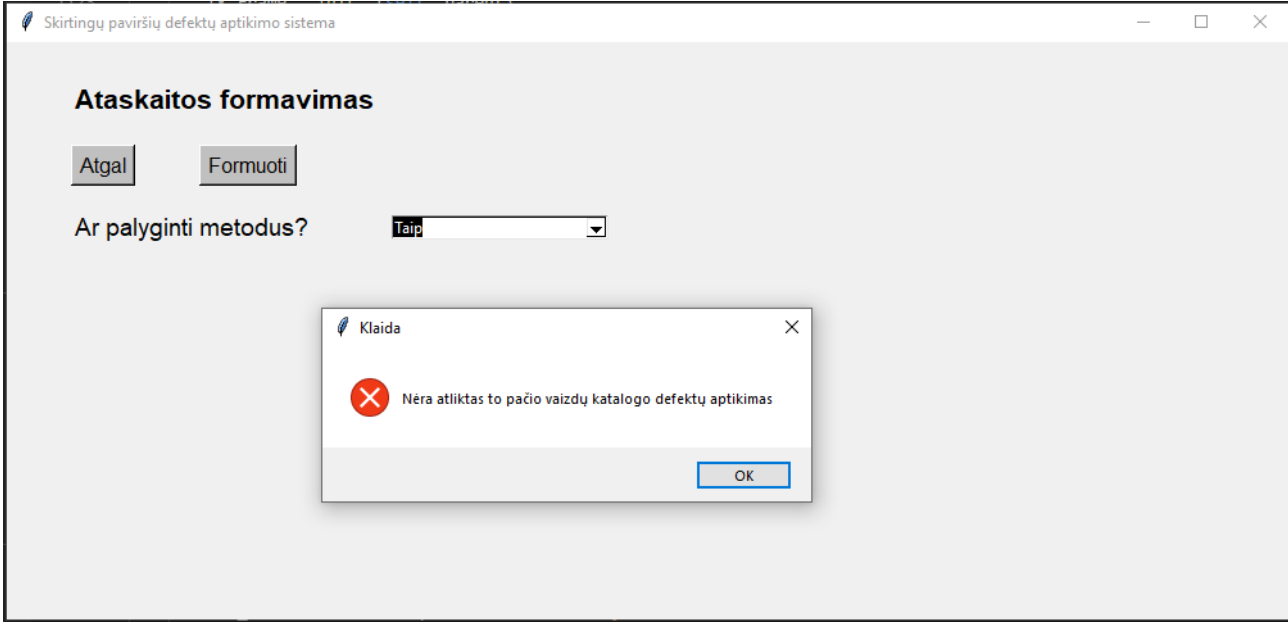
Nėra defekto



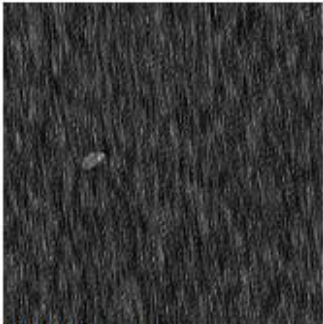
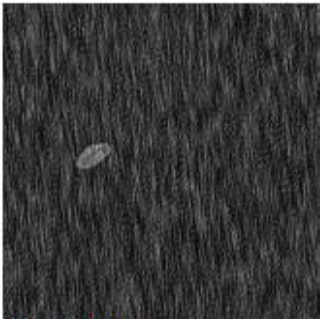
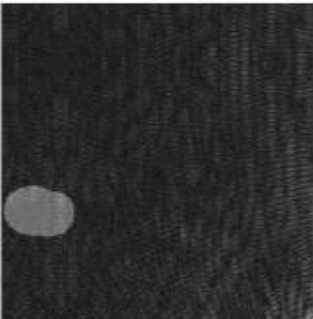
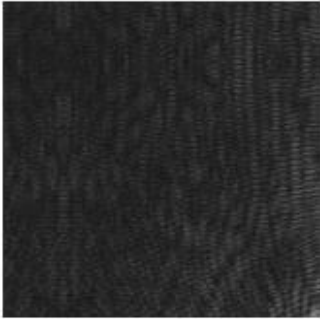
Yra defektas

Defekto dydis pikseliais: 83

Nr.	Turimo gauti rezultato numeris	Rezultatas
5.4.	1.	<p data-bbox="618 379 1424 432">Hierarchinis defektų aptikimo metodas</p> <p data-bbox="618 440 922 472">Defektų aptikimo laikas:41.2</p> <div data-bbox="618 485 945 812"></div> <p data-bbox="1048 595 1187 619">Nėra defekto</p> <div data-bbox="618 917 945 1246"></div> <p data-bbox="1048 1031 1182 1054">Yra defektas</p> <p data-bbox="1048 1074 1339 1098">Defekto dydis pikseliais: 83</p>

Nr.	Turimo gauti rezultato numeris	Rezultatas
5.5.	1.	

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

5.6.	1.	<h3 style="text-align: center;">Klasikinio ir hierarchinio metodų palyginimas</h3> <p style="text-align: center;">Defektų aptikimo laikas klasikiniu metodu:19.53 Defektų aptikimo laikas hierarchiniu metodu:329.57</p> <div style="display: flex; justify-content: space-around;"> <div style="text-align: center;">  <p>Yra defektas Defekto dydis pikseliais: 32</p> </div> <div style="text-align: center;">  <p>Yra defektas Defekto dydis pikseliais: 44</p> </div> </div> <div style="display: flex; justify-content: space-around; margin-top: 20px;"> <div style="text-align: center;">  <p>Yra defektas Defekto dydis pikseliais: 88</p> </div> <div style="text-align: center;">  <p>Nėra defekto</p> </div> </div>
------	----	--

TS6. Klasikinio metodo kokybės įverčių peržiūra

Nr.	Turimo gauti rezultato numeris	Rezultatas
6.1.	1.	

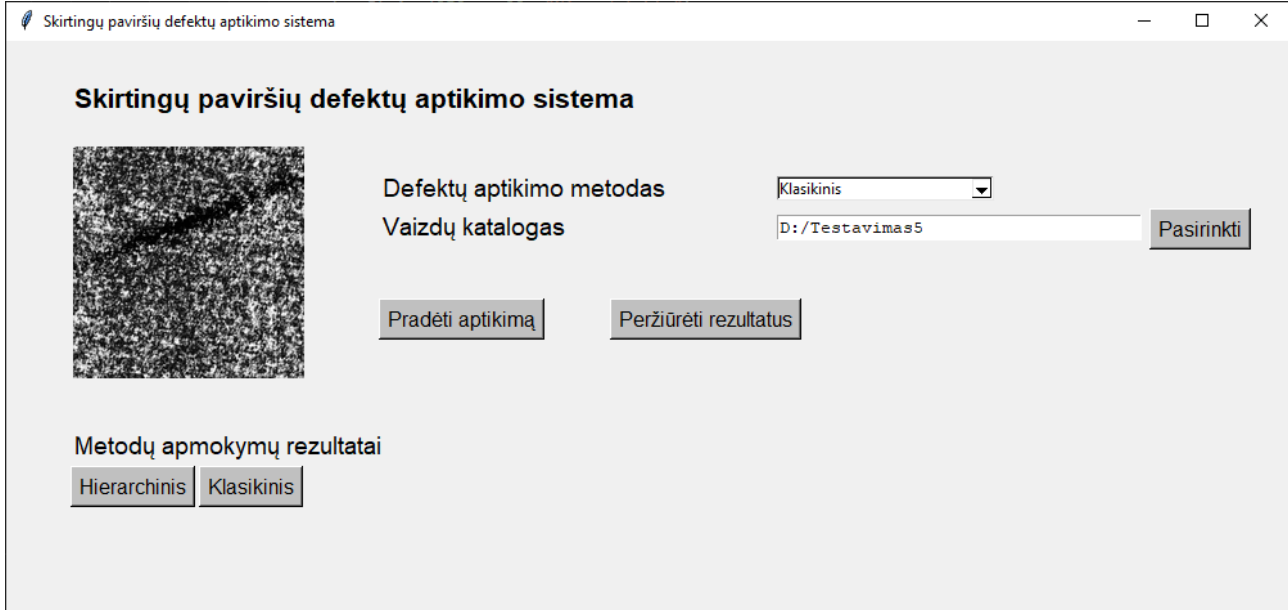
2.

Skirtingų paviršių defektų aptikimo sistema

Klasikinio defektų aptikimo metodo kokybės įverčiai

Atgal

F1	<input type="text" value="0.9841"/>	Jautrumas	<input type="text" value="0.9882"/>
Tikslumas	<input type="text" value="0.9993"/>	PPV	<input type="text" value="0.9851"/>

3.	
----	--

TS7. Hierarchinio metodo kokybės įverčių peržiūra

Nr.	Turimo gauti rezultato numeris	Rezultatas
-----	--------------------------------	------------

7.1.

1.

Skirtingų paviršių defektų aptikimo sistema

Hierarchinio defektų aptikimo metodo kokybės įverčiai

Atgal

Klasių klasifikavimas Pirma klasė Antra klasė Trečia klasė Ketvirta klasė Penkta klasė Šešta klasė

F1	0.7	Jautrumas	0.7433
Tikslumas	0.75	PPV	0.8633

2.

Skirtingų paviršių defektų aptikimo sistema

Hierarchinio defektų aptikimo metodo kokybės įverčiai

Atgal

Klasių klasifikavimas: Pirmą klasę Antra klasė Trečia klasė Ketvirta klasė Penkta klasė Šešta klasė

F1	0.9855	Jautrumas	0.9895
Tikslumas	0.999	PPV	0.9859

3.

Skirtingų paviršių defektų aptikimo sistema

Hierarchinio defektų aptikimo metodo kokybės įverčiai

Atgal

Klasių klasifikavimas Pirma klasė Antra klasė Trečia klasė Ketvirta klasė Penkta klasė Šešta klasė

F1	0.9789	Jautrumas	0.9815
Tikslumas	0.9996	PPV	0.9813

4.

Skirtingų paviršių defektų aptikimo sistema

Hierarchinio defektų aptikimo metodo kokybės įverčiai

Atgal

Klasių klasifikavimas Pirma klasė Antra klasė Trečia klasė Ketvirta klasė Penkta klasė Šešta klasė

F1	0.988	Jautrumas	0.9899
Tikslumas	0.9996	PPV	0.988

5.

Skirtingų paviršių defektų aptikimo sistema

Hierarchinio defektų aptikimo metodo kokybės įverčiai

Atgal

Klasių klasifikavimas | Pirma klasė | Antra klasė | Trečia klasė | **Ketvirta klasė** | Penka klasė | Šešta klasė

F1	<input type="text" value="0.9799"/>	Jautrumas	<input type="text" value="0.9861"/>
Tikslumas	<input type="text" value="0.9994"/>	PPV	<input type="text" value="0.9844"/>

6.

Skirtingų paviršių defektų aptikimo sistema

Hierarchinio defektų aptikimo metodo kokybės įverčiai

Atgal

Klasių klasifikavimas Pirma klasė Antra klasė Trečia klasė Ketvirta klasė Penka klasė Šešta klasė

F1	0.9909	Jautrumas	0.9934
Tikslumas	0.9998	PPV	0.9922

7.

Skirtingų paviršių defektų aptikimo sistema

Hierarchinio defektų aptikimo metodo kokybės įverčiai

Atgal


Klasių klasifikavimas Pirma klasė Antra klasė Trečia klasė Ketvirta klasė Penka klasė Šešta klasė

F1	0.9963	Jautrumas	0.9955
Tikslumas	0.9994	PPV	0.9971

8.

Skirtingų paviršių defektų aptikimo sistema

Skirtingų paviršių defektų aptikimo sistema



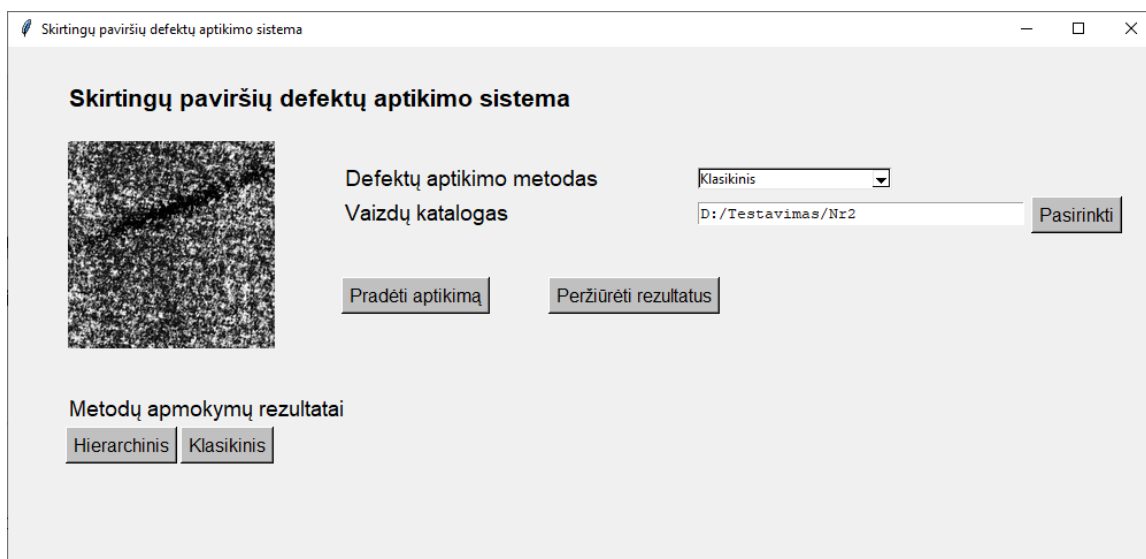
Defektų aptikimo metodas

Vaizdų katalogas

Metodų apmokymų rezultatai

2 priedas. Naudotojo vadovas

Skirtingų paviršių defektų aptikimo sistemos pagrindinis langas



Skirtingų paviršių defektų aptikimo sistemos pagrindinis langas

Lango aprašymas

Langas skirtas defektų aptikimo metodo pasirinkimui, vaizdų katalogo pasirinkimui, defektų aptikimo inicijavimui, rezultatų peržiūros lango atidarymui, klasikinio ir hierarchinio metodo kokybės įverčių peržiūros lango atidarymui.

Lange rodomų laukų aprašymas

- **Defektų aptikimo metodas** – pasirenkamas laukas, kuriame galima pasirinkti reikšmes „Klasikinis“, „Hierarchinis“. Jeigu yra pasirenkama reikšmė „Klasikinis“, tada yra atliekamas defektų aptikimas klasikiniu metodu. Jeigu yra pasirenkama reikšmė „Hierarchinis“, tada yra atliekamas defektų aptikimas hierarchiniu metodu.
- **Vaizdų katalogas** – laukas, kuriame atvaizduojama pasirinkto vaizdų katalogo vieta kompiuteryje. Pasirinkto katalogo vaizdams atliekamas defektų aptikimas.

Galimi atlikti veiksmai:

1. Pasirinkti defektų aptikimo metodą;
2. Pasirinkti vaizdų katalogą;
3. Inicijuoti defektų aptikimą;
4. Atidaryti rezultatų peržiūros langą;
5. Atidaryti klasikinio metodo kokybės įverčių peržiūros langą;
6. Atidaryti hierarchinio metodo kokybės įverčių peržiūros langą.

1. Pasirinkti defektų aptikimo metodą

Prieš pradėdant:

-

Atlikimo eiga:

1. Išskleisti pasirinkimų sąrašą lauko lauke „Defektų aptikimo metodas“.
2. Pasirinkti defektų aptikimo metodą.

Rezultatai:

Pasirinktas defektų aptikimo metodas.

2. Pasirinkti vaizdų katalogą**Prieš pradedant:**

-

Atlikimo eiga:

1. Paspausti mygtuką [Pasirinkti].
2. Pasirinkti „DAGM“ duomenų bazės tikrinamų vaizdų katalogą iš kompiuteryje esančių duomenų failų.
3. Spausti mygtuką [Pasirinkti].

Rezultatai:

Pasirinktas vaizdų katalogas ir lauke „Vaizdų katalogas“ atvaizduojama pasirinkto vaizdo katalogo vieta kompiuteryje.

3. Inicijuoti defektų aptikimą**Prieš pradedant:**

Pasirinktas defektų aptikimo metodas ir vaizdų katalogas.

Atlikimo eiga:

1. Paspausti mygtuką [Pradėti aptikimą].

Rezultatai:

Atliktas defektų aptikimas pasirinktam vaizdų katalogui pagal pasirinktą defektų aptikimo metodą.

4. Atidaryti rezultatų peržiūros langą**Prieš pradedant:**

Atliktas defektų aptikimas.

Atlikimo eiga:

1. Paspausti mygtuką [Peržiūrėti rezultatus].

Rezultatai:

Atidarytas rezultatų peržiūros langas.

5. Atidaryti klasikinio metodo kokybės įverčių peržiūros langą**Prieš pradedant:**

-

Atlikimo eiga:

1. Paspausti mygtuką [Klasikinis].

Rezultatai:

Atidarytas klasikinio metodo kokybės įverčių peržiūros langas.

6. Atidaryti hierarchinio metodo kokybės įverčių peržiūros langą

Prieš pradedant:

-

Atlikimo eiga:

1. Paspausti mygtuką [Hierarchinis].

Rezultatai:

Atidarytas hierarchinio metodo kokybės įverčių peržiūros langas.

Rezultatų peržiūros langas



Rezultatų peržiūros langas 1



Rezultatų peržiūros langas 2

Lango aprašymas

Langas skirtas peržiūrėti defektų aptikimo rezultatus. Rezultatų peržiūros lange pateikiami visi vaizdai iš pasirinkto vaizdų katalogo.

Lange rodomų laukų aprašymas

- **Bendras aptikimo laikas** – laukas, kuriame atvaizduojamas defektų aptikimo laikas sekundėmis. Atvaizduojamas defektų aptikimo laikas yra bendras, kuris apskaičiuojamas visiems vaizdų kataloge tikrinamiems vaizdams.
- **Yra defektas** – laukas, kuriame atvaizduojama reikšmė „Taip“ arba „Ne“. Jeigu atvaizduojama reikšmė „Taip“, tikrintas vaizdas turi defektą. Jeigu tikrintame vaizde defekto nėra, atvaizduojama reikšmė „Ne“.
- **Defekto dydis** – laukas, kuriame atvaizduojamas defekto dydis pikseliais. Jeigu tikrintame vaizde defekto nėra, atvaizduojama reikšmė „0“.

Galimi atlikti veiksmai:

1. Inicijuoti rezultatų rodymą;
2. Peržiūrėti sekančio vaizdo rezultatą;
3. Peržiūrėti ankstesnio vaizdo rezultatą;
4. Išvalyti rezultatų peržiūros langą;
5. Atidaryti ataskaitos formavimo langą;
6. Grįžti į sistemos pagrindinį langą.

1. Inicijuoti rezultatų rodymą

Prieš pradėdant:

-

Atlikimo eiga:

1. Paspaušti mygtuką [Rodyti].

Rezultatai:

Rodomi defektų aptikimo rezultatai.

2. Peržiūrėti sekančio vaizdo rezultatą**Prieš pradedant:**

Pateikiamas ne paskutinis defektų aptikimo rezultatas.

Atlikimo eiga:

1. Paspausti mygtuką [Sekantis].

Rezultatai:

Rodomas sekantis defektų aptikimo rezultatas.

3. Peržiūrėti ankstesnio vaizdo rezultatą**Prieš pradedant:**

Pateikiamas ne pirmas defektų aptikimo rezultatas.

Atlikimo eiga:

1. Paspausti mygtuką [Ankstesnis].

Rezultatai:

Rodomas ankstesnis defektų aptikimo rezultatas.

4. Išvalyti rezultatų peržiūros langą**Prieš pradedant:**

Atvaizduojami defektų aptikimo rezultatai.

Atlikimo eiga:

1. Paspausti mygtuką [Išvalyti].

Rezultatai:

Neatvaizduojami defektų aptikimo rezultatai.

5. Atidaryti ataskaitos formavimo langą**Prieš pradedant:**

Išvalomi defektų aptikimo rezultatai.

Atlikimo eiga:

1. Paspausti mygtuką [Formuoti ataskaitą].

Rezultatai:

Atidaromas rezultatų peržiūros langas.

6. Grįžti į sistemos pagrindinį langą**Prieš pradedant:**

Išvalomi defektų aptikimo rezultatai.

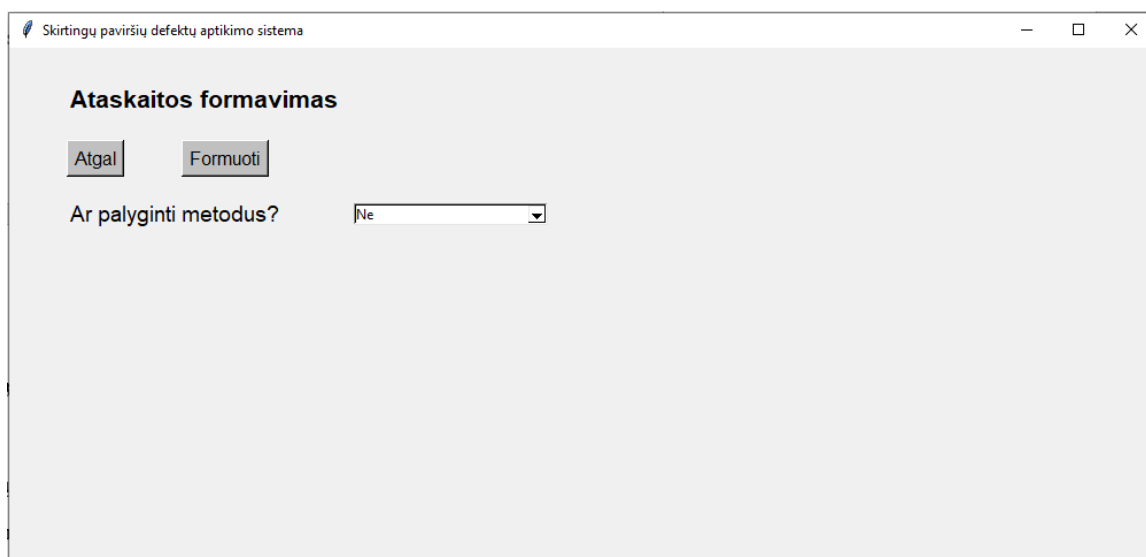
Atlikimo eiga:

1. Paspausti mygtuką [Grįžti].

Rezultatai:

Atidaromas sistemos pagrindinis langas.

Ataskaitos formavimo langas



Ataskaitos formavimo langas

Lango aprašymas

Langas skirtas inicijuoti defektų aptikimo ataskaitos formavimą.

Lange rodomų laukų aprašymas

- **Ar palyginti metodus?** – pasirenkamas laukas, kuriame galima pasirinkti reikšmes „Taip“, „Ne“. Jeigu ataskaita formuojama su pasirinkta reikšme „Ne“, ataskaitoje pateikiami defektų aptikimo rezultatai, kurie gauti paskutinio aptikimo metu. Jeigu ataskaita formuojama su pasirinkta reikšme „Taip“, ataskaitoje pateikiami defektų aptikimo rezultatai, kurie gauti klasikiniu ir hierarchiniu metodu.

Galimi atlikti veiksmai:

1. Formuoti defektų aptikimo ataskaitą.
2. Formuoti defektų aptikimų metodų palyginimo ataskaitą.
3. Grįžti į rezultatų peržiūros langą.

1. Formuoti defektų aptikimo ataskaitą

Prieš pradėdant:

-

Atlikimo eiga:

1. Paspausti mygtuką [Formuoti].

Rezultatai:

Suformuota defektų aptikimo ataskaita.

2. Formuoti defektų aptikimo metodų palyginimo ataskaitą

Prieš pradedant:

Tam pačiam vaizdų katalogui atliktas defektų aptikimas klasikiniu ir hierarchiniu metodu.

Atlikimo eiga:

1. Paspausti mygtuką [Formuoti].

Rezultatai:

Suformuota defektų aptikimo metodų palyginimo ataskaita.

3. Grįžti į rezultatų peržiūros langą

Prieš pradedant:

-

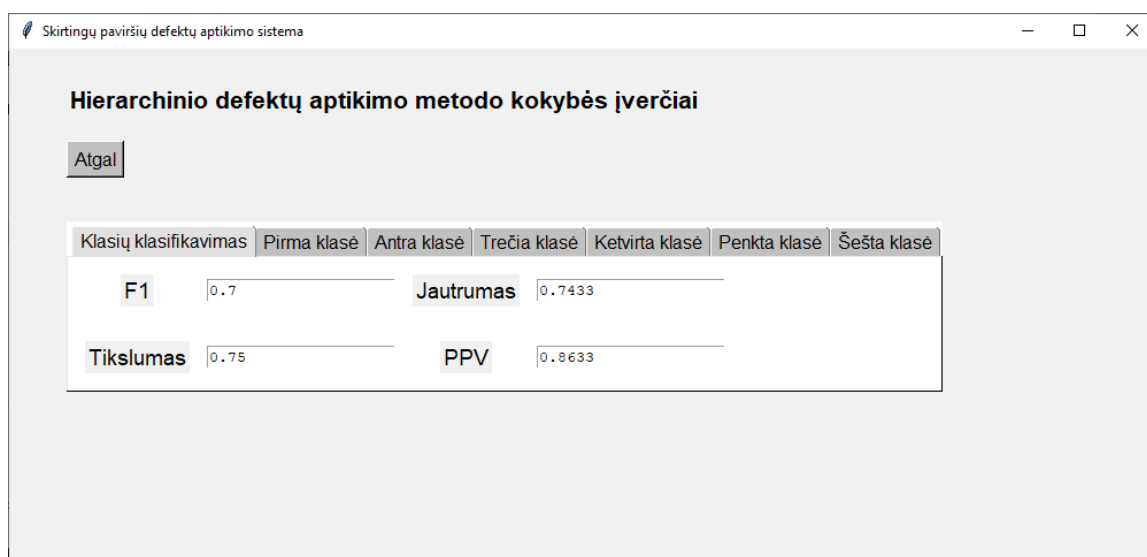
Atlikimo eiga:

1. Paspausti mygtuką [Atgal].

Rezultatai:

Atidaromas rezultatų peržiūros langas.

Hierarchinio metodo kokybės įverčių peržiūros langas



Hierarchinio metodo kokybės įverčių peržiūros langas

Lango aprašymas

Langas skirtas peržiūrėti hierarchinio metodo kokybės įverčius.

Lange rodomų laukų aprašymas

- **F1** – lauke atvaizduojamas neuroninio tinklo mokymo kokybės įvertis *F1*. Kokybės įvertis atvaizduojamas suapvalintas iki trijų skaičių po kablelio.
- **Tikslumas** – lauke atvaizduojamas neuroninio tinklo mokymo kokybės įvertis *tikslumas*. Kokybės įvertis atvaizduojamas suapvalintas iki trijų skaičių po kablelio.
- **Jautrumas** – lauke atvaizduojamas neuroninio tinklo mokymo kokybės įvertis *jautrumas*. Kokybės įvertis atvaizduojamas suapvalintas iki trijų skaičių po kablelio.
- **PPV** – lauke atvaizduojamas neuroninio tinklo mokymo kokybės įvertis *PPV*. Kokybės įvertis atvaizduojamas suapvalintas iki trijų skaičių po kablelio.

Galimi atlikti veiksmai:

1. Peržiūrėti klasių klasifikavimo kokybės įverčius.
2. Peržiūrėti pirmos vaizdo klasės kokybės įverčius.
3. Peržiūrėti antros vaizdo klasės kokybės įverčius.
4. Peržiūrėti trečios vaizdo klasės kokybės įverčius.
5. Peržiūrėti ketvirtos vaizdo klasės kokybės įverčius.
6. Peržiūrėti penktos vaizdo klasės kokybės įverčius.
7. Peržiūrėti šeštos vaizdo klasės kokybės įverčius.
8. Grįžti į sistemos pagrindinį langą.

1. Peržiūrėti klasių klasifikavimo kokybės įverčius

Prieš pradedant:

-

Atlikimo eiga:

1. Atidaryti kortelę „Klasių klasifikavimas“.

Rezultatai:

Atvaizduojami klasių klasifikavimo kokybės įverčiai.

2. Peržiūrėti pirmos vaizdo klasės kokybės įverčius

Prieš pradedant:

-

Atlikimo eiga:

1. Atidaryti kortelę „Pirma klasė“.

Rezultatai:

Atvaizduojami pirmos klasės kokybės įverčiai.

3. Peržiūrėti antros vaizdo klasės kokybės įverčius

Prieš pradedant:

-

Atlikimo eiga:

1. Atidaryti kortelę „Antra klasė“.

Rezultatai:

Atvaizduojami antros klasės kokybės įverčiai.

4. Peržiūrėti trečios vaizdo klasės kokybės įverčius

Prieš pradedant:

-

Atlikimo eiga:

1. Atidaryti kortelę „Trečia klasė“.

Rezultatai:

Atvaizduojami trečios klasės kokybės įverčiai.

5. Peržiūrėti ketvirtos vaizdo klasės kokybės įverčius

Prieš pradedant:

-

Atlikimo eiga:

1. Atidaryti kortelę „Ketvirta klasė“.

Rezultatai:

Atvaizduojami ketvirtos klasės kokybės įverčiai.

6. Peržiūrėti penktos vaizdo klasės kokybės įverčius

Prieš pradedant:

-

Atlikimo eiga:

1. Atidaryti kortelę „Penkta klasė“.

Rezultatai:

Atvaizduojami penktos klasės kokybės įverčiai.

7. Peržiūrėti šeštos vaizdo klasės kokybės įverčius

Prieš pradedant:

-

Atlikimo eiga:

1. Atidaryti kortelę „Šešta klasė“.

Rezultatai:

Atvaizduojami šeštos klasės kokybės įverčiai.

8. Grįžti į sistemos pagrindinį langą

Prieš pradedant:

-

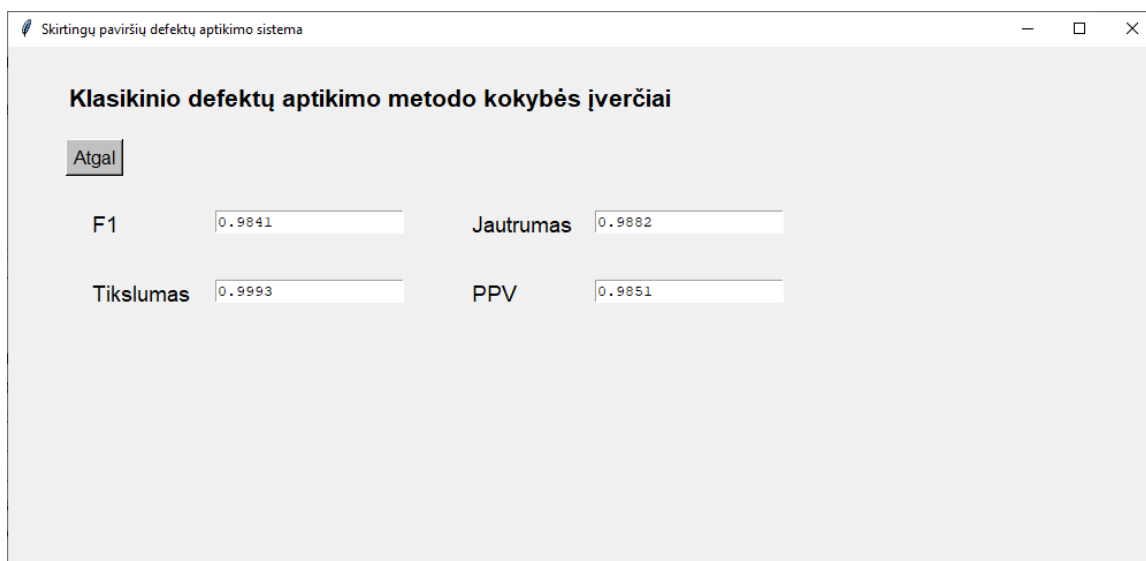
Atlikimo eiga:

1. Paspausti mygtuką [Atgal].

Rezultatai:

Atidaromas sistemos pagrindinis langas.

Klasikinio metodo kokybės įverčių peržiūros langas



Klasikinio defektų aptikimo metodo kokybės įverčiai			
Atgal			
F1	0.9841	Jautrumas	0.9882
Tikslumas	0.9993	PPV	0.9851

Klasikinio metodo kokybės įverčių peržiūros langas

Lango aprašymas

Langas skirtas peržiūrėti klasikinio metodo kokybės įverčius.

Lange rodomų laukų aprašymas

- **F1** – lauke atvaizduojamas neuroninio tinklo mokymo kokybės įvertis *F1*. Kokybės įvertis atvaizduojamas suapvalintas iki trijų skaičių po kablelio.
- **Tikslumas** – lauke atvaizduojamas neuroninio tinklo mokymo kokybės įvertis *tikslumas*. Kokybės įvertis atvaizduojamas suapvalintas iki trijų skaičių po kablelio.
- **Jautrumas** – lauke atvaizduojamas neuroninio tinklo mokymo kokybės įvertis *jautrumas*. Kokybės įvertis atvaizduojamas suapvalintas iki trijų skaičių po kablelio.
- **PPV** – lauke atvaizduojamas neuroninio tinklo mokymo kokybės įvertis *PPV*. Kokybės įvertis atvaizduojamas suapvalintas iki trijų skaičių po kablelio.

Galimi atlikti veiksmai:

1. Grįžti į sistemos pagrindinį langą.

1. Grįžti į sistemos pagrindinį langą

Prieš pradedant:

-

Atlikimo eiga:

1. Paspausti mygtuką [Atgal].

Rezultatai:


Atidaromas sistemos pagrindinis langas.

3 priedas. Pirmo eksperimento rezultatai


Klasikinio ir hierarchinio metodų palyginimas

Defektų aptikimo laikas klasikiniu metodu:19.79


Defektų aptikimo laikas hierarchiniu metodu:310.65




Nėra defekto




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 99




Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 52




Yra defektas
Defekto dydis pikseliais: 53




Nėra defekto



Neaptikta vaizdo klasė



Yra defektas
Defekto dydis pikseliais: 76




Neaptikta vaizdo klasė



Nėra defekto



Nėra defekto



Yra defektas
Defekto dydis pikseliais: 62




Yra defektas
Defekto dydis pikseliais: 56




Nėra defekto




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 51



Neaptikta vaizdo klasė




Nėra defekto




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 36




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 332




Yra defektas
Defekto dydis pikseliais: 357




Nėra defekto




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 37




Yra defektas
Defekto dydis pikseliais: 30




Yra defektas
Defekto dydis pikseliais: 24



Yra defektas
Defekto dydis pikseliais: 24




Yra defektas
Defekto dydis pikseliais: 304




Yra defektas
Defekto dydis pikseliais: 312




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 22




Yra defektas
Defekto dydis pikseliais: 86




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 128




Yra defektas
Defekto dydis pikseliais: 128




Yra defektas
Defekto dydis pikseliais: 120




Yra defektas
Defekto dydis pikseliais: 120




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto




Nēra defekto




Nēra defekto




Neaptikta vaizdo klasē




Nėra defekto



Nėra defekto




Yra defektas
Defekto dydis pikseliais: 158




Yra defektas
Defekto dydis pikseliais: 155




Yra defektas
Defekto dydis pikseliais: 137




Neaptikta vaizdo klasė



Nėra defekto




Nėra defekto




Nėra defekto




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 69




Yra defektas
Defekto dydis pikseliais: 63




Yra defektas
Defekto dydis pikseliais: 132




Neaptikta vaizdo klasė




Nėra defekto




Neaptikta vaizdo klasė



Nėra defekto




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 107




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 53




Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 124




Yra defektas
Defekto dydis pikseliais: 115




Nėra defekto




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 419




Yra defektas
Defekto dydis pikseliais: 415




Yra defektas
Defekto dydis pikseliais: 92




Neaptikta vaizdo klasė



Yra defektas
Defekto dydis pikseliais: 239




Yra defektas
Defekto dydis pikseliais: 244




Yra defektas
Defekto dydis pikseliais: 81




Neaptikta vaizdo klasė




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 2




Nėra defekto




Nėra defekto




Nėra defekto




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 34




Yra defektas
Defekto dydis pikseliais: 33




Yra defektas
Defekto dydis pikseliais: 140



Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Nėra defekto




Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Yra defektas.
Defekto dydis pikseliais: 100




Yra defektas.
Defekto dydis pikseliais: 94




Yra defektas
Defekto dydis pikseliais: 36




Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 105




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 103




Neaptikta vaizdo klasė




Nėra defekto



Nėra defekto




Nėra defekto




Neaptikta vaizdo klasė




Nēra defekto



Nēra defekto



Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto




Nēra defekto




Nėra defekto



Neaptikta vaizdo klasė



Yra defektas
Defekto dydis pikseliais: 64




Yra defektas
Defekto dydis pikseliais: 61

4 priedas. Antro eksperimento rezultatai


Klasikinio ir hierarchinio metodų palyginimas

Defektų aptikimo laikas klasikiniu metodu:19.41


Defektų aptikimo laikas hierarchiniu metodu:313.12




Nėra defekto



Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Nėra defekto



Neaptikta vaizdo klasė



Néra defekto




Neaptikta vaizdo klasė




Néra defekto




Néra defekto




Néra defekto




Neaptikta vaizdo klasė




Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto




Neaptikta vaizdo klasē




Yra defektas
Defekto dydis pikseliais: 5




Nėra defekto




Nėra defekto




Neaptikta vaizdo klasė




Nėra defekto



Nėra defekto



Nēra defekto



Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto




Neaptikta vaizdo klasē




Nėra defekto




Nėra defekto




Nėra defekto




Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto




Neapiktā vaizdo klasē




Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto



Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto



Neaptikta vaizdo klasē



Nēra defekto




Nēra defekto




Nēra defekto




Nēra defekto




Nëra defekto




Nëra defekto




Nëra defekto



Nëra defekto



Nëra defekto



Nëra defekto




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto



Nēra defekto



Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto



Neaptikta vaizdo klasē




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto




Nēra defekto




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto



Nēra defekto



Nēra defekto




Nēra defekto




Nēra defekto




Neaptikta vaizdo klasē



Nēra defekto




Nēra defekto




Nēra defekto



Nēra defekto



Nēra defekto




Nēra defekto




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto



Neaptikta vaizdo klasē



Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto



Neaptikta vaizdo klasē



Nēra defekto




Neaptikta vaizdo klasē




Nēra defekto




Nēra defekto




Yra defektas
Defekto dydis pikseliais: 22




Nėra defekto



Nėra defekto




Neaptikta vaizdo klasė




Nėra defekto




Neaptikta vaizdo klasė




Néra defekto




Néra defekto




Néra defekto




Néra defekto




Néra defekto




Néra defekto




Nëra defekto



Nëra defekto



Nëra defekto




Nëra defekto

5 priedas. Trečio eksperimento rezultatai


Klasikinio ir hierarchinio metodų palyginimas

Defektų aptikimo laikas klasikiniu metodu: 19.53


Defektų aptikimo laikas hierarchiniu metodu: 329.57




Yra defektas
Defekto dydis pikseliais: 32



Yra defektas
Defekto dydis pikseliais: 44




Yra defektas
Defekto dydis pikseliais: 88




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 73




Neaptikta vaizdo klasė




Defekto dydis pikseliais: 176




Yra defektas
Defekto dydis pikseliais: 178




Yra defektas
Defekto dydis pikseliais: 77




Yra defektas
Defekto dydis pikseliais: 81




Yra defektas
Defekto dydis pikseliais: 114




Yra defektas
Defekto dydis pikseliais: 108




Yra defektas
Defekto dydis pikseliais: 39




Yra defektas
Defekto dydis pikseliais: 37




Yra defektas
Defekto dydis pikseliais: 82




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 76



Yra defektas
Defekto dydis pikseliais: 72




Yra defektas
Defekto dydis pikseliais: 390




Yra defektas
Defekto dydis pikseliais: 393




Yra defektas
Defekto dydis pikseliais: 32




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 115




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 164




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 68




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 81




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 93



Yra defektas
Defekto dydis pikseliais: 94




Yra defektas
Defekto dydis pikseliais: 304




Yra defektas
Defekto dydis pikseliais: 312




Yra defektas
Defekto dydis pikseliais: 72




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 112




Yra defektas
Defekto dydis pikseliais: 115




Yra defektas
Defekto dydis pikseliais: 80




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 101




Yra defektas
Defekto dydis pikseliais: 87




Yra defektas
Defekto dydis pikseliais: 154



Nėra defekto




Yra defektas
Defekto dydis pikseliais: 375




Yra defektas
Defekto dydis pikseliais: 389



Yra defektas
Defekto dydis pikseliais: 59




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 164




Neaptikta vaizdo klasė



Yra defektas
Defekto dydis pikseliais: 86



Yra defektas
Defekto dydis pikseliais: 87




Yra defektas
Defekto dydis pikseliais: 134




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 75




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 38




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 440




Yra defektas
Defekto dydis pikseliais: 500



Yra defektas
Defekto dydis pikseliais: 319




Yra defektas
Defekto dydis pikseliais: 317




Yra defektas
Defekto dydis pikseliais: 112



Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 103




Yra defektas
Defekto dydis pikseliais: 99



Yra defektas
Defekto dydis pikseliais: 84




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 136




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 75



Yra defektas
Defekto dydis pikseliais: 70




Yra defektas
Defekto dydis pikseliais: 124



Yra defektas
Defekto dydis pikseliais: 115



Yra defektas
Defekto dydis pikseliais: 69




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 94




Yra defektas
Defekto dydis pikseliais: 90




Yra defektas
Defekto dydis pikseliais: 191




Yra defektas
Defekto dydis pikseliais: 196




Yra defektas
Defekto dydis pikseliais: 239




Yra defektas
Defekto dydis pikseliais: 244




Yra defektas
Defekto dydis pikseliais: 39



Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 81




Neaptikta vaizdo klasė



Yra defektas
Defekto dydis pikseliais: 13




Yra defektas
Defekto dydis pikseliais: 30




Yra defektas
Defekto dydis pikseliais: 166




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 81




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 282




Yra defektas
Defekto dydis pikseliais: 278




Yra defektas
Defekto dydis pikseliais: 50




Yra defektas
Defekto dydis pikseliais: 54




Yra defektas
Defekto dydis pikseliais: 178




Yra defektas
Defekto dydis pikseliais: 170



Yra defektas
Defekto dydis pikseliais: 386



Yra defektas
Defekto dydis pikseliais: 392




Yra defektas
Defekto dydis pikseliais: 77



Neaptikta vaizdo klasė




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 31




Yra defektas
Defekto dydis pikseliais: 128




Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 104




Yra defektas
Defekto dydis pikseliais: 100




Yra defektas
Defekto dydis pikseliais: 48




Neaptikta vaizdo klasė




Nėra defekto




Nėra defekto




Yra defektas
Defekto dydis pikseliais: 126




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 467




Yra defektas
Defekto dydis pikseliais: 464




Yra defektas
Defekto dydis pikseliais: 149




Neaptikta vaizdo klasė




Yra defektas
Defekto dydis pikseliais: 64



Yra defektas
Defekto dydis pikseliais: 61



Yra defektas
Defekto dydis pikseliais: 70



Neaptikta vaizdo klasė