



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

**Gilaus apmokymo metodo taikymo medienos lukšto kokybės
įvertinimui tyrimas**

Baigiamasis magistro projektas

Augustas Urbonas

Projekto autorius

doc. dr. Vidas Raudonis

Vadovas

Kaunas, 2019



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Gilaus apmokymo metodo taikymo medienos lukšto kokybės įvertinimui tyrimas

Baigiamasis magistro projektas

Valdymo technologijos (6211EX014)

Augustas Urbonas

Projekto autorius

doc. dr. Vidas Raudonis

Vadovas

lekt. dr. Kęstas Rimkus

Recenzentas

Kaunas, 2019



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Augustas Urbonas

Gilaus apmokymo metodo taikymo medienos lukšto kokybės įvertinimui tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Augusto Urbono, baigiamasis projektas tema „Gilaus apmokymo metodo taikymo medienos lukšto kokybės įvertinimui 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)

Urbonas Augustas. Gilaus apmokymo metodo taikymo medienos lukšto kokybės įvertinimui tyrimas. Magistro baigiamasis projektas / vadovas doc. dr. Vidas Raudonis; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): elektronikos inžinerija, inžinerijos mokslai

Reikšminiai žodžiai: Kompiuterinė rega, mašininis mokymas, objektų atpažinimas, gilieji neuroniniai tinklai, vizualinė kokybės analizė

Kaunas, 2019. 58 p.

Santrauka

Medienos vizualinę patikrą pramonėje vis dar atlieka apmokyti operatoriai, tačiau tai varginantis ir pasikartojantis darbas, kuriame išlieka žmogiškosios klaidos tikimybė. Šiuo metu rinkoje vis dažniau yra pritaikomi automatizuoti įrenginiai, naudojančys aukštos rezoliucijos kameras bei skaitinius metodus, tačiau jie ne visada yra pakankamai greiti bei tikslūs.

Šiame darbe yra aprašomas *Faster R-CNN* metodo panaudojimas medienos lukšto analizei tirti bei įvertinti. Šis metodas rinkoje jau buvo panaudotas medicinos, pėsčiųjų stebėjimo bei sekimo srityse, tačiau duomenų apie šio metodo pritaikymą medienos lukšto kokybės analizėje nėra.

Šiame darbe yra atliekami metodo tikslumo priklausomybės nuo mokymo epochų, atrinktų regionų kiekio bei dydžio tyrimai. Nustatyta sintetinės duomenų bazės bei skirtingo bazinio modelio įtaką metodo tikslumui bei greitaveikai. Metodas taip pat išbandomas panaudojant papildomą perdavimo mokymo metu apmokytą klasifikatorių.

Urbonas Augustas. Research of Deep Learning Method for Wood Veneer Quality Inspection. Master's Final Degree Project / supervisor assoc. prof. dr. Vidas Raudonis.; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

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

Keywords: computer vision, machine learning, defect detection, deep learning method

Kaunas, 2019. 58.

Summary

In lumber industry most of the visual quality inspections are still done by trained operators, this is tedious and repetitive task with high likelihood of human error. Currently, new automated solutions with high resolution cameras and visual inspection algorithms are being tested, but they are not always fast and accurate enough.

This paper describes how highly effective faster region-based convolutional neural network (*Faster R-CNN*) is implemented in wood veneer defect detection. This method was successfully used in medicine and surveillance solutions, but there are no papers about this method usage in wood veneer quality assurance.

In this paper, research on method accuracy dependence from learning epoch count, learning and testing proposal region count is carried out. Performance optimization using different base models and proposal region count is also analyzed. Experiments using synthetically augmented dataset and additional transfer learning classifier are also performed.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	9
Santrumpų ir terminų sąrašas	11
Įvadas.....	12
1. Literatūros analizė.....	13
1.1. Skaitmeninis vaizdas	13
1.2. Vaizdo atpažinimas	13
1.3. Medienos lukštas	14
1.3.1. Medienos lukšto kokybė.....	15
1.4. Kokybės patikra.....	15
1.5. Vizualinių kokybės patikros metodų bei algoritmų apžvalga	16
1.5.1. Dviejų slenksčių metodas	16
1.5.2. Vilnelių transformacijos metodas.....	16
1.5.3. Gabor filtro metodas.....	18
1.5.4. Dirbtiniais sąsukos neuroniais tinklais pagrįstos sistemos.....	18
1.5.5. <i>R-CNN</i> detektoriai.....	20
1.5.6. <i>Fast R-CNN</i> metodas	21
1.5.7. <i>Faster R-CNN</i> metodas.....	22
1.6. <i>Faster R-CNN</i> tinklo architektūros.....	23
1.6.1. <i>AlexNet</i> architektūra	23
1.6.2. <i>VGG16</i> architektūra.....	23
1.7. Mokymo perkėlimo metodas	24
1.7.1. ResNet architektūra	25
1.7.2. GoogleNet/Inception architektūra	25
1.8. Esamų pramoninių kokybės patikros sistemų apžvalga	27
1.8.1. „Omron“ vaizdo sistemos.....	27
1.8.2. „Argos Solutions“ kokybės tikrinimo sistemos.....	28
2. Metodologija	29
2.1. Naudojamų technologijų analizė	29
2.1.1. Duomenų rinkimo stendas	29
2.1.2. Linijinės kameros	29
2.1.3. Basler raL4096-24gm kamera	30
2.1.4. Impulsinis enkoderis.....	30
2.1.5. Programinė įranga	31
2.2. Duomenų bazė	32
2.2.1. Duomenų bazės praplėtimas sintetiniais duomenimis.....	34
2.3. Metodo tikslumo vertinimas	34
2.3.1. Defektų pozicijos radimo tikslumo nustatymas	34
2.3.2. Rūšies nustatymo tikslumas	35
3. Eksperimentiniai tyrimai.....	36
3.1. Originalios ir praplėstos sintetiniais duomenimis duomenų bazės įtaka metodo tikslumui.....	37
3.2. Skirtingo epochų skaičiaus įtaka metodo tikslumui	38
3.3. Skirtingų tinklo architektūrų įtaka metodo tikslumui.....	40

3.4. Skirtingo atrinktų regionų kiekio naudojant maksimumų atrinkimą mokymo metu įtaka metodo tikslumui	42
3.5. Regionų išskyrimo tinklo slenkančio lango dydžio kitimo įtaka metodo tikslumui	43
3.6. Skirtingo atrinktų regionų kiekio, naudojant maksimumų atrinkimą įvertinimo metu, įtaka metodo tikslumui bei greitaveikai	45
3.7. <i>AlexNet</i> architektūra grįsto defekto atpažinimo algoritmo tikslumo tyrimas	46
3.8. Atpažinimo algoritmų, sukurtų taikant mokymo perkėlimo metodą, atpažinimo tikslumo tyrimas	47
3.8.1. Perkelta mokymosi <i>AlexNet ImageNet</i> modelio tikslumo tyrimas.....	48
3.8.2. Perkelta mokymosi <i>VGG16 ImageNet</i> modelio tikslumo tyrimas.....	49
3.8.3. Perkelta mokymosi <i>BNInception ImageNet</i> modelio tikslumo tyrimas	50
3.8.4. Perkelta mokymosi <i>ResNet152 ImageNet</i> modelio tikslumo tyrimas	52
3.9. Skirtingų mokymo perkėlimo metodu apmokytų modelių palyginimas	53
3.10. Defektų radimo metodo su papildomu klasifikatoriumi tyrimas.....	55
Išvados	56
Literatūros sąrašas	57
Priedai.....	59
1 priedas. Bandymų rezultatų skaitinių reikšmių lentelės	59

Lentelių sąrašas

1 lentelė. <i>R-CNN</i> rūšies metodų palyginimas	23
2 lentelė. Kameros parametrai.....	30
3 lentelė. Enkoderio parametrai	31
4 lentelė. Defektų rūšies vertinimo lentelė.....	35
5 lentelė. Antro eksperimento metodo parametrai	38
6 lentelė. Skirtingų tinklo architektūrų mokymo trukmės bei testavimo greitaveikos palyginimas	41
7 lentelė. Ketvirto eksperimento metodo parametrai	42
8 lentelė. Penkto eksperimento metodo parametrai	44
9 lentelė. Regionų išskyrimo slenkančių langų dydžių įtaka metodo tikslumui	44
10 lentelė. Šešto eksperimento metodo parametrai.....	45
11 lentelė. <i>AlexNet</i> perdavimo mokymosi rezultatai.....	48
12 lentelė. <i>VGG16</i> modelio perdavimo mokymo rezultatai.....	49
13 lentelė. <i>BNInception</i> modelio perdavimo mokymo rezultatai.....	50
14 lentelė. <i>ResNet152</i> modelio perdavimo mokymo rezultatai	52
15 lentelė. Skirtingų baziniu modelių, naudotų perdavimo mokyme, įtaka metodo tikslumui.	53
16 lentelė. Metodo su papildomu klasifikatoriumi tyrimo rezultatai	55

Paveikslų sąrašas

1 pav. Skaitmeninio vaizdo sudėtis	13
2 pav. Vaizdo atpažinimo sistemų panaudojimas: a) žmonių aptikimas, b) tekstilės defektų radimas, c) kelio linijų aptikimas	13
3 pav. Medienos lukštas	14
4 pav. Lukšto gavimo būdai, a) sukimo metodas, b) pjaustymo metodas	15
5 pav. Dvigubo slenksčio metodas. a) Matomas defektas, b) Vaizdas apdorotas dvigubo slenksčio algoritmu.....	16
6 pav. Pirmo bei antro lygio vilnelių transformacijos[WAVE3]	17
7 pav. Tekstilės defektų aptikimo algoritmo veikimas	17
8 pav. Šašukos sluoksnio filtrai.....	18
9 pav. Tankinimo operacija naudojant maksimalios vertės funkciją	19
10 pav. <i>R-CNN</i> veikimo principas. a) originali nuotrauka, b) SS rasti tikslingi regionai.....	20
11 pav. <i>Fast R-CNN</i> veikimas a) originali nuotrauka b) šašukos požymių sudarymas	21
12 pav. 9 pasiūlomi regionai	22
13 pav. Regionų pasiūlymų tinklas, SS – šašukos sluoksnis	22
14 pav. <i>AlexNet</i> architektūra.	23
15 pav. <i>VGG16</i> architektūra.....	24
16 pav. ResNet jungtis	25
17 pav. Dimensijų mažinimo pavyzdys	26
18 pav. <i>Inception</i> modulis	26
19 pav. Rezultatas po sujungimo	26
20 pav. Omron FQ serijos kameros	28
21 pav. „Argos Solutions“ faneros kokybės tikrinimo sistema.....	28
22 pav. Duomenų rinkimo stendas.....	29
23 pav. Basler raL4096-24gm kamera	30
24 pav. LIKA enkoderis	30
25 pav. Lukšto nuotraukų pavyzdžiai, a) be defektų, b) matomas branduolys, c) matomos šakos ..	32
26 pav. Nuotraukos rezoliucijos įtaka įbrėžimo defektui, a) originalus fragmentas, b) 5 kartus sumažintas nuotraukos fragmentas, c) 10 kartų sumažintas nuotraukos fragmentas	32
27 pav. Defektų pavyzdžiai, a) skilimas, b) branduolys, c) šaka, d) dėmė.....	33
28 pav. VoTT programa sužymėta nuotrauka. Žalia spalva pažymėtos šakos, mėlyna – skilimai, geltona – dėmės	33
29 pav. Defektų regionų kiekis duomenų bazėje	34
30 pav. Duomenų bazės sintetinimo pavyzdys, a) – originali nuotrauka, b), c) d) nuotraukos gautos sintetinant duomenų bazę.	34
31 pav. <i>IoU</i> parametro skaičiavimas	35
32 pav. Pirmieji <i>Faster R-CNN</i> bandymai	37
33 pav. Originalios ir praplėstos sintetiniais duomenimis duomenų bazių įtaka metodo tikslumui ..	37
34 pav. <i>AlexNet</i> architektūros pagrindu apmokyto metodo defektų radimo tikslumo bei lukšto rūšies nustatymo tikslumo bandymai.....	39
35 pav. <i>VGG16</i> architektūros pagrindu apmokyto metodo tikslumo priklausomybė nuo epochų skaičiaus	40
36 pav. <i>AlexNet</i> ir <i>VGG16</i> architektūrų su optimaliais epochų skaičiais palyginimas	41

37 pav. Atrinktų regionų kiekio kitimo įtaka metodo tikslumui.....	43
38 pav. Atrinktų regionų testavimo metu kiekio kitimo įtaka metodo tikslumui bei greitaverikai ..	46
39 pav. <i>Faster R-CNN</i> metodo su viena klase naudojančio <i>AlexNet</i> architektūrą tikslumo priklausomybė nuo epochų skaičiaus	47
40 pav. <i>AlexNet</i> rezultatų metodo sumaišymo matrica	49
41 pav. <i>VGG16</i> rezultatų metodo sumaišymo matrica	50
42 pav. <i>BNInception</i> rezultatų metodo sumaišymo matrica.....	51
43 pav. <i>ResNet152</i> rezultatų metodo sumaišymo matrica	53
44 pav. Modelių bendro tikslumo palyginimas.....	54
45 pav. Modelių greitaveikos palyginimas	54

Santrumpų ir terminų sąrašas

Santrumpos:

ms. – milisekundė;

px. – pikselis;

PI. – pasikliautinumo intervalas su 95% tikimybe

R-CNN - metodas, kuris apjungia regionų paieškos bei sąsukos neuroninių tinklų metodus.

NMS – maksimumų atrinkimas (angl. *non maximum supression*)

Terminai:

Maksimumų atrinkimas – atrenkamas nurodytas kiekis maksimalią vertę turinčių verčių didesnių už užduotą slenkstį.

Išvadas

Jungtinių Tautų Organizacijos duomenimis medienos pramonės augimas fiksuojamas visame pasaulyje. 2015 metais medienos plokščių pasaulio gamyba pasiekė 399 milijonus m³ per metus[1]. Vien Azijos rinkoje 2011–2015 metų periodu medienos produkcija išaugo 40 %. Viena medienos perdirbimo sričių yra medžio lukšto gamyba, kuri kartu su faneros plokščių gamyba, tapo dominuojančia rinka, užimančia 39 % visos medienos perdirbimo rinkos arba 171 milijonus m³ per metus. Ši medžiaga yra naudojama baldų, durų ar interjero elementų paviršių dengimui. Dėl nevienalytės žaliavos ir sudėtingo gamybos proceso pagamintuose lakštuose atsiranda įvairių defektų, tokių kaip įbrėžimai, dėmės ar medžio branduolio rievės. Rinkoje išdžiovinto kokybės kontrolę dažniausiai atlieka apmokyti operatoriai, tai labai varginantis ir pasikartojantis darbas, kuriame visada išlieka žmogiškosios klaidos tikimybė. Rinkoje yra keletas įmonių besispecializuojančių medienos defektų radime bei keletas skaitmeninių metodų naudojamų paviršiaus analizei, tokie kaip dviejų slenksčių, Gaboro ar vilnelių transformacijos bei populiarėjantys neuroninių tinklų metodai, tačiau jie yra ne visada pakankamai tikslūs bei greiti. 2015 metais pristatytas novatoriškas *Faster R-CNN* metodas buvo išbandytas medicinoje, objektų sekime bei stebėjime, tačiau apie jo panaudojimą medienos kokybinei analizei yra labai mažai arba visai nėra.

Šio darbo tikslas yra eksperimentiškai ištirti gilaus apmokymo metodo panaudojimą medienos lukšto kokybei vertinti.

Šiam tikslui yra keliami šie uždaviniai:


1. atlikti literatūros analizę;
2. apžvelgti rinkoje esančių panašių sprendimų technologijas bei išanalizuoti populiariausių rinkoje giliųjų neuroninių tinklų architektūras;
3. sukurti eksperimentinę bazę;
4. eksperimentiškai ištirti sintetiniais duomenimis padidintos duomenų bazės įtaką metodo tikslumui;
5. eksperimentiškai ištirti skirtingų defektų atpažinimo metodų tikslumą taikant skirtingus bazinius modelius bei parametrus;
6. eksperimentiškai ištirti skirtingų atpažinimo metodų spartą taikant skirtingus bazinius modelius bei parametrus;
7. eksperimentiškai ištirti mokymo perdavimo būdu apmokyto klasifikatoriaus tikslumą bei greitaveiką;
8. pateikti išvadas bei rekomendacijas.

1. Literatūros analizė

Žmonės pasaulį suvokia naudodami 5 jutimus – regą, uoslę, klausą skonį bei lytėjimą, bet kompiuteriams ši užduotis yra kur kas sunkesnė. Šiuo metu viena labiausiai populiarėjančių sričių yra kompiuterinė rega arba vaizdo atpažinimas, kur kompiuteriai apdorojami skaitmeninį vaizdą, turi išskirti tam tikrą svarbią informaciją.

1.1. Skaitmeninis vaizdas

Skaitmeninis vaizdas – tai kompiuteryje atvaizduotas dvimatis skaičių masyvas sudarytas iš pikselių [2]. Pikselis – tai mažiausias skaitmeninio vaizdo elementas, kuris nusako tam tikros paveikslėlio vietos, kurioje yra, intensyvumą. Pikseliai būna vieno arba kelių kanalų. Nespalvotos nuotraukos turi tik vieną kanalą, kuriame pikselių intensyvumas kinta nuo juodos iki baltos, o spalvotos – kelis kanalus, kurie kisdami nuo šviesiausio iki tamsiausio atspalvio sudaro spalvotą vaizdą. Skaitmeninio vaizdo sudėtis pavaizduota 1 paveiksle.




1 pav. Skaitmeninio vaizdo sudėtis

Spalvotas vaizdas yra skirstomas modeliais, kurie priklauso nuo to, kur vaizdas bus naudojamas. Dažniausiai spalvotas vaizdas susideda iš trijų dedamųjų: YUV, RGB, HSL, CMY bei kiti [2].

1.2. Vaizdo atpažinimas

Vaizdų atpažinimas naudojamas visur. Vaizdų atpažinimo pritaikymo galimybės plečiasi, jis naudojamas įvairiose srityse: nuo veidų atpažinimo žmonių identifikavimui ar QR kodų skenavimo iki panaudojimo autonominiuose automobiliuose bei virtualioje realybėje. Vien iki 2021 planuojama, kad vaizdų atpažinimo rinka augs iki 38,92 milijardų JAV dolerių per metus [3]. Šiuo metu rinkoje yra daugybė skirtingų algoritmų naudojamų vaizdo apdorojimui, tai – kampų radimo algoritmai, naudojami lokalizacijos bei 3D skenavimo uždavinių sprendimui, linijų radimo algoritmai – naudojami autonominiuose automobiliuose bei eismo juostos išlaikymo sistemose, nuotraukų klasifikavimo algoritmai – naudojami kokybės patikros sistemose ar nuotraukų segmentavimui.




2 pav. Vaizdo atpažinimo sistemų panaudojimas: a) žmonių aptikimas, b) tekstilės defektų radimas, c) kelio linijų aptikimas

Vaizdo atpažinimas vis dažniau naudojamas pramonėje, dėl lengvo integravimo sprendžiant paprastus uždavinius, tokius kaip etikečių patikra, brūkšninių kodų skenavimas tokiu būdu padidinant našumą bei taupant gamybos kaštus. Šiame darbe vaizdo analizė yra panaudojama medienos lukšto vizualinei kokybei vertinti.

1.3. Medienos lukštas

Medienos lukštas – tai ploni (0,5 –3 mm), dažniausiai kietmedžio medžio lakštai, skirti įvairių plokščių, skirtų baldų, durų ar interjero elementų paviršių dengimui. Medienos lukštas pavaizduotas 3 pav.




3 pav. Medienos lukštas

Medienos lukštas taip pat naudojamas ir faneros gamyboje, kuomet yra suklijuojami keli lukšto sluoksniai. Jis taip pat naudojamas degtukų bei ledų pagaliukų gamybai bei dekoratyvinei medienos inkrustacijai.

Medžio lukštas yra gaunamas dviem pagrindiniais būdais:

- sukimo metodas – Raštas yra išlukštenamas sukant aplink centrinę ašį, tokiu būdu gaunant ilgą medžio lukšto ruošinį. Šis metodas dažniausiai naudojamas faneros pramonėje. Šis metodas pavaizduotas 4 pav. a).
- pjaustymo metodas – raštas yra pjaustomas lygiagrečiomis juostomis, taip gaunant kitokio rašto medienos lukštą. Šis metodas dažniau naudojamas baldų pramonėje, kurioje yra svarbus medžio raštas. Šis metodas pavaizduotas 4 pav. b).



4 pav. Lukšto gavimo būdai, a) sukimo metodai, b) pjaustymo metodai

1.3.1. Medienos lukšto kokybė

Medienos lukšto vizualinė kokybė taip pat labai svarbi, nuo jos priklauso kur medienos lukšto lapas bus panaudotas. Pavyzdžiui, baldų gamyboje paviršių dengimui lukšto vizualinė kokybė yra labai svarbi, norima, kad būtų kuo mažiau šakų, dėmių ar įtrūkimų. Faneros gamyboje standartus atitinkančios vizualinės kokybės lukštas yra naudojamas paviršiaus sluoksniuose, o prastesnės vizualinės kokybės lukštas dedamas į vidinius sluoksnius. Šiame darbe išskiriame 5 pagrindines medienos lukšto kokybės rūšis:

- A/B rūšis – medžio lukštas turintis iki 5 nedidelių šakų viename kvadratiname metre;
- C rūšis – medžio lukštas turintis virš 5 nedidelių šakų viename kvadratiname metre, tačiau panaudotinas tolesnėje gamyboje;
- BR rūšis – tai medžio lukštas turintis medžio šerdies intarpų, tačiau panaudotinas tolesnėje gamyboje;
- D rūšis – tai medžio lukštas turintis didelius defektus ir nepanaudotinas tolesnėje gamyboje;
- K rūšis – tai medžio lukštas turintis defektus plokštės galuose, todėl gali būti trumpinamas ir panaudojamas gamyboje.

1.4. Kokybės patikra

Augant pramonės mastams bei didėjant produkcijos kiekiams, taip pat didėja ir nekokybiškos produkcijos kiekiai. Įmonės steigia kokybės užtikrinimo skyrius, kurie yra atsakingi už kokybiškų produktų patekimą į rinką. Kokybiškas produktas – tai produktas, kurio bruožai atitinka gamintojo ir vartotojo standartus[4].

Vienas populiariausių kokybės tikrinimo metodų yra atsitiktinis tikrinimas gamybos eigoje, atsitiktine tvarka parenkant produktus bei patikrinant pagal kokybės kriterijus, jei patikrinti produktai yra kokybiški, gamyba tęsiama, jei randami defektai ar neatitikimai, gamybos linija stabdoma, ieškoma sprendimo, tačiau įmonė dėl prastovų patiria nuostolius. Nors šis metodas yra plačiai naudojamas, jis neužtikrina visos produkcijos patikrinimo[5]. Esant dideliems produkcijos kiekiams, žmonės tiesiog nespėja patikrinti visų gaminių, taip pat visada išlieka žmogiškosios klaidos veiksniai, tokie kaip išsiblašymas ar nuovargis. Šiuolaikinės automatinės patikros sistemos naudojamos įvairius jutiklius sugeba veikti be sustojimo, dideliu greičiu, griežtai apibrėžtomis taisyklėmis, tokiu būdu gali patikrinti visus gaminamus produktus bei užtikrinti patikimą rezultatą. [6][7]. Vizualinei kokybės patikrai vis dažniau naudojamos kompiuterinės regos sistemos.

1.5. Vizualinių kokybės patikros metodų bei algoritmų apžvalga

Medienos rinkoje dažnai vizualinę kokybės analizę atlieka apmokyti ekspertai, tačiau tai varginantis ir pasikartojantis darbas, kuriame išlieka žmogiškosios klaidos faktorius. Ištirta, kad žmonės retai kada geba pasiekti daugiau nei 70 % vizualinės analizės patikimumo [8], todėl gamybos kompanijos ieško kaip automatizuoti šį procesą, tokiu būdu padidinant patikimumą bei kokybiškos produkcijos kiekį. Kompiuterinės regos sistemos naudojančios aukštos rezoliucijos bei didelės greitaiveikos filmavimo kameras skenuoja gaminius, o apdorojus gautą vaizdą įvairiais algoritmais ir metodais, informuoja apie gaminio kokybę. Šiame skyriuje yra apžvelgiami rinkoje naudojami metodai bei algoritmai naudojami paviršiaus kokybės analizei.

1.5.1. Dviejų slenksčių metodas

Tai vienas paprasčiausių bei seniausiai žinomų kompiuterinės regos paviršiaus kokybės tikrinimo metodų, panaudotas T. Carewo bei O.Ghito darbe apie paviršiaus kokybės patikrą dažytose keramikos plokštėse [9]. Šiame metode yra tikrinama nuotraukos pikselio vertė $P(x,y)$ papuola tarp dviejų slenksčių T_1 ir T_2 (1).

$$B(x,y) = \begin{cases} 0, & T_1 < P(x,y) < T_2 \\ 1 & \end{cases} ; \quad (1)$$

Tokiu būdu gaunamas binarinis paveikslas, pavaizduotas 5 pav.




5 pav. Dvigubo slenksčio metodas. a) Matomas defektas, b) Vaizdas apdorotas dvigubo slenksčio algoritmu

Tuomet suskaičiuojami pikseliai nuotraukoje esantys už slenksčio ribų, t.y. $B(x,y)=1$, jei pikselių suma yra didesnė už slenksčių, produktas yra nekokybiškas.

Šis metodas taip pat buvo panaudotas tikrinant kokybę tekstilės pramonėje, norint sumažinti duomenų kiekį nuotraukose, kurios buvo naudojamos neuroninių tinklų apmokymui bei spėjimui [10]. Nors šis metodas yra vienas greičiausių, jis yra tinkamas tik tolygaus apšvietimo sistemoms, taip pat objektams neturintiems gilios tekstūros, pavyzdžiui, tolygioms keramikinėms plytelėms ar smulkaus rašto tekstilei.

1.5.2. Vilnelių transformacijos metodas


Vilnelių transformacijos metodas (angl. *Wavelet transform*) – tai vaizdo suspaudimo bei duomenų tankinimo metodas, skirtas išsaugoti kuo daugiau informacijos vaizde neprarandant reikšmingos informacijos.



6 pav. Pirmo bei antro lygio vilnelių transformacijos[WAVE3]

Pirmiausiai paveikslas yra užaštrinamas panaudojant aukšto dažnio filtrus (angl. *high-pass filter*) tokiu būdu išskiriant vietinius ryškumo pasikeitimus, tuomet paveikslas suglotninamas panaudojant žemo dažnio filtrus(angl. *low-pass filter*) bei sumažinamas du kartus taip gaunant suspaustą apytikslį paveikslą[11]. Norint gauti antro lygio vilnelių transformaciją, operacija kartojama.

Šis metodas buvo pritaikytas mokslininkų Y. Li bei J.Ai komandos tekstilės defektų radimo sistemoje[12]. Algoritmas buvo patikrintas pramonėje bei pasiekė 98 % patikimumo rodiklį ieškant tekstilės defektų. Algoritmo veikimo eiga pavaizduota 7 paveiksle.



7 pav. Tekstilės defektų aptikimo algoritmo veikimas

Nufotografavus nuotrauką (7 pav. (a)), ji normalizuojama panaudojant histogramos suliginimo algoritimą (7 pav. (b)). Triukšmas nufiltruojamas panaudojant medianos filtrą (7 pav. (c)). Gautam paveikslui atliekama antros eilės vilnelių transformacija (7 pav. (d)). Atliekamos slenkstinės bei erozijos bei auginimo operacijos (7 pav. (e), (f) bei (g)). Panaudojant vietinį dvejetainis rašto (angl. *local binary pattern*) deskriptorių gaunamas vaizdas išskiriantis kokybės neatitinkančias vietas. Vilnelių transformacijos taip pat buvo panaudotos Y. A. Karayiannis bei R. Stojanovic tekstilės defektų radimo darbe, kuriame algoritmas pasiekė 85 % tikslumą esant vaizdo trikdžiam, bei 94 % tikslumą be trikdžių vaizde [10]. Metodus taip pat buvo panaudotas medienos pramonėje medžio šakų bei taškų klasifikavimui [13].

1.5.3. Gabor filtro metodas

Gaboro filtras – tai tiesinis filtras naudojamas paveikslo rašto analizei nusakantis ar raštas yra tam tikro dažnio spektro aplink užduotą tikrinimo tašką. Šis filtras yra sudarytas iš Gauso ir sinuso bei kosinuso funkcijų sandaugos. Kadangi filtras yra taikomas dvimačiam vaizdui, visus funkcijos yra dviejų kintamųjų. Dvimatė Gabor filtro išraiška pateikta 2 lygtyje.

$$f(x, y, \omega, \theta, \sigma_x, \sigma_y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[\frac{-1}{2}\left(\left(\frac{x}{\sigma_x}\right)^2 + \left(\frac{y}{\sigma_y}\right)^2\right) + j\omega(x\cos\theta + y\sin\theta)\right]; \quad (2)$$

čia σ – erdvinis pasiskirstymas, ω – dažnis, θ - kryptis


Šis metodas buvo pritaikytas medžio lukšto kokybės analizei [GABOR2], kuomet naudojant Gabor požymius bei RGB histogramas buvo apmokytas daugiasluoksnis perceptronas (angl. *Multilayer Perceptron*). Sistema buvo skirta medžio šakų bei nelygumo klasifikavimui. Apmokytas daugiasluoksnis perceptronas veikė 85-90 % procentų tikslumu[14]. Šis metodas taip pat plačiai taikytas tekstilės pramonėje[15][16].

1.5.4. Dirbtiniais sąsukos neuroniais tinklais pagrastos sistemos

Sąsukos neuronų tinklai (angl. *Convolutional Neural Networks*) puikiai tinka klasifikavimo uždaviniams spręsti, tai vieni tiksliausių rinkoje esančių algoritmų, tačiau pasižymi dideliu skaičiavimų kiekiu[17]. Šie tinklai yra sudaryti iš daugybės filtrų, kurių išėjimams naudojamos sąsukos bei tankinimo operacijos. Parametrų kiekis šiuose tinkluose taip pat yra labai didelis, pavyzdžiui CIFAR-10 duomenų bazėje nuotraukos yra spalvotos 32x32 pikselių rezoliucijos, todėl vien pirmame pilnai sujungtame neurone svorių kiekis yra lygus $32 \times 32 \times 3 = 3072$. Jei nuotraukos rezoliucija būtų 200x200, svorių skaičius išaugtų iki 120000 vienam perceptronui, o jų neuronų tinkle būna dešimtys ar net šimtai[18].

Pagrindiniai sąsukos neuronų tinklų sluoksniai yra:

- įėjimo sluoksnis – šiame sluoksnyje į tinklą yra paduodama originali nuotrauka paversta į vienmatį vektorių. Pavyzdžiui, spalvota 3 kanalų nuotrauka, kurios dydis yra 32 x 32 pikseliai bus paverčiamas $32 \times 32 \times 3 = 3072$ reikšmių vektoriumi.
- sąsukos sluoksnis – tai pagrindinė neuroninio tinklo dalis. Šiame sluoksnyje skaičiuojama šio sluoksnio filtro matricos ir įėjimo svorių matricos skaliarinė sandauga prie kurios yra pridamas paklaidos koeficientas, taip gaunamas objekto požymio žemėlapių rinkinys (angl. *feature map*). Filtrų pavyzdžiai pavaizduoti 8 pav.



8 pav. Sąsukos sluoksnio filtrai

Sąsukos sluoksnio svorių bei paklaidų matricos yra sukuriamos tinklo mokymosi metu. Gautame požymių dvimatyje žemėlapyje yra matoma sluoksnio rezultatas. Šie filtrai išmoksta ieškomo ar klasifikuojamo objekto kampų, kraštinių, spalvų požymius. Gautas požymių žemėlapis yra perduodamas aktyvavimo funkcijai.

- aktyvacijos sluoksnis – šis sluoksnis būna po kiekvieno sąsukos sluoksnio. Šiame sluoksnyje yra pritaikoma netiesinė funkcija visoms požymių žemėlapio reikšmėms. Populiariausios yra 3 funkcijos:

- ReLU aktyvacijos funkcija

$$f(x) = \max(0, x); \quad (3)$$

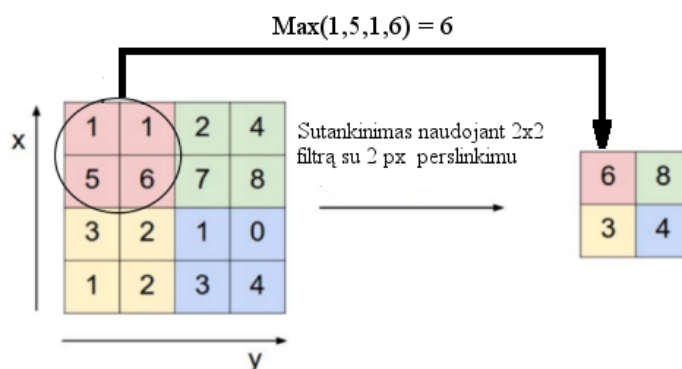
- sigmoidinė aktyvacijos funkcija

$$f(x) = \frac{1}{1+e^{-x}}; \quad (4)$$

- tangentinė aktyvacijos funkcija

$$f(x) = \tanh(x) = \frac{e^{2x}-1}{e^{2x}+1}; \quad (5)$$

- sutankinimo sluoksnis (angl. *pooling*) – šis sluoksnis naudojamas požymių žemėlapio duomenų kiekio mažinimui. Duomenų tankinimui gali būti naudojamos maksimalios vertės, vidurkio ar sumos tankinimo operacijos. Maksimalios vertės tankinimo operacija pavaizduota 9 paveiksle.



9 pav. Tankinimo operacija naudojant maksimalios vertės funkciją

- pilnai sujungtas (angl. *fully connected*) sluoksnis – tai paskutinis sąsukos neuroninio tinklo sluoksnis. Šio sluoksnio visi neuronai yra sujungti su prieš tai esančio sluoksnio neuronais. Šio sluoksnio išėjimas yra vektorius, kurio ilgis yra lygus neuroninio tinklo klasių skaičiui. Pavyzdžiui, jei tai būtų skaičių atpažinimo neuroninis tinklas, n būtų lygus 10, nes yra 10 skaičių.


Sąsukos neuroniniai tinklai puikiai tinka klasifikavimo operacijom, tačiau objektų radime, jei naudojamas slenkančio lango metodą, jie yra labai lėti, nes objekto paieškos laikas yra proporcingas nuotraukos dydžiui [19]. Vienas iš šios problemų sprendimų yra naudoti regionų pasiūlymo (angl. *region proposal*) metodus, darant prielaidą, kad ieškomi objektai turi bendrų vizualinių bruožų ir

išsiskiria iš foninio vaizdo. Radus regioną, kuriame yra didelė tikimybė rasti objektą, jis patikrinamas tikslesniu klasifikatoriumi, taip nustatant tikslią jo poziciją bei klasę. Naudojant šį metodą paieškos regionų kiekis yra sumažinamas kelis kartus[19]. Vieni pagrindinių šio tipo detektorių yra *R-CNN* (angl. *Regions with Convolutional Neural Networks features*)[20] rūšies detektoriai.

1.5.5. *R-CNN* detektoriai

2014 metais Rosas Girshickas ir Jefas Donahuas pristatė *R-CNN* (angl. *region based convolutional neural network*) metodą, kuris apjungia paieškos regionų bei sąsukos neuroninių tinklų metodus[20]. Regionų paieškos metodas buvo pasirinktas norint palyginti *R-CNN* metodą su tuo metu rinkoje esančiais konkurentais, tokiais kaip *OverFeat* metodu.

Algoritmas naudojamas pasirinkimų paieškos metodą (angl. *selective search*) iš nuotraukos išskiria 2000 tikslinių regionų pasiūlymų. Pasirinkimų paieškos metodui radus tinkamus regionus jie yra transformuojami į 227×227 fiksuoto dydžio nuotraukas, kurios yra apdorojamos panaudojant sąsukos neuroninius tinklus. Kiekvienam regionui yra gaunamas 4096 dimensijų vektorius, kuris klasifikuojamas tiesiniame SVM klasifikatoriuje. Gavus suklasifikuotus regionus, šie regionai yra apdorojama maksimumų atrinkimo metodu (angl. *non maximum supression*), kuris atmeta mažiausią tikslumą turinčius regionus bei panaikina persidengiančius regionus palikdami tik vieną kandidatą. *R-CNN* metodo sutrumpintas veikimas pavaizduotas 10 pav.



10 pav. *R-CNN* veikimo principas. a) originali nuotrauka, b) SS rasti tikslingi regionai
c) sąsukos požymių skaičiavimas, d) klasifikavimas

Šis metodas pasiekė 53,3 % vidutinio aptikimo tikslumo (angl. *mAP – mean average precision*) balą naudojant PASCAL VOC 2012 duomenų rinkinį, ir daugiau nei 30 % aplenkė prieš tai buvusį konkurentą naudojantį HOG pagrindu sukurtą metodą. Naudojant ILVRC2013 duomenų rinkinį šis metodas pasiekė 33,4 % *mAP* ir aplenkė prieš tai geriausią *OverFeat* metodą, kurio *mAP* buvo 24,3 %. Šis metodas nors ir pasižymi gan dideliu tikslumu, jo skaičiavimo laikas vienai nuotraukai naudojant *VGG16* duomenų rinkinį atliekant naudojant grafinį procesorių yra 47 sekundės [21], todėl jis yra netinkamas realaus laiko sistemoms. Šio metodo apmokymas užtrunka ilgai, pavyzdžiui, naudojant *VGG16* duomenų rinkinį reikalinga 2,5 vaizdo plokščių skaičiavimo dienos norint apmokinti 5 tūkstančius nuotraukų, kadangi kiekvieno regiono požymių vektoriai yra saugomi kietajame diske, mokymosi informacijai taip pat reikia labai daug kompiuterio atminties.

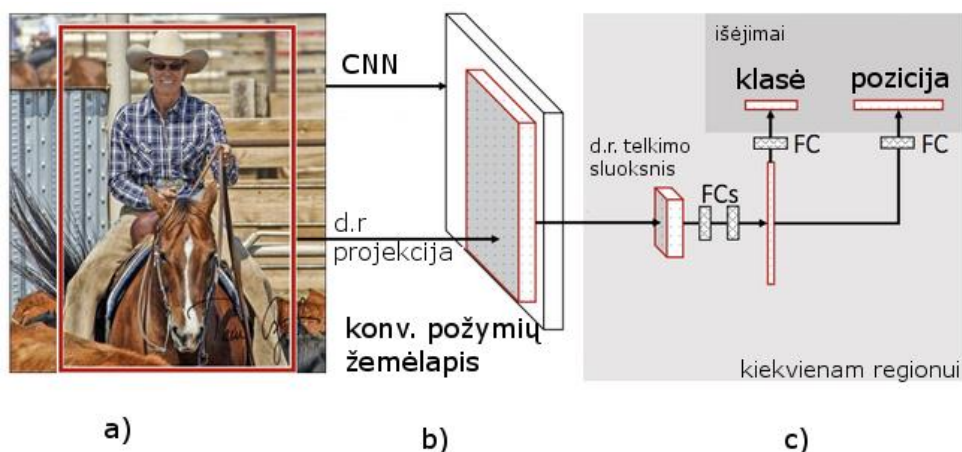
Šio metodo greitimeika buvo padidinta panaudojant erdviųjų piramidžių telkimo tinklus (angl. *SPPnets – Spatial pyramid pooling networks*) [21]. Nuotraukos apdorojimas bei objektų radimas laikas sumažėjo nuo 10 iki 100 kartų, o apmokymo laikas sumažėjo 3 kartus, tačiau naudojant šį

metodą tinklo apmokymo metu požymių žemėlapiam reikėjo labai daug kompiuterio atminties bei dėl *SSPnet* bruožų nebuvo galima lengvai derinti (angl. *fine tune*) neuroninio tinklo, pavyzdžiui permokant tik paskutinį sluoksnį. Šios problemos apribojo metodo tolesnį tikslumo tobulinimą. Šio metodo trūkumai buvo išspręsti *Fast R-CNN* metode.

1.5.6. *Fast R-CNN* metodas

Fast R-CNN metodas yra patobulinta *R-CNN* versija pristatyta 2015 metais. Šiuo metodu naudojant *VGG16* duomenų rinkinį apmokoma 9 kartus greičiau, o nuotraukų tikrinimas atliekamas 213 kartų greičiau nei taikant jo pirmtaką *R-CNN* metodą [21].

Fast R-CNN metode nuotrauka yra apdorojama panaudojant keletą paeiliui sujungtų sąsukos bei maksimalaus telkimo sluoksnių, tokių būdu gaunamas vienas sąsukos požymių žemėlapis. Šiame požymių žemėlapyje yra parenkami dominantys regionai, kurie yra apdorojami dominančių regionų telkimo sluoksniuose. Šiame sluoksnyje kiekvienas požymių regionas yra paverčiamas fiksuoto dydžio požymių vektoriumi, kurie yra apdorojami pilnai sujungtuose tinklo sluoksniuose. Apdorojus regioną pilnai sujungtu sluoksniu, sluoksnis šakojasi į du atskirus išėjimo sluoksnius: klasės nustatymo sluoksnį, kuriame yra panaudojant minkštojo maksimumo funkcija yra nustatoma objekto klasė, bei pozicijos nustatymo sluoksnį, kuriame nustatoma 4 objektą ribojančio stačiakampio taškų pozicijos. Metodo sutrumpintas veikimas pavaizduotas 11 pav.




11 pav. *Fast R-CNN* veikimas a) originali nuotrauka b) sąsukos požymių sudarymas
c) dominančių regionų klasifikavimas

Šis metodas pasižymi didesniu tikslumu nei *R-CNN* bei *SPPnet* metodai. Mokymosi metu yra apmokomi visi tinklo sluoksniai bei apmokymo metu nereikia daug vietos požymių žemėlapių saugojimui [FRCNN1]. Šis metodas yra apmokomas 18,3 karto greičiau nei *R-CNN* metodas bei 3,4 kartus greičiau nei *SPPnet* metodas. Objektų radimo greitis padidėjo 213 kartų palyginus su pirmtaku *R-CNN* metodu bei 20 kartų palyginus su *SSPnet* metodu, tačiau jis vis dar nebuvo tinkamas realaus laiko sistemoms. Šis metodas buvo dar kartą patobulintas 2016 metais mokslininkų Shaoqingo Reno bei Kaimingo Hu sukuriant *Faster R-CNN* metodą [22].


1.5.7. *Faster R-CNN* metodas

Faster R-CNN metode pasirinkimų paieškos metodas yra pakeičiamas papildomu regionų pasiūlymų tinklu (angl. *Region Proposal Network*). Šiame metode taip pat buvo pristatytas naujas regionų išskyrimo metodas, panaudojant kintantį slenkantį langą (angl. *anchor boxes*). Lango dydžių 3 daugikliai yra pasirenkami apmokymo metu, o kraštinių santykis kinta tarp 1:1, 1:2 ir 2:1, tokių būdu kiekvienoje vietoje yra sukuriami 9 regionai. Pavyzdžiui, bazinis lango dydis yra 16 x16 pikselių rezoliucijos, todėl yra sukuriami 3 skirtingo kraštinių santykio langai: 8x24 px, 16x16 px bei 24x8 px. Šie lango dydžiai yra sudauginami su pasirinktais 3 daugikliais, tokiu būdu yra gaunami 9 skirtingi langai. Regiono pavyzdys pavaizduotas 12 pav.



12 pav. 9 pasiūlomi regionai

Jei nuotrauka yra 800x600 pikselių rezoliucijos, o pasislinkimas yra kas 16 pikselių išvis gaunama 1989 pozicijos arba 17901 tikrinami regionai. Šie regionai yra apdorojami regionų pasiūlymų tinklu, toliau RPN. Šiame tinkle yra gaunamas nuotraukos požymių žemėlapis, kuriame nurodoma ar regionas gali būti ieškomas objektas ar tai yra fonas. Šiame etape klasifikacija yra nevykdoma. Supaprastinto regionų tinklo modelis pavaizduotas 13 pav.



13 pav. Regionų pasiūlymų tinklas, SS – sąsukos sluoksnis

RPN tinklo išėjimas yra požymių žemėlapis, kuris nurodo kiekvieno iš tiriamo regiono poziciją, plotį bei ilgį ir tikimybę būti objektu arba fonu. Pritaikius maksimumų atrinkimo funkciją yra paliekamas nurodytas regionų skaičius, kurie yra apdorojami dominančių regionų telkimo sluoksnyje. Šiame sluoksnyje skirtingų dydžių regionai yra paverčiami fiksuoto dydžio požymių vektoriais. Šie vektoriai galiausiai yra panaudojami *R-CNN* tinkle, kuriame yra nustatoma objekto klasė ir pozicija, o fono vaizdai atmetami. *R-CNN* tinkle yra panaudojami 2 pilnai sujungti sluoksniai, pirmas sluoksnis turini $N+1$ neuronų, kur N yra klasių skaičius su papildoma klase fonui, o antras yra $4N$ neuronų sluoksnis, kuris nurodo objekto poziciją bei dydį.

Faster R-CNN metodas yra 10 kartų greitesnis už pirmtaką *Fast R-CNN* metodą bei pasiekė didesnę tikslumą. *R-CNN* rūšies algoritmų greitaveikos ir tikslumo palyginimas pateiktas 1 lentelėje.

1 lentelė. R-CNN rūšies metodų palyginimas


Metodas	R-CNN	Fast R-CNN	Faster R-CNN
Paveikslo apdorojimo laikas	50s	2s	0,2s
Pagreitėjimas	1x	25x	250x
mAP, VOC2007	66 % [21]	66,9 % [21]	73,2 % [22]

Faster R-CNN metodas buvo naudojamas medicinoje polipų radimui tyrime metodas pasiekė 98,5 % radimo tikslumą [23]. Šis metodas taip pat buvo naudojamas automobilių ženklų emblemų lokalizacijai, kuri pasiekė 94.33 % vidutinį radimo tikslumą [24] bei metalo liejinių defektų radimui, kur pasiekė vidutinį 92,10 % radimo tikslumą [25].

1.6. Faster R-CNN tinklo architektūros

1.6.1. AlexNet architektūra

AlexNet neuroninio tinklo architektūra buvo pristatyta 2012 metais *ImageNet LSVRC-2012* konkurse, kuriame reikėjo suklasifikuoti 1,2 milijono nuotraukų į 1000 skirtingų klasių. Šioje architektūroje pirmą kartą įrodyta, kad telkimo sluoksniai neturi būti naudojami iš karto po sąsukos sluoksnių. Ši tinklą sudarė 11 sluoksnių, iš kurių yra 5 sąsukos sluoksniai bei 3 maksimalaus kaupimo sluoksniai [26]. Šio tinklo architektūra pavaizduota 14 pav, čia SS – sąsukos sluoksnis, MT – maksimalaus telkimo sluoksnis, PS – pilnai sujungtas sluoksnis, IŠ - išėjimas

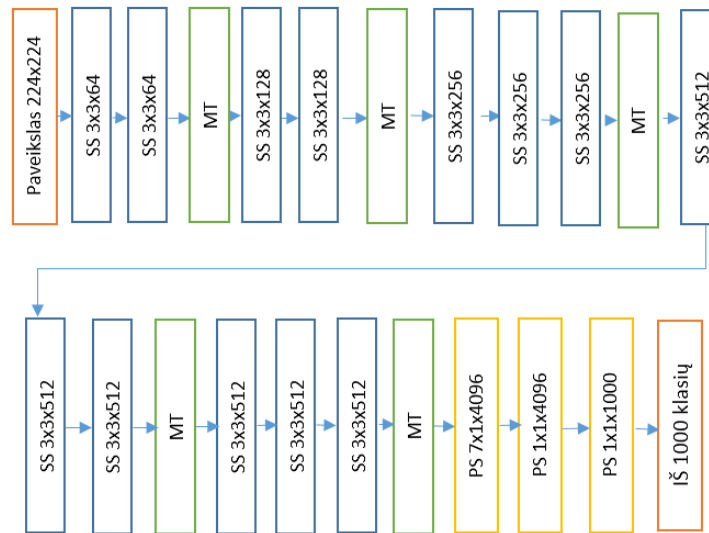


14 pav. AlexNet architektūra.

Tinklo įėjimas yra 224x224x3 pikselių dydžio vektorius, kuris atitinka paveikslo dydį, o tinklo išėjime gaunamas 1000 verčių vektorius, kuris nurodo klasę, kuriai buvo priskirtas objektas. Ši tinklo architektūra užėmė 1 vietą *ILSVRC-2012* konkurse ir pasiekė 15,3 % klaidos procentą, aplenkdamą antrą vietą daugiau nei 10 %.

1.6.2. VGG16 architektūra

VGG-16 architektūra buvo pristatyta 2014 metais bei tais pačiais metais *ImageNet Challenge 2014* užėmė pirmą bei antrą vietas objektų radimo bei klasifikacijos rungtyse. Ši tinklą sudaro 21 sluoksnis iš kurių 13 sluoksnių yra sąsukos sluoksniai, 5 maksimalaus telkimo bei 3 pilnai sujungti sluoksniai [27]. Šio tinklo ypatybė yra ta, kad visi sąsukos sluoksniai yra 3x3 pikselių dydžio. VGG16 architektūra pavaizduota 15 pav. Žymėjimas išlieka toks pats kaip ir AlexNet architektūroje.



15 pav. VGG16 architektūra

Šios architektūros įėjimas kaip ir *AlexNet* yra $224 \times 224 \times 3$ dydžio vektorius, o išėjimas yra 1000 verčių vektorius, kuris nurodo klasę, kuriai priskiriamas paveikslas. Ši architektūra užėmė 2 vietą ILSVRC-2014 konkurse ir pasiekė 8,8 % klaidos procentą.

1.7. Mokymo perkėlimo metodas

Mokymo perkėlimo metodas (angl. *transfer learning*) – tai neuroninio tinklo mokymosi metodas, kuomet yra panaudojamas jau apmokytas tinklo modelis panašaus uždavinio sprendimui, apmokant tik tam tikras apmokyto modelio dalis [28]. Šis metodas pirmą kartą buvo cituotas 1993 metais L.Y. Pratto, kuris pasiūlė pagreitinti mokymąsi panaudojant jau apmokytus neuroninio tinklo daugiklius, o ne mokyti iš pradžių su atsitiktinėmis reikšmėmis [29]. Dabartinėje rinkoje mokymo perkėlimo metodas yra dažnai naudojamas sąsukos tinklų apmokymui, norint pagreitinti neuroninio tinklo apmokymą arba esant per mažai turimai duomenų bazei. Nauji modeliai yra dažnai apmokomi pritaikant *ImageNet* ar *CIFAR10* duomenų rinkinius jau apmokytus modelius. *ImageNet* – tai viena didžiausių duomenų bazių skirtų neuroninių tinklų mokymuisi, ją sudaro 1,2 milijono paveikslų iš 1000 skirtingų klasių. Šiuo metu yra 2 pagrindiniai mokymo perkėlimo būdai.

Pirmasis būdas yra kuomet yra permokomas tik paskutinis sluoksnis, paliekant originalų modelį kaip būdingų požymių išskyrimo įrankį. Pavyzdžiui, naudojamas sąsukos tinklas apmokytas naudojant *ImageNet* duomenų bazę, kurio paskutinis pilnai sujungtas sluoksnis, nurodantis klasę yra pašalinamas, ir vietoje jo yra apmokomas naujas klasifikatorius, toks kaip atraminių vektorių mašina ar minkštojo maksimumo (angl. *softmax*) sluoksnis.

Antruoju būdu yra apmokomas ne tik paskutinis sluoksnis, tačiau tai pat apmokomi ir kiti pasirinkti sluoksniai [30]. Šis metodas vadinamas tinklo tobulinimo metodu (angl. *fine-tuning*). Pavyzdžiui, tokiu būdu permokomi iš naujo gali būti tik keli paskutiniai sluoksniai, kurie yra atsakingi už klasėms būdingų požymių išskyrimą. Pavyzdžiui, pirmieji sąsukos tinklo sluoksniai dažniausiai išskiria bendrinius požymius, tokius kaip kraštai ar kampai, o paskutiniai, būna prisitaikę prie tam tikrų klasėms būdingų požymių išskyrimo.

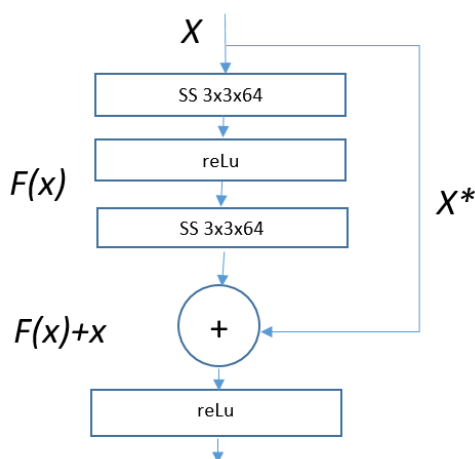
Mokymo perkėlimo metodas buvo panaudotas žarnyno polipų klasifikavimui [31], kuriame naudodamas bazinį MCN modelį metodas pasiekė bendrą klasifikavimo 89,74 % tikslumą. Paskutinio

sluoksnio permokymas taip pat buvo naudojamas krūtinės ląstos rentgeno nuotraukų klasifikavimui, kuriame naudodamas *ResNet50* modelį pasiekė 78,91 % pneumotorakso ligos nustatymo tikslumą[32].

Šiuo metu rinkoje yra keletas populiarių mokymo perkėlimui naudojamų modelių, tokių kaip: *AlexNet* modelis, *VGG* rūšies modeliai, *ResNet* rūšies modeliai bei *GoogLeNet/Inception* rūšies modeliai.

1.7.1. ResNet architektūra

ResNet – tai 2015 metais pristatytas likutinis tinklo modelis (angl. Residual Network) [33]. Šioje tinklo architektūroje yra išsprendžiama nykstančio gradiento (angl. vanishing gradient) problema. Ši problema atsiranda kuomet tinklas yra per gilus ir gradiento reikšmė po netekties (angl. loss) funkcijos mažėja, o vėlesniuose sluoksniuose ji tampa per maža, kad darytų įtaką sluoksnių daugikliams, tokiu būdu tinklas daugiau nebesimoko. *ResNet* architektūra išsprendžia šią problemą, sukurdamą papildomas jungtis tarp skirtingų sluoksnių, kuriuose gradientų informacija yra perduodama tiesiogiai praleidžiant tarpinius sluoksnius. ResNet supaprastinta sluoksnių jungtis pavaizduota 16 pav.



16 pav. ResNet jungtis


ResNet tinklo architektūra buvo išbandyta panaudojant 152 sluoksnius, tai yra 8 kartus giliau nei *VGG* architektūros tinklas[33]. Šios architektūros tinklas užėmė 1 vietą *ILSVRC* 2015 metų konkurse, kuriame šis tinklas pasiekė vidutinį 96,43 % tikslumą. Ši tinklo architektūra taip pat buvo panaudota kaip bazinis modelis *COCO* 2015 metų konkurse, kurioje užėmė 1 vietas objektų radimo, lokalizacijos bei segmentacijos rungtyse.

1.7.2. GoogleNet/Inception architektūra

GoogleNet arba *Inception* tinklo architektūros buvo pristatytos 2014 metais „Google“ komandos *ILSVRC14* konkurse[34]. Ši tinklo architektūra turi 22 neuroninius sluoksnius. Šio tinklo pagrindinės ypatybės buvo 1x1 dydžio sąsukos operacijos bei *Inception* modulis.

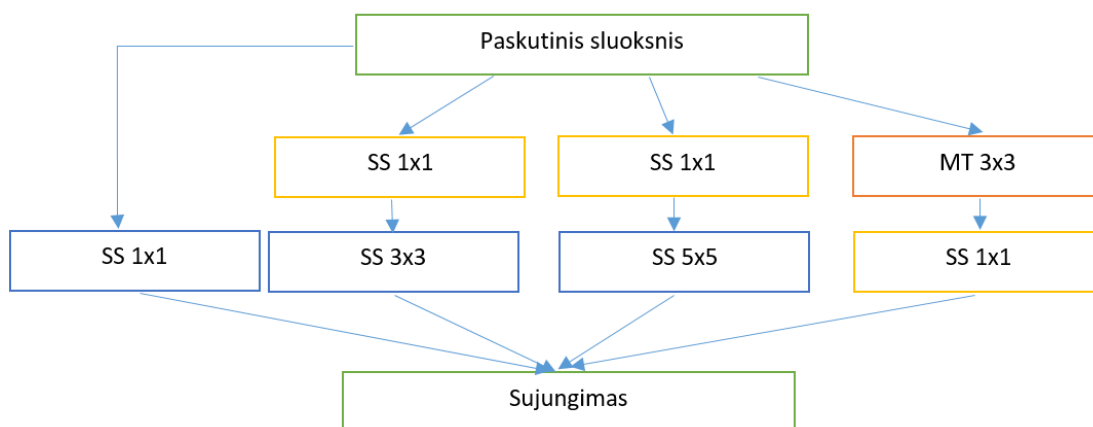
1x1 sąsukos operacijos pirmą kartą buvo pristatytos *NIN* (angl. *Network in network*) tinkle[35]. Tinklo tinkle metodas, toliau *NIN*, buvo panaudotas požymių išskyrimui vietoj tiesinių filtrų prieš klasifikavimą, tai padidino tinklo tikslumą. Taip pat *NIN* panaudotas vietoje maksimalaus tankinimo sluoksnių, vietoj kurių buvo sukuriami aktyvacijos sluoksniai, kurių kiekis yra proporcingas klasių

skaičiui. Pritaikius vidurkio operaciją bei minkštojo maksimumo sluoksnį yra gaunami klasių rezultatai. Šis *NIN* pritaikymas padidino metodo greitaveiką bei tikslumą. *NIN* metodas laikomas vienu iš *GoogleNet* sukūrimą įkvėpusių metodų [34]. *GoogleNet* architektūroje 1×1 sąsukos operacijos naudojamos dimensijų mažinimui. Dimensijų mažinimo pavyzdys pavaizduotas 17 pav.




17 pav. Dimensijų mažinimo pavyzdys

Antroji *GoogleNet* tinklo ypatybė yra *Inception* modulis. Šiame modulyje skirtingo dydžio sąsukos filtrų operacijos lygiagrečiai yra pritaikomos įėjimo sluoksniui bei sudedamos gaunant naują išėjimo požymių vektorių. *Inception* modulio diagrama pavaizduota 18 paveiksle.



18 pav. *Inception* modulis

Inception diagramoje geltonai pavaizduoti dimensijų mažinimo sluoksniai, raudonai pavaizduota maksimalaus telkimo sluoksnis, mėlynai – sąsukos operacijų sluoksniai. Sujungimo sluoksnyje visi rezultatai yra sujungiami į vieną požymių žemėlapi. Požymių žemėlapis pavaizduotas 19 pav. *R* reiškia tam tikro sluoksnio rezultatas, o *RM* – maksimalaus telkimo rezultatas.



19 pav. Rezultatas po sujungimo

Ši architektūra *ILSVRC* 2014 konkurse užėmė pirmą vietą, su 93,33 % klasifikavimo tikslumu bei pirmą gilaus apmokymo tinkle tikslumas kartą priartėjo prie 94,9 % žmogaus eksperto klasifikavimo

tikslumo. Ši architektūra buvo patobulinta 2015 metais sukuriant *Inception-v2* arba *BNInception* metodą.

BNInception metode buvo panaudotas mokymo partijos normalizavimas (angl. *batch normalization*, *BN*). Normalizavimas – tai partijos elementų vidurkio (angl. *mean*) bei pasiskirstymo (angl. *variance*) išlyginimas [36]. *BNInception* metode buvo pristatyta partijos normalizavimo transformacija, kuri panaudota ne tik įėjimo sluoksnyje, bet ir paslėptuose sluoksniuose, kur kiekviena duomenų partija naujoje iteracijoje yra pritaikoma prie išmoktų vidurkio ir pasiskirstymo reikšmių. Partijos normalizacijos transformacijos lygtys pateiktos 6 – 9 lygtyse.

$$\mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i ; \quad (6)$$

čia μ_B – partijos vidurkis, x_i – partijos elementas

$$\sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 ; \quad (7)$$

čia σ_B^2 – partijos pasiskirstymas

$$\hat{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} ; \quad (8)$$

čia \hat{x}_i – normalizuota vertė

$$y_i \leftarrow \gamma \hat{x}_i + \beta \equiv BN_{\gamma, \beta}(x_i) ; \quad (9)$$

čia y_i – visos partijos normalizavimas. γ ir β parametrai yra gaunami apmokymo metu.

Partijos normalizavimo transformacija suteikė galimybę apmokyti modelius su didesniu mokymo greičiu, dėl sumažinto pasiskirstymo bei ši transformacija taip pat sumažina persimokymą, kuomet modelis per daug prisitaiko prie apmokymo duomenų. *BNInception* architektūra naudodama ILSCRC 2015 duomenų rinkinį pasiekė 95,2 % klasifikavimo tikslumą, tai buvo geriausias 2015 metų rezultatas.

1.8. Esamų pramoninių kokybės patikros sistemų apžvalga

Rinkoje egzistuoja ne viena įmonė, kurianti bei diegianti kompiuterinės regos sistemas bei jutiklius pramonėje skirtus kokybės tikrinimui, tokios kaip *Omron*, *Cognex*, *Argos Solutions* bei *Grecon*.

1.8.1. „Omron“ vaizdo sistemos

„Omron“ – tai kompanija turinti platų automatikos produkcijos pasirinkimą, gaminanti įvairius daviklius, pavaras, variklių valdiklius, robotus bei vizualinės patikros sistemas. Pagrindinis šios kompanijos vizualinės patikros produktas tai FQ produktų linija: FQ2 bei FQ-M serijos.



20 pav. Omron FQ serijos kameros

Tai išmaniosios kameros, turinčios kamerą bei procesorių skirtą skaičiavimams viename korpuse, turinčiame IP67 atsparumo klasę. Šios kameros turi eterneto jungtį bei skaitmeninių įėjimų bei išėjimų jungtis. Šios kameros sugeba atlikti komponentų pozicijos patikrą, spalvos bei formos neatitikimų patikrą. Turi integruotą brūkšninių bei *QR* kodų skenavimo galimybes. Gali atlikti linijos storio matavimus. Šios kameros puikiai tinka nedidelių objektų bazinei kokybės patikrai. Taip pat, dėl didelio paruoštų programų ir funkcijų pasirinkimo suteikia galimybę jas programuoti bei įdiegti ir patirties neturintiems vartotojams.

1.8.2. „Argos Solutions“ kokybės tikrinimo sistemos

„Argos Solutions“ tai Norvegijos kompanija besispecializuojanti visų tipų paviršiaus defektų kokybės analizėje. Ši kompanija dirba su faneros, laminuotų medžio drožlių plokščių bei gipso kartono plokščių paviršiaus bei kraštų kokybės tikrinimo sistemomis. Ši kompanija savo sistemas yra integravus daugiau nei 200 kokybės tikrinimo sistemų 30 pasaulio šalių.



21 pav. „Argos Solutions“ faneros kokybės tikrinimo sistema

Šios kompanijos skeneriai naudodami naujausias technologijas sukuria dvimatį bei trimatį detalės vaizdą, taip patikrindami ne tik dvimačius defektus, tokius kaip spalvos netolygumas, tačiau ir giluminius, tokius kaip įbrėžimai bei įspaudai. Šiose sistemose yra integruotas automatinis kalibravimas bei naujų detalių apsimokymas. Tai sistema puikiai tinkanti medienos, metalo ar gipso pramonėje.

Rinkoje yra daug skirtingų metodų vizualinei kokybės analizei tirti, tačiau visi turi savo trūkumų bei privalumų, šiame darbe yra tiriamas *Faster R-CNN* metodo panaudojimas medienos lukšto kokybei vertinti. Kitame skyriuje yra aprašoma tyrimo metodologija, duomenų bazė bei tetavimo įranga.

2. Metodologija

Šiame baigiamajame darbe medienos lukšto defektų radimui buvo pasirinktas naudoti *Faster R-CNN* metodas, aprašytas 1.5.7 skyriuje. Šiame skyriuje aprašoma naudojama techninė bei programinė įranga nuotraukų gavimui, gilaus apmokymo tinklo kūrimui. Taip pat aprašoma surinkta duomenų bazė bei metodo tikslumo vertinimo kriterijai.

2.1. Naudojamų technologijų analizė

Šiuo metu populiariausios defektų radimo sistemos susideda iš linijinių kamerų, impulsinio enkoderio bei linijinio apšvietimo[22]. Mūsų metodo testavimui buvo pasirinkta tokia pati sistema.

2.1.1. Duomenų rinkimo stendas

Duomenų rinkimui buvo pagamintas specialus juostinis transporteris. Šis transporteris pavaizduotas 22 pav.



22 pav. Duomenų rinkimo stendas

Transporteris geba išvystyti iki 1 m/s greitį. Transporterio juostos ilgis – 1 m, plotis - 30 cm. Atstumas tarp kameros objektyvo ir tiriamojo objekto – 30 cm. Šviestuvai įmontuoti 10 cm aukštyje. Šviestuvai įmontuoti 20 laipsnių kampu su tiriamuoju objektu. Vaizdai gauti naudojama linijinė kamera.

2.1.2. Linijinės kameros

Linijinės kameros (angl. *line scan*) veikia fotografuodamos tik vieną pikselių juostą (pavyzdžiui: 2048x1 px. rezoliucijos), priešingai negu regiono (angl. *area*) tipo kameros[37]. Linijinės kameros gali fotografuoti kur kas didesnes vertikalios rezoliucijos nuotraukas negu regiono tipo kameros, tačiau šioms kameroms yra reikalingas judantis vaizdas. Jos puikiai tinka judančio vaizdo fiksavimui, priešingai negu regiono tipo kameros, kurios kur kas labiau tinka stovinčio vaizdo fiksavimui.

2.1.3. Basler raL4096-24gm kamera

Šiam projektui buvo pasirinkta Basler raL4096-24gm kamera, pavaizduota 23 pav. Ši kamera pasižymi 26 kHz linijos fiksavimo greitaveika bei 4096 taškų horizontalia rezoliucija.



23 pav. Basler raL4096-24gm kamera

Šios kameros rezoliucijos ir greitaveikos pakanka norint fiksuoti medžio lukštą, judantį 4 m/s greičiu išlaikant 0,25mm²/px rezoliucija. Pagrindiniai šios kameros parametrai pateikti 2 lentelėje.

2 lentelė. Kameros parametrai

Modelis	Basler raL4096-24gm
Matmenys	36 mm x 56 mm x 62 mm
Tipas	Monochromatinė
Linijos fiksavimo dažnis	26kHz
Rezoliucija (px)	4096 x 1
Sensorius	Awaiba DR-4k-7
Protokolas	GigE

2.1.4. Impulsinis enkoderis

Kameros fotografavimas sinchronizuojamas su judančiu konvejeriu naudojant impulsinį LIKA CK59-Y-500ZCZ214R impulsinį enkoderį, pavaizduotą 24 pav.



24 pav. LIKA enkoderis

Pagrindiniai šio enkoderio parametrai pateikti 3 lentelėje.

3 lentelė. Enkoderio parametrai

Modelis	CK59-Y-500ZCZ214R
Rezoliucija	500
Maksimalus dažnis	100 kHz
Maitinimas	10-30V
Ašies diametras	14 mm

2.1.5. Programinė įranga


Šiam projektui įgyvendinti buvo naudojama *Python* ir *C#* programavimo kalbos. Darbui su neuroniniais tinklais buvo naudojamas *Microsoft CNTK* paketas 2.6 versija. Visi skaičiavimai buvo atlikti naudojant kompiuterį, kurio parametrai Intel I7-7700 3,6 Ghz 4 branduolių procesorius, 16 Gb GDDR5 darbinės atminties bei 2 vienetai GTX 1060 6GB vaizdo plokščių. Duomenims saugoti kompiuteryje buvo naudojamas SSD diskas

Microsoft Cognitive Toolkit, toliau *CNTK*– tai atviro kodo gilaus apmokymo įrankis pristatytas 2016 sausio 25 dieną[38]. Šiame įrankyje neuroniniai tinklai apibūdinami kaip skaičiavimų sekos surašytos orientuotuose grafuose. *CNTK* paketas leidžia naudoti esamus bei tobulinti tokius gilaus apmokymo tinklus tokius kaip sąsukos neuroninius tinklus bei pasikartojančius neuroninius tinklus (*RNN*, *LSTM*) (angl. *recurrent neural networks*). Šis paketas palaiko stochastinį gradientų nusileidimą bei atgalinį klaidos stebėjimą (angl. *error backpropagation*) keliem vaizdo apdorojimo procesoriam vienu metu, tokiu būdu sukurdamas galimybę naudoti lygiagrečiai kelias vaizdo plokštes ar serverius.

CNTK gali būti naudojamas *Python*, *C#* bei *C++* kalbomis. Modelių tikrinimas taip pat gali būti naudojamas Java programavimo kalbos aplinkoje. Šis neuroninių tinklų paketas veikia 64 bitų Windows bei Linux operacinėse sistemose.


2.2. Duomenų bazė

Apmokymui ir testavimui buvo nuskenuoti 250 lukšto bandiniai, kurių dydis apie 300mm x 300mm. Lukštas buvo skenuojamas 4000x3000 pikselių rezoliucija nespalvotomis, vieno kanalo nuotraukomis naudojant anksčiau aprašytą bandymų stendą. Iš viso buvo gautos 353 lukšto nuotraukos. Gautos lukšto nuotraukos pavaizduotos 25 pav.



25 pav. Lukšto nuotraukų pavyzdžiai, a) be defektų, b) matomas branduolys, c) matomos šakos

Duomenų bazės nuotraukos buvo sumažintos iki 800x600 pikselių rezoliucijos, norint pagreitinti neuroninio tinklo apmokymo greitį. Šis dydis buvo pasirinktas dėl optimalios kokybės bei greitaveikos. Mažinant nuotraukos dydį mažėja smulkių objektų, tokių kaip skilimai ar įbrėžimai matomumas. Nuotraukos fragmento dydžio mažėjimas su įbrėžimo defektu pavaizduotas 26 pav.




26 pav. Nuotraukos rezoliucijos įtaka įbrėžimo defektui, a) originalus fragmentas, b) 5 kartus sumažintas nuotraukos fragmentas, c) 10 kartų sumažintas nuotraukos fragmentas

26 paveikslo a dalyje, originalioje nuotraukoje, kurios rezoliucija yra 4000x3000 įbrėžimas yra aiškiai matomas bei išsiskiria iš medžio tekstūros. 26 paveikslo b dalyje fragmento rezoliucija yra sumažinta 5 kartus nuo originalios ir yra 800x600 pikselių, tačiau įbrėžimas yra matomas bei išsiskiria iš foninio vaizdo. 26 paveikslo c dalyje nuotrauka yra sumažinta 10 kartų iki 400x300 pikselių rezoliucijos, įbrėžimo kontūrai yra blogai matomi ir beveik nesiskiria nuo medžio tekstūros.

Šiame darbe buvo išskirti 4 pagrindiniai medienos lukšto defektai:


- šakos – tai vietos, kuriose matomos medžio šakos;
- įbrėžimai/skilimai – tai vietos, kuriose matomi įtrūkimai, skilimai ar įbrėžimai;
- branduolys – tai vietos, kuriose matoma medžio šerdis arba žievė;
- dėmė – tai vandens ar pigmentacijos sukeltos dėmės.

Defektų pavyzdžiai pateikiami 27 paveiksle.



27 pav. Defektų pavyzdžiai, a) skilimas, b) branduolys, c) šaka, d) dėmė

Medienos lukšto nuotraukos buvo klasifikuojamos ir žymimos *VoTT* (angl. *Visual Object Tagging Tool*) programa, skirta nuotraukoms žymėti ir rūšiuoti gilaus apmokymo tinklams. Šioje programoje yra pažymimi ieškomi objektai: dydis, pozicija bei klasė, kuriai jis yra priskiriamas. *VoTT* programa pažymėta nuotrauka pavaizduota 28 pav.

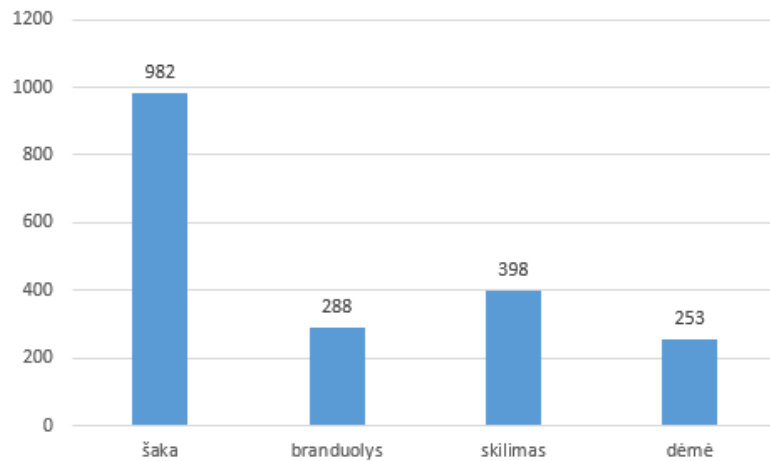


28 pav. *VoTT* programa sužymėta nuotrauka. Žalia spalva pažymėtos šakos, mėlyna – skilimai, geltona – dėmės

Duomenų bazė yra paruošiama *CNTK* paketui, gaunamos trys direktorijos:

- neigiami pavyzdžiai – tai nuotraukos, kuriose nėra defektų, naudojamos apmokymo metu;
- teigiami pavyzdžiai – tai nuotraukos, kuriose yra bent vienas defektas, naudojamos apmokymo metu;
- testavimas – tai nuotraukos, naudojamos tik modelio tikslumo patikrinimui.


Faster R-CNN defektų radimo metodo apmokymui naudojama 291 nuotrauka, iš kurių 6 be defektų, o 285 – turi bent vieną defektą. Modelio testavimui naudojamos 62 nuotraukos. Modelis yra apmokomas naudojant 82,38 % duomenų bazės, o testuojamas naudojant – 17,62 % duomenų bazės. Defektų regionų pasiskirstymas duomenų bazėje pavaizduotas 29 pav.



29 pav. Defektų regionų kiekis duomenų bazėje

2.2.1. Duomenų bazės praplėtimas sintetiniais duomenimis

Duomenų bazės sintetinis arba didinimas yra dažnai naudojamas neuroninių tinklų tikslumo didinimui bei prisitaikymui. J. Wango bei L. Perez'o aprašytame tyrime panaudojus geometrinės transformacijos klasifikatoriaus tikslumas padidėjo nuo 4 % iki 10 % klasifikuojant skirtingas klases[39]. L. Tayloro bei G. Nitschke'o tyrime duomenų vien bazės apkarpymas taip ją padidinant pagerino klasifikatoriaus tikslumą 13,82 % [40]. Šiame darbe pritaikytos 3 skirtingos geometrinės transformacijos duomenų bazės didinti: veidrodinis apskukimas (angl. *flip*), posūkio transformacija bei dydžio transformacija. Kiekvienai iš 291 apmokymui skirtos nuotraukos buvo sukurtos 4 atsitiktinės sintetinės nuotraukos. Susintetintos nuotraukos pavyzdys pateiktas 30 pav.



30 pav. Duomenų bazės sintetinio pavyzdys, a) – originali nuotrauka, b), c) d) nuotraukos gautos sintetinant duomenų bazę.

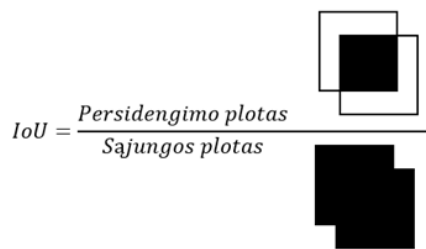
2.3. Metodo tikslumo vertinimas

Tiriamąjį metodą patikimumas buvo vertinamas dviem skirtingais būdais, objektų radimo tikslumu bei rūšies nustatymo tikslumu.

2.3.1. Defektų pozicijos radimo tikslumo nustatymas

Defektų radimo tikslumas nustatomas sankirtos ir sąjungos (angl. *intersection over union*) parametru IoU, kuris apibrėžia realios (angl. *ground truth*) pozicijos bei rastos pozicijos sankirtos ir sąjungos santykį. Šis parametras dar vadinamas Džakardo indeksu (angl. *Jaccard index*) pavadintas

mokslininko Paulo Džakardo vardu, parametą aprašiusio 20 a. pradžioje. Šio koeficiento supaprastintas skaičiavimas pateiktas 31 paveiksle.



$$IoU = \frac{\text{Persidengimo plotas}}{\text{Sajungos plotas}}$$

31 pav. *IoU* parametro skaičiavimas

Dažniausiai objektas patvirtinamas kaip rastas, kai *IoU* yra lygu arba daugiau negu 0,5. Šiame tiriamajame darbe tikslumas buvo skaičiuojamas naudojant tikrų teigiamų (angl. *true positive*) TP bei klaidingų teigiamų (angl. *false positive*) FP ir tikrų teigiamų sumos santykį. Radimo tikslumo formulė pavaizduota 10 lygtyje.

$$\text{tikslumas} = \frac{TP}{TP+FP} ; \quad (10)$$

čia TP – tai rasti objektai, kurių *IoU* didesnis nei užduotas slenkstis, FP – tai nerasti objektai, kurių *IoU* mažesnis negu užduotas slenkstis.

Kiekvienai iš 4 klasių yra skaičiuojamas vidutinis tikslumas - *AP* (angl. *average precision*) visam testavimo duomenų rinkiniui. Tai parametras, nusakantis kaip tiksliai metodas nustatė objekto poziciją bei klasę.

2.3.2. Rūšies nustatymo tikslumas

Nustačius defektų rūšis bei jų pozicijas, nuotraukos yra klasifikuojamos į rūšis pagal parametrus pateiktus 4 lentelėje.

4 lentelė. Defektų rūšies vertinimo lentelė

Rūšis	Šakos dydis, px ²	Šakų kiekis	Leidžiamas branduolio plotas, px ²	Leidžiamas įtrūkimo plotas, px ²	Leidžiamas įtrūkimų kiekis	Leidžiamas dėmių plotas, px ²
A/B	6300	6	0	2100	3	0
E	4200	6	0	12000	3	0
C	16000	neribojama	10 % paviršiaus	12000	8	5 % paviršiaus
D	90000	neribojama	neribojama	12000	8	20 % paviršiaus
G	neribojama	neribojama	neribojama	neribojama	neribojama	neribojama

Tiriamo metodo nustatyta rūšis bei tikroji rūšis yra palyginama ir nustatoma ar metodas teisingai nustatė rūšį. Metodo nustatymo tikslumas skaičiuojamas visam duomenų rinkiniui ir gaunamas pagal formulę:

$$\text{tikslumas} = \frac{\text{teisingai nustatyta rūšies nuotraukų skaičius}}{(\text{teisingai} + \text{neteisingai}) \text{ nustatytos rūšių nuotraukų skaičius}} ; \quad (11)$$


3. Eksperimentiniai tyrimai

Faster R-CNN metodas realizuojamas *CNTK* pakete. Metodo apmokymas vykdomas naudojant *Python* programavimo kalbą, modelio tikslumo testavimas vykdomas *C#* programavimo kalboje. Atlikome šiuos *Faster R-CNN* metodo tyrimus:

- originalios ir praplėtos sintetiniai duomenimis duomenų bazės įtaka metodo tikslumui;
- mokymo epochų skaičiaus (angl. *epoch count*) įtaka algoritmo tikslumui;
- skirtingos tinklo architektūros įtaka metodo tikslumui bei greitimeikai;
- pasiūlytų regionų (angl. *proposal count*) skaičiaus kitimo mokymo metu įtaka algoritmo tikslumui;
- pasiūlytų regionų dydžių (angl. *anchor boxes*) kitimo įtaka algoritmo tikslumui;
- pasiūlytų regionų skaičiaus testavimo metu įtaka algoritmo tikslumui bei greitimeikai;
- skirtingų mokymo perdavimo būdu apmokytų klasifikatorių tikslumo bei greitimeikos tyrimai;
- vienos rūšies defekto radimo tikslumo tyrimas;
- metodo su papildomu klasifikatoriumi tikslumo bei greitimeikos tyrimas.

Visi bandymų rezultatai buvo gauti testuojant su 68 skirtingomis nuotraukomis pagal X skyriuje aprašytus vertinimo metodus. Persidengusių objektų panaikinimui buvo naudojamas maksimumų atrinkimas pagal persidengimo plotą bei tikrinama metodo pasitikėjimo vertė. Maksimumų filtravimo metu buvo paliekami tik daugiau nei 60 % pasitikėjimo turintys rezultatai, kurių persidengimas su kitais objektais neviršijo 10 %. Objektas pažymimas kaip rastas jei jo *IoU* yra daugiau nei 0,5 su tikrąją pozicija.

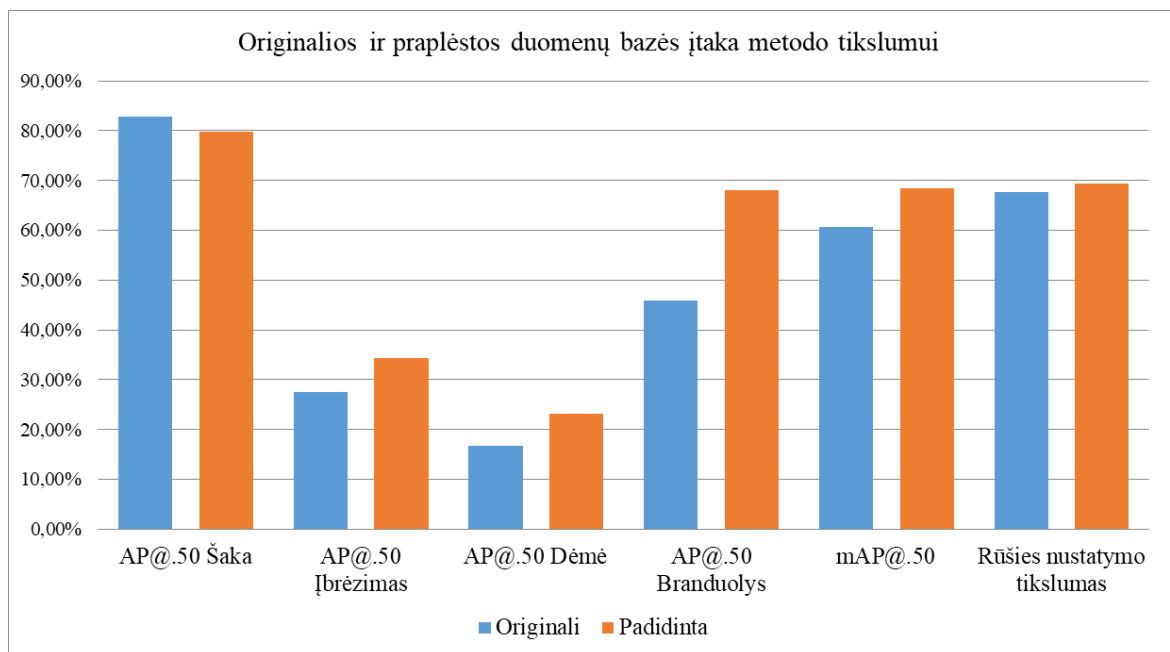
Pirmieji *Faster R-CNN* metodo lukšto bandymo rezultatai pavaizduoti 32 paveiksle. Žalia spalva pažymėtos šakos, mėlyna – skilimai, violetine – branduolys, geltona – vandens dėmės.



32 pav. Pirmieji *Faster R-CNN* bandymai

3.1. Originalios ir praplėtos sintetiniai duomenimis duomenų bazės įtaka metodo tikslumui

Buvo atliktas eksperimentas, kuriuo vertinome kaip metodo tikslumas priklauso nuo duomenų bazės dydžio, kuris yra padidintas sintetiniu būdu. Kiekvienai iš apmokymui skirtų nuotraukų buvo sukurtos 4 atsitiktinės sintetinės nuotraukos, tokiu būdu duomenų bazė buvo padidinta 4 kartus. Eksperimento rezultatai pateikti 33 paveiksle.



33 pav. Originalios ir praplėtos sintetiniai duomenimis duomenų bazių įtaka metodo tikslumui

Naudojant padidintą duomenų bazę, rūšies nustatymo tikslumas padidėjo nuo 67,74 % iki 69,35 % arba 1.02 karto. Bendras metodo defektų radimo tikslumas visose klasėse padidėjo 1,13 karto nuo 60,59 % iki 68,36 %.

Defektų radimo tikslumas taip pat padidėjo visose klasėse išskyrus šakų. Šakų radimo tikslumas sumažėjo 3,91 % nuo 82,84 % iki 79,72 %. Duomenų bazės praplėtimas sintetiniais duomenimis didžiausią įtaką turėjo branduolio radimui, kur tikslumas padidėjo 1,48 karto nuo 45,83% iki 68 %. Dėmių radimo tikslumas atitinkamai padidėjo 1,38 karto nuo 16,67 % iki 23,08 %. Duomenų bazės praplėtimas mažiausią įtaką padarė įbrėžimų klasei, įbrėžimų radimo tikslumas padidėjo 1,24 kartus nuo 27,59 % iki 34,38 %.

Duomenų bazę padidinus 5 kartus metodo mokymosi laikas atitinkamai taip pat padidėjo 5 kartus, nuo vidutiniškai 40 sekundžių vienai epochai iki 204 sekundžių vienai epochai. Nuotraukos patikrinimo laikas nekito ir buvo pastovus. Nuotrauka buvo patikrinama per vidutiniškai 600 milisekundžių naudojant *AlexNet* bazinį modelį su skirtingomis duomenų bazėmis. Grafiko skaitinės reikšmės su pasikliautinumo intervalais pateiktos 1 priede.


3.2. Skirtingo epochų skaičiaus įtaka metodo tikslumui

Faster R-CNN metodas buvo apmokytas su dviem skirtingomis tinklo architektūromis bei 7 skirtingais mokymo epochų kiekiais. Šiam tyrimui buvo pasirinktos *AlexNet* bei *VGG16* neuroninių tinklų architektūros. Eksperimentą atlikome su šiais epochų kiekiais: 1, 5, 20, 50, 100, 200 bei 500. Buvo atlikta 14 mokymų, po 7 kiekvienai skirtingai tinklo architektūrai. Šiame tyrime visi kiti tinklo parametrai buvo pastovūs ir nekito viso bandymo metu. Pagrindiniai tinklo parametrai pateikti 5 lentelėje. Paryškinti yra šiame eksperimente keičiami parametrai.

5 lentelė. Antro eksperimento metodo parametrai

Parametras	Reikšmė
Tinklo architektūra	[<i>AlexNet</i> ; <i>VGG16</i>]
Epochų skaičius	[1; 5; 20; 50; 100; 200; 500]
Slenkančio lango dydis	[4;8;12]
Slenkančio lango pasislinkimas	16
Mokymosi grietis	1
Po NMS likusių klasifikuojamų regionų kiekis apmokymo metu	200

Apmokytas metodas buvo testuojamas su testavimo duomenų baze. Pirmiausiai buvo atliktas *Faster R-CNN* metodo apmokymas naudojant *AlexNet* tinklo architektūrą. Bandymo rezultatai pateikti 34 pav.



34 pav. AlexNet architektūros pagrindu apmokyto metodo defektų radimo tikslumo bei lukšto rūšies nustatymo tikslumo bandymai

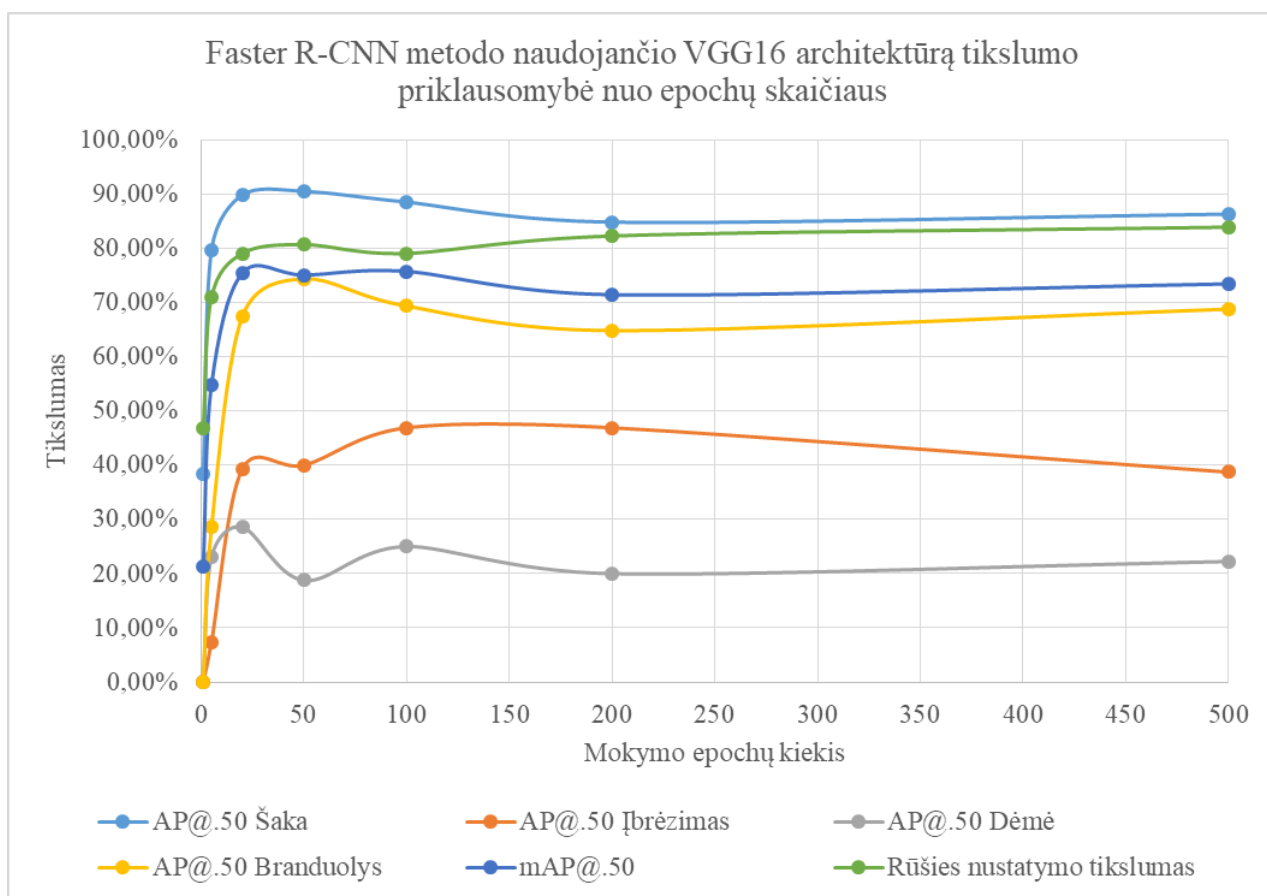
AlexNet tinklo architektūra naudojantis *Faster R-CNN* metodas didžiausią rūšies nustatymo tikslumą pasiekė ties 500 iteracijų riba, ir buvo 75,87 %. Metodas didžiausią bendrą defektų radimo tikslumą pasiekė ties 20 epochų riba, ir buvo 73,16 %.

Didžiausias šakų klasės radimo tikslumas buvo nustatytas ties 20 epochų riba bei buvo 88,27 %. Metodas didžiausią branduolio radimo tikslumą pasiekė taip pat ties 500 epochų riba, kuris buvo 80,56 %. Įbrėžimų radimo didžiausias tikslumas buvo pasiektas ties 50 epochų riba bei siekė 44,83 %. Dėmių klasės radimo tikslumas buvo mažiausias viso bandymo metu, maksimalią 26,67 % radimo tikslumo reikšmę pasiekęs ties 100 epochų riba.

AlexNet architektūros pagrindu apmokyto modelio optimalus epochų kiekis yra 20, ties šia riba bendras visų klasių pozicijų nustatymo tikslumas buvo maksimalus ir buvo lygus 73,16 %, rūšies nustatymo tikslumas lygus 70,97 %, o modelio apmokymo laikas buvo 1 valanda ir 8 minutės. Šis epochų skaičius buvo pasirinktas tolesniuose bandymuose dėl optimalaus kokybės ir apmokymo santykio.

Intervale nuo 50 iki 500 epochų yra matomas visų klasių radimo tikslumo augimo mažėjimas. Šiai tendencijai įtaką daro neuroninio tinklo „persimokymas“ (angl. overfitting), kuomet modelis prisitaiko prie apmokymui skirtos duomenų bazės. Grafiko skaitinės reikšmės su pasikliautinumo intervalais pateiktos 1 priede.

Buvo atliktas *Faster R-CNN* metodo apmokymas naudojant *VGG16* architektūrą bei iširtas metodo tikslumo priklausomybė nuo mokymo iteracijų skaičiaus. Tyrimo rezultatai pavaizduoti 35 pav.



35 pav. *VGG16* architektūros pagrindu apmokyto metodo tikslumo priklausomybė nuo epochų skaičiaus

VGG16 architektūros pagrindu apmokytas *Faster R-CNN* metodas didžiausią rūšies nustatymo tikslumą pasiekė ties 500 iteracijų riba, kuris buvo 83,87 %.


Bendras objektų radimo tikslumas maksimalus pasiektas buvo 75,72 % ties 100 epochų riba.

Maksimalus šakų radimo tikslumas yra 90,50 % buvo pasiektas ties 50 epochų riba. Metodas didžiausią branduolio radimo tikslumą pasiekė ties 50 epochų riba, ir buvo lygus 74,36 %. Dėmių radimo tikslumas didžiausias buvo ties 20 epochų riba ir buvo lygus 28,57 %. Įbrėžimų radimo maksimalus tikslumas buvo pasiektas ties 100 epochų riba bei buvo lygus 46,88 %.

Optimalus *VGG16* pagrindu apmokyto metodo epochų kiekis yra 20 epochų. Ties šia riba metodas pasiekė 75,40 % bendrą defektų radimo tikslumą, kuris yra 0,4 % mažesnis už maksimalų pasiektą 75,72 % tikslumą, tačiau yra apmokomas 5 kartus greičiau. *Faster R-CNN* metodu apmokyti 20 epochų užtruko 2 valandas ir 25 minutes. Ties 20 epochų riba metodas pasiekė 79,03 % rūšies nustatymo tikslumą. Grafiko skaitinės reikšmės su pasikliautinimo intervalais pateiktos 1 priede.

3.3. Skirtingų tinklo architektūrų įtaka metodo tikslumui

Buvo atliktas optimalių *AlexNet* bei *VGG16* architektūromis apmokytų *Faster R-CNN* metodų palyginimas. Palyginimo rezultatai pateikti 36 pav.



36 pav. AlexNet ir VGG16 architektūrų su optimaliais epochų skaičiais palyginimas

Abiejuose modeliuose su skirtingomis architektūromis geriausiai buvo randamos šakos. Šakų radime VGG16 architektūrą naudojantis metodas veikė 1,01 karto geriau nei AlexNet. AlexNet pasiekė 88,27 % šakų radimo tikslumą, o VGG16 - 89,80 %. Branduolys buvo randamas 1,03 karto geriau naudojant VGG16 architektūrą su kuria metodas pasiekė 67,39 % branduolio pozicijos radimo tikslumą, AlexNet – 65,38 %. Įbrėžimai abiejuose modeliuose buvo aptinkami vidutiniškai, AlexNet pasiekė 36,67 % tikslumą, o VGG16 - 39,29 % tikslumą. Abiejuose modeliuose blogiausiai buvo randami dėmių defektai, VGG16 naudojantis metodas juos rado su 28,43 % tikslumu, o AlexNet – 25 %.

Rūšies nustatyme didesnę tikslumą pasiekė VGG16 architektūrą naudojantis metodas, kuris 11 % geriau nustatė medienos lukšto rūšį, VGG16 metodas pasiekė 79,03 % tikslumą, o AlexNet – 70,97 %.

Taip pat buvo atliktas AlexNet bei VGG16 architektūras naudojančių metodų greitaveikos bei apmokymo laiko palyginimas. Bandyto rezultatai pateikti 6 lentelėje.

6 lentelė. Skirtingų tinklo architektūrų mokymo trukmės bei testavimo greitaveikos palyginimas

Tinklo architektūra	1 epochos apmokymo laikas (s)	1 epochos apmokymo laiko pasikliautinumo intervalas (s)	Nuotraukos įvertinimo laikas (s)	Nuotraukos įvertinimo laiko pasikliautinumo intervalas (s)
AlexNet	204	[198; 210]	0,6	[0,52; 0,68]
VGG16	438	[420; 456]	2,7	[2,45; 2,95]

AlexNet architektūros pagrindu apmokytas modelis vieną nuotrauką apdorodavo ir defektus rasdavo per vidutiniškai 600 ms, 95 proc. PI (520 - 680) ms, o *VGG16* per 2,7 s., 95 proc. PI (2,45 - 2,95)s. *VGG16* architektūros pagrindą naudojantis *Faster R-CNN* metodas yra 4,5 kartus lėtesnis nei *AlexNet* architektūra apmokytas metodas.

Vienos iteracijos tinklo apmokymo laikas naudojant *AlexNet* architektūrą yra 204 sekundės, o *VGG16* – 438 sekundės. Naudojant *VGG16* architektūrą tinklas yra apmokomas 2,68 kartus lėčiau nei *AlexNet*.

Apibendrinant, *VGG16* metodas nors ir pasiekė didesnę defektų pozicijų nustatymo tikslumą bei rūšies nustatymo tikslumą, tačiau šią architektūrą naudojantis metodas buvo 4,5 kartus lėtesnis nuotraukos įvertinimo metu nei *AlexNet* ir yra netinkamas realaus laiko sistemomis, dėl šios priežasties tolesni tikslumo didinimo bei greitaveikos bandymai buvo atliekami su *AlexNet* tinklo architektūra.


3.4. Skirtingo atrinktų regionų kiekio naudojant maksimumų atrinkimą mokymo metu įtaka metodo tikslumui

Šiam tyrimui buvo pasirinkta *AlexNet* neuroninio tinklo architektūra. Eksperimentas buvo atliktas su šiais regionų pasiūlymų kiekiais: 20, 50, 100, 200, 500, 1000 bei 2000. Šiame tyrime visi kiti tinklo parametrai buvo pastovūs ir nekito viso bandymo metu. Pagrindiniai tinklo parametrai pateikti 7 lentelėje. Paryškinti yra šiame eksperimente keičiami parametrai.

7 lentelė. Ketvirto eksperimento metodo parametrai

Parametras	Reikšmė
Tinklo architektūra	<i>AlexNet</i>
Iteracijų skaičius	20
Slenkančio lango dydis	[4;8;12]
Slenkančio lango pasislinkimas	16
Mokymosi grietis	1
Po NMS likusių klasifikuojamų regionų kiekis apmokymo metu	[20; 50; 100, 200; 500; 1000; 2000]

Apmokius metodą su skirtingais regionų kiekiais atlikome bandymus. Gauti rezultatai pateikti 37 paveiksle.



37 pav. Atrinktų regionų kiekio kitimo įtaka metodo tikslumui

Didžiausiais bendras defektų radimo tikslumas buvo pasiektas ties 500 regionų riba bei buvo lygus 76,69 %. Didžiausiais metodo rūšies nustatymo tikslumas buvo pasiektas apmokius tinklą naudojant 2000 atrinktų regionų kiekį – 77,42 %, o pasikliautinumo intervalas su 95 % tikimybe yra lygus [67,01 – 87,83 %]. Geriausiai eksperimento metu buvo randama šakų klasė, kurios radimo tikslumas prie 500 atrinktų regionų ribos yra 90,50 %.

Atrinktų regionų kiekiui kintant intervale nuo 20 iki 500 matomas bendro metodo tikslumo augimas. Metodo bendras tikslumas šiame intervale padidėjo 2,06 karto, nuo 37,19 % iki 76,69 %. Didžiausią įtaką regionų kiekio didėjimas turėjo įbrėžimų bei dėmių radimo tikslumui. Įbrėžimo klasės radimo tikslumas padidėjo 2,13 kartus nuo 18,37 % iki 39,29 % intervale tarp 20 ir 500 atrinktų regionų. Dėmės buvo geriausiai randamos prie 500 atrinktų regionų ribos, ties šia riba dėmių radimo tikslumas buvo 30,77 % bei padidėjo 7,37 kartus nuo pradinės 20 atrinktų regionų ribos. Tikslios tikslumo bei pasikliautinumo intervalo skaitinės reikšmės yra pateiktos 1 priede.

3.5. Regionų išskyrimo tinklo slenkančio lango dydžio kitimo įtaka metodo tikslumui

Faster R-CNN metodo neuroninis tinklas buvo apmokytas su skirtingomis slenkančio lango dydžių imtimis. Visi metodo pagrindiniai parametrai bei langų daugikliai pavaizduoti 8 lentelėje.

8 lentelė. Penkto eksperimento metodo parametrai

Parametras	Reikšmė
Tinklo architektūra	<i>AlexNet</i>
Iteracijų skaičius	20
Slenkančio lango dydis	[1; 2; 4], [2; 4; 8], [4; 8; 12], [4; 8; 16], [8; 16; 32], [2; 8; 16], [2; 8; 32], [2; 16; 32],
Slenkančio lango pasislinkimas	16
Mokymosi grietis	1
Po NMS likusių klasifikuojamų regionų kiekis apmokymo metu	500

Apmokius metodą su skirtingomis slenkančio lango daugiklių reikšmėmis, metodas buvo išbandytas su testavimo duomenų bazė. Gauti rezultatai pateikti 9 lentelėje.

9 lentelė. Regionų išskyrimo slenkančių langų dydžių įtaka metodo tikslumui

Slenkančio lango daugikliai	Tikslumas				Bendras tikslumas	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
[1, 2, 4]	88,27 %	38,71 %	25,00 %	69,57 %	70,59 %	69,35 %
[2, 4, 8]	84,80 %	40,00 %	20,00 %	56,52 %	67,82 %	69,35 %
[2, 8, 16]	85,38 %	33,33 %	25,00 %	63,64 %	71,92 %	70,97 %
[2, 8, 32]	86,27 %	27,78 %	27,27 %	72,00 %	65,43 %	70,97 %
[2, 16, 32]	84,31 %	35,48 %	17,24 %	72,00 %	61,57 %	62,90 %
[4, 8, 12]	90,50 %	39,29 %	30,77 %	76,19 %	76,69 %	66,13 %
[4, 8, 16]	86,27 %	35,48 %	25,00 %	65,22 %	71,49 %	74,19 %
[8, 16, 32]	90,10 %	33,33 %	21,43 %	78,26 %	71,87 %	69,35 %

Didžiausiais bendras tikslumas buvo pasiektas 76,69 %, yra matomas kuomet lango dydžio daugikliai yra 4, 8 ir 12. Mažiausiais bendras visų klasių defektų radimo tikslumas eksperimento metu buvo 61,57 %, naudojant daugiklius 2, 16 ir 32.

Šakų klasė geriausiai yra randama naudojant 4, 8 ir 12 langų daugiklius. Radimo tikslumas prie šių daugiklių yra 90,50 %. Prasčiausiai šakų klasė randama prie daugiklių lygių 2, 16 ir 32, tikslumas - 84,31 %.

Branduolio klasė geriausiai buvo randama naudojant 8, 16 ir 32 slenkančių langų daugiklius bei originalius 4, 8 ir 12 slenkančio lango daugiklius. Didžiausias branduolio radimo tikslumas yra 78,26 %. Prasčiausiai branduolys buvo randamas naudojant 2, 4, ir 8 lango daugiklio, tikslumas 56,52 %.

Faster R-CNN metodas blogiausiai rado įbrėžimų bei dėmių klases. Įbrėžimai geriausiai buvo randama naudojant 2, 4 ir 8 langų daugiklius, tikslumas - 40,00 %. Įbrėžimai buvo blogiausiai randami naudojant plačiausią slenkančių langų intervalą – 2, 16 ir 32, tikslumas prie šios vertės yra lygus 27,27 %. Dėmių klasė didžiausią tikslumą 30,77 % pasiekė prie originalių 4, 8 ir 12 daugiklių.

Lukšto kokybinės rūšies nustatymo didžiausiais tikslumas pasiektas naudojant 4, 8 ir 16 langų dydžių daugiklius, tikslumas lygus 74,19 %. Mažiausiais rūšies nustatymo tikslumas 62,90 % pasiektas naudojant 8, 16 ir 32 langų daugiklius.

Optimalus slenkančių langų daugikliai yra 4, 8 ir 12 dėl didžiausio bendro defektų pozicijų tikslumo. Šis dydis buvo naudojamas kituose bandymuose. Visos tyrimo pasikliautinų intervalų reikšmės pateiktos 1 Priede.


3.6. Skirtingo atrinktų regionų kiekio, naudojant maksimumų atrinkmą įvertinimo metu, įtaka metodo tikslumui bei greitaveikai

Buvo ištirtas skirtingo atrinktų regionų pasiūlymų kiekio įvertinimo metu bandymas. Viso eksperimento metu visi tinklo apmokymo parametrai buvo pastovūs bei nekito. Keičiamas buvo tik atrinktų regionų kiekis įvertinimo metu, paryškintas 10 lentelėje.

10 lentelė. Šešto eksperimento metodo parametrai

Parametras	Reikšmė
Tinklo architektūra	<i>AlexNet</i>
Iteracijų skaičius	20
Slenkančio lango dydis	[4; 8; 12]
Slenkančio lango pasislinkimas	16
Mokymosi grietis	1
Po NMS likusių klasifikuojamų regionų kiekis apmokymo metu	500
Po NMS likusių klasifikuojamų regionų kiekis įvertinimo metu	10, 50, 100, 200, 300, 500, 1000, 2000

Apmokius metodą su skirtingomis atrinktų regionų įvertinimo metu reikšmėmis, buvo atlikti bandymai su testavimo duomenų baze. Bandymo tikslumo bei greitaveikos rezultatai pavaizduoti 38 paveiksle.



38 pav. Atrinktų regionų testavimo metu kiekio kitimo įtaka metodo tikslumui bei greitaverikai

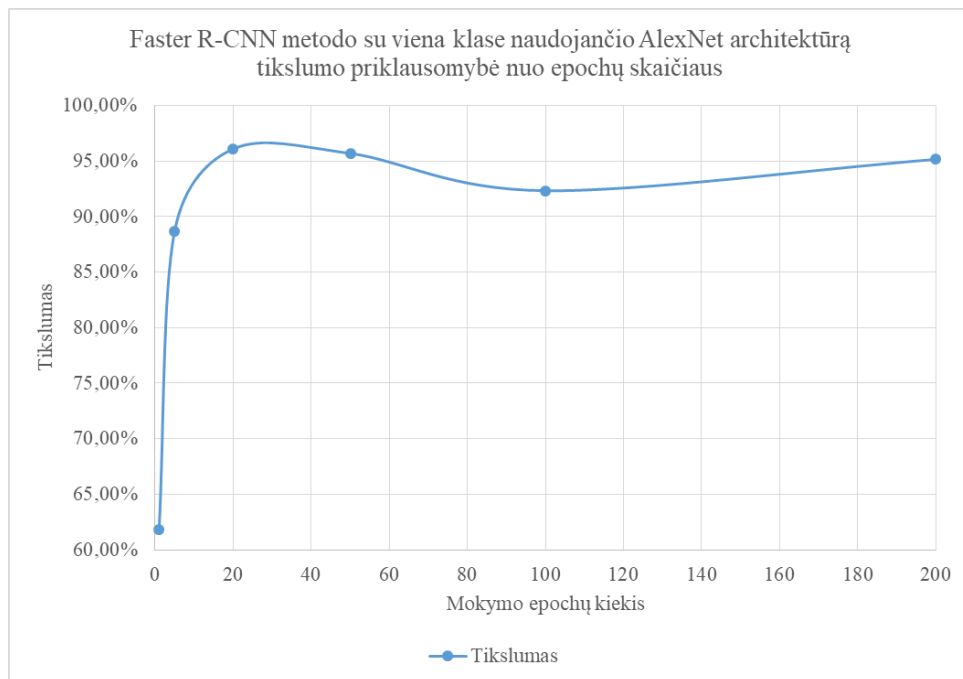
Didžiausias *Faster R-CNN* metodo bendras defektų radimo tikslumas buvo pasiektas naudojant 300 atrinktų regionų kiekį, prie šios vertės tikslumas buvo 76,69 %. Didžiausias rūšies nustatymo tikslumas buvo pasiektas ties 2000 atrinktų regionų riba, ir buvo 70,97 %.

Metodo nuotraukos įvertinimo laikas yra tiesiogiai proporcingas atrinktų regionų kiekiui. Ilgiausiai nuotrauka buvo apdorojama su 2000 atrinktų regionų, ties šia verte nuotrauka buvo apdorojama per vidutiniškai 1686 ms, greičiausiai - ties 10 atrinktų regionų riba nuotrauka yra įvertinama per 426 ms.

Optimalus metodo atrinktų regionų kiekis yra 300, dėl pakankamos greitaveikos bei didelio tikslumo. Nuotrauka naudojant 300 atrinktų regionų yra apdorojama per 662,42ms. Bendras defektų radimo tikslumas yra 74,06 %, o rūšies nustatymo tikslumas yra 66,13 %. Rezultatų skaitinės reikšmės yra pateiktos 1 priede.

3.7. *AlexNet* architektūra grįsto defekto atpažinimo algoritmo tikslumo tyrimas

Šiame eksperimentiniame tyrime nėra įvertinama defektų rūšis. Siekiama nustatyti naudojamos struktūros atpažinimo tikslumą, atskiriant pažeistą lukšto dalį nuo kokybiškos. *Faster R-CNN* metodas buvo apmokytas naudojant *AlexNet* bazinį modelį. Šiam tyrimui buvo pasirinktas optimalus 500 atrinktų regionų apmokymo metu kiekis. Slenkančių langų dydžiai buvo pasirinkti 4, 8 ir 12. Dėl optimalios greitaveikos buvo pasirinktas 300 atrinktų regionų kiekis įvertinimo metu. Bandyto rezultatai pateikti 39 pav.



39 pav. *Faster R-CNN* metodo su viena klase naudojančio *AlexNet* architektūrą tikslumo priklausomybė nuo epochų skaičiaus

Didžiausią objektų radimo tikslumas *Faster R-CNN* metodas pasiekė ties 20 epochų riba, kuris buvo 96,10 %.

Metodo tikslumo augimas nusistovėjo ties 20 epochų riba. Didžiausias tikslumo augimas buvo matomas intervale nuo 1 iki 5 epochų. Šiame intervale metodo tikslumas padidėjo 1,43 karto nuo 61,83 % iki 88,71 %. Intervale tarp 5 ir 20 tikslumas augo 1,08 karto ir pasiekė maksimalią 96,10 % vertę. Intervale nuo 20 iki 200 epochų metodo tikslumas sumažėjo iki 95,16 %.

20 epochų yra optimalus vieną klasę ieškančio *Faster R-CNN* metodo su šiuo duomenų rinkiniu skaičius. Šis epochų skaičius buvo naudojamas kituose bandymuose, kuriame yra naudojamas papildomas klasifikatorius defekto rūšies nustatymui. Visos bandymo tikslumo bei pasikliautino intervalo reikšmės pateiktos 1 priede.

3.8. Atpažinimo algoritmų, sukurtų taikant mokymo perkėlimo metodą, atpažinimo tikslumo tyrimas

Faster R-CNN metodu vienos klasės rasti defektai buvo klasifikuojami panaudojant papildomą perdavimo mokymo metodu apmokytą klasifikatorių. Klasifikatorius buvo apmokomas paskutinio sluoksnio perrašymo būdu, aprašytu 1.7 skyriuje. Perdavimo mokymas buvo atliekamas su šiais apmokytais modeliais:

- *AlexNet ImageNet* modeliui;
- *VGG16 ImageNet* modeliui;
- *BNInception ImageNet* modeliui;
- *ResNet152 ImageNet* modeliui.

Buvo atlikti geriausio partijos dydžio bei mokymosi greičio bandymai. Mokymo partijos dydis buvo keičiamas šiais žingsniais: 32; 64; 128; 256. VGG16 modelio didžiausias partijos dydis buvo 100, dėl apribotos vaizdo plokštės atminties. Mokymosi greitis buvo keičiamas šiais žingsniais: 0,2; 0,1; 0,01; 0,001. Visi bandymai naudojo vienodą epochų skaičių, kuris yra lygus 200.

Apmokymas buvo atliekamas naudojant sintetinius duomenimis padidintą iškarpų duomenų bazę susidedančią iš 22500 nuotraukų.

Apmokius modelius visi bandymai buvo atliekami su identiška tikrinimo duomenų baze susidedančia iš 500 defektų nuotraukų.

3.8.1. Perkelto mokymosi AlexNet ImageNet modelio tikslumo tyrimas

AlexNet ImageNet modelis buvo apmokytas 16 kartų naudojant skirtingas partijų dydžio bei mokymosi greičio vertes. Rezultatai pateikti 11 lentelėje.

11 lentelė. AlexNet perdavimo mokymosi rezultatai

Partijos dydis (nuotraukų kiekis)	Mokymosi greičio koeficientas	Tikslumas pagal klases (%)					Bendras tikslumas (%)
		Šaka	Įbrėžimas	Dėmė	Branduolys	Fonas	
32	0,001	82,76 %	77,88 %	48,00 %	69,83 %	86,02 %	72,40 %
32	0,01	82,76 %	70,19 %	68,00 %	86,21 %	84,95 %	78,40 %
32	0,1	65,52 %	83,65 %	61,00 %	79,31 %	91,40 %	76,40 %
32	0,2	57,47 %	68,27 %	70,00 %	75,00 %	92,47 %	72,80 %
64	0,001	81,61 %	71,15 %	56,00 %	78,45 %	86,02 %	74,40 %
64	0,01	82,76 %	83,65 %	59,00 %	77,59 %	91,40 %	78,60 %
64	0,1	89,66 %	71,15 %	50,00 %	93,10 %	72,04 %	75,40 %
64	0,2	82,76 %	46,15 %	8,00 %	100,00 %	60,22 %	60,00 %
128	0,001	82,76 %	75,96 %	54,00 %	71,55 %	86,02 %	73,60 %
128	0,01	86,21 %	75,96 %	63,00 %	87,07 %	87,10 %	79,80 %
128	0,1	94,25 %	69,23 %	53,00 %	82,76 %	89,25 %	77,20 %
128	0,2	82,76 %	45,19 %	70,00 %	89,66 %	83,87 %	74,20 %
256	0,001	83,91 %	77,88 %	51,00 %	69,83 %	86,02 %	73,20 %
256	0,01	82,76 %	81,73 %	66,00 %	82,76 %	88,17 %	80,20 %
256	0,1	86,21 %	90,38 %	64,00 %	61,21 %	94,62 %	78,40 %
256	0,2	94,25 %	81,73 %	33,00 %	67,24 %	97,85 %	73,80 %

Didžiausias bendras tikslumas buvo pasiektas naudojant 256 dydžio mokymo partiją bei 0,01 mokymosi greičio koeficientą, bendras tikslumas buvo lygus 80,20 %, pasikliautinumo intervalas su 95 % tikimybe yra lygus [76,71 – 83,69 %]. Didžiausias šakų klasifikavimo tikslumas buvo pasiektas naudojant didžiausią partijos dydį bei didžiausią tirtą mokymosi greičio koeficientą, šakų klasifikavimo tikslumas buvo lygus 94,25 %. Branduolio klasės didžiausias klasifikavimo tikslumas buvo 100 %, pasiektas prie 64 dydžio partijos bei 0,2 mokymosi greičio koeficiento. Fono klasė geriausiai buvo išskiriama ties 256 dydžio partija bei 0,2 mokymosi greičio koeficientu ir jos

nustatymo tikslumas buvo lygus 97,85 %. Įbrėžimų klasės klasifikavimo tikslumas didžiausias buvo 90,38 %, pasiektas naudojant didžiausią galimą partijos dydį. Prasčiausiai buvo nustatoma dėmių klasė, kurios maksimalus tikslumas buvo pasiektas 68 %. Didžiausią bendrą tikslumą su *AlexNet* baziniu modeliu pasiekusio modelio sumaišymo matrica pateikta 40 pav.

		Nustatyta klasė				
		branduolys	dėmė	įbrėžimas	šaka	fonas
Originali klasė	branduolys	82,76%	3,45%	6,03%	2,59%	5,17%
	dėmė	5,00%	66,00%	10,00%	10,00%	9,00%
	įbrėžimas	2,88%	10,58%	81,73%	3,85%	0,96%
	šaka	1,15%	12,64%	3,45%	82,76%	0,00%
	fonas	8,60%	2,15%	1,08%	0,00%	88,17%

40 pav. *AlexNet* rezultatų metodo sumaišymo matrica

Sumaišymo matricoje yra matoma, kad dėmių klasė labiausiai yra painiojama su įbrėžimų bei šakų klasėmis, atitinkamai po 10 %. Taip pat dėmių klasė buvo painiojama su fono klase, 9 % dėmių vaizdų buvo pažymėti kaip foninis vaizdas. Nors viena iš tiksliausiai nustatomų buvo šakų klasė, tačiau ji buvo labiausiai painiojama su dėmėmis. 12,64 % šakų buvo priskirta dėmių klasei.

3.8.2. Perkelto mokymosi *VGG16* ImageNet modelio tikslumo tyrimas

VGG16 ImageNet modelis buvo apmokytas 12 kartų naudojant skirtingas partijų dydžio bei mokymosi greičio vertes. Rezultatai pateikti 12 lentelėje.

12 lentelė. *VGG16* modelio perdavimo mokymo rezultatai

Partijos dydis (nuotraukų kiekis)	Mokymosi greičio koeficientas	Tikslumas pagal klases (%)					Bendras tikslumas (%)
		Šaka	Įbrėžimas	Dėmė	Branduolys	Šaka	
32	0,001	75,86 %	73,08 %	51,00 %	67,24 %	81,72 %	69,40 %
32	0,01	90,80 %	80,77 %	50,00 %	84,48 %	78,49 %	76,80 %
32	0,1	45,98 %	84,62 %	56,00 %	42,24 %	98,92 %	65,00 %
32	0,2	74,71 %	73,08 %	71,00 %	28,45 %	96,77 %	67,00 %
64	0,001	80,46 %	69,23 %	49,00 %	67,24 %	80,65 %	68,80 %
64	0,01	86,21 %	81,73 %	52,00 %	81,90 %	88,17 %	77,80 %
64	0,1	74,71 %	68,27 %	66,00 %	93,10 %	78,49 %	76,60 %
64	0,2	89,66 %	50,00 %	45,00 %	96,55 %	23,66 %	61,80 %
100	0,001	80,46 %	71,15 %	47,00 %	67,24 %	78,49 %	68,40 %
100	0,01	90,80 %	81,73 %	57,00 %	68,97 %	91,40 %	77,20 %
100	0,1	72,41 %	63,46 %	73,00 %	81,90 %	96,77 %	77,40 %
100	0,2	49,43 %	37,50 %	88,00 %	10,34 %	92,47 %	53,60 %

Didžiausias bendras tikslumas buvo pasiektas naudojant 64 dydžio mokymo partiją bei 0,01 mokymosi greičio koeficientą, bendras tikslumas buvo lygus 77,80. Didžiausias šakų tikslumas buvo pasiektas naudojant mažiausią partijos dydį lygų 32 bei 0,01 mokymosi koeficientą, šakų klasifikavimo tikslumas buvo lygus 90,80 %. Branduolio klasės didžiausias klasifikavimo tikslumas buvo 96,55 %, pasiektas prie 64 dydžio partijos bei 0,2 mokymosi greičio koeficiento. Fono klasė geriausiai buvo išskiriama naudojant 32 dydžio partija bei 0,1 mokymosi greičio koeficientą, jos nustatymo tikslumas buvo lygus 98,92 %. Įbrėžimų klasės klasifikavimo tikslumas didžiausias buvo 84,62 %, pasiektas naudojant mažiausią partijos dydį. Dėmių klasės maksimalus tikslumas buvo pasiektas 88 %, prie didžiausio galimo partijos dydžio. Didžiausią bendrą tikslumą su *VGG16* baziniu modeliu pasiekusio modelio sumaišymo matrica pateikta 41 pav.

		Nustatyta klasė				
		branduolys	dėmė	įbrėžimas	šaka	fonas
Originali klasė	branduolys	81,90%	4,31%	5,17%	0,86%	7,76%
	dėmė	11,00%	52,00%	12,00%	12,00%	13,00%
	įbrėžimas	5,77%	8,65%	81,73%	3,85%	0,00%
	šaka	3,45%	8,05%	1,15%	86,21%	1,15%
	fonas	11,83%	0,00%	0,00%	0,00%	88,17%

41 pav. *VGG16* rezultatų metodo sumaišymo matrica

Didžiausią bendrą tikslumą pasiekusiame *VGG16* pagrindu apmokytame modelyje geriausiai buvo nustatoma fono klasė, kurios klasifikavimo tikslumas pasiekė 88,17 % tikslumą. Fono klasė labiausiai buvo painiojama su branduolio klase. Šakų klasė buvo nustatoma su 86,21 % tikslumu. Šakų klasė labiausiai buvo painiojama su dėmių klase. Branduolio klasė klasifikavimas pasiekė 81,90 % tikslumą bei buvo labiausiai maišoma su fono bei įbrėžimų klase. Įbrėžimų klasifikavimas pasiekė 81,73 % tikslumą. Įbrėžimų klasė buvo labiausiai buvo maišoma su dėmių klase. Dėmių klasė buvo klasifikuojama prasčiausiai, pasiekė 52 % klasifikavimo tikslumą, bei buvo maišoma su visomis 4 klasėmis.

3.8.3. Perkelto mokymosi *BNInception ImageNet* modelio tikslumo tyrimas

BNInception ImageNet modelis buvo apmokytas 16 kartų naudojant skirtingas partijų dydžio bei mokymosi greičio vertes. Rezultatai pateikti 13 lentelėje.

13 lentelė. *BNInception* modelio perdavimo mokymo rezultatai

Partijos dydis (nuotraukų kiekis)	Mokymosi greičio koeficientas	Tikslumas pagal klases (%)					Bendras tikslumas (%)
		Šaka	Įbrėžimas	Dėmė	Branduolys	Šaka	
32	0,001	64,37 %	54,81 %	51,00 %	55,17 %	82,80 %	61,00 %
32	0,01	88,51 %	68,27 %	59,00 %	76,72 %	80,65 %	74,20 %
32	0,1	81,61 %	68,27 %	49,00 %	85,34 %	80,65 %	73,00 %

32	0,2	64,37 %	89,42 %	49,00 %	66,38 %	88,17 %	71,40 %
64	0,001	65,52 %	35,58 %	57,00 %	51,72 %	82,80 %	57,60 %
64	0,01	87,36 %	80,77 %	54,00 %	69,83 %	91,40 %	76,00 %
64	0,1	87,36 %	70,19 %	53,00 %	95,69 %	31,18 %	68,40 %
64	0,2	95,40 %	76,92 %	18,00 %	76,72 %	91,40 %	71,00 %
128	0,001	65,52 %	49,04 %	54,00 %	51,72 %	83,87 %	60,00 %
128	0,01	89,66 %	75,96 %	51,00 %	79,31 %	84,95 %	75,80 %
128	0,1	98,85 %	67,31 %	22,00 %	48,28 %	97,85 %	65,00 %
128	0,2	59,77 %	33,65 %	87,00 %	87,07 %	72,04 %	68,40 %
256	0,001	67,82 %	49,04 %	54,00 %	54,31 %	83,87 %	61,00 %
256	0,01	86,21 %	77,88 %	55,00 %	75,00 %	83,87 %	75,20 %
256	0,1	91,95 %	86,54 %	56,00 %	64,66 %	92,47 %	77,40 %
256	0,2	94,25 %	92,31 %	28,00 %	64,66 %	97,85 %	74,40 %

Didžiausias bendras klasifikavimo tikslumas buvo lygus 77,40 % ir buvo pasiektas naudojant 256 dydžio mokymo partiją bei 0,1 mokymosi greičio koeficientą. Didžiausias šakų klasifikavimo tikslumas buvo pasiektas naudojant vidutinę partijos dydį lygų 128 bei 0,1 mokymosi koeficientą, šakų klasifikavimo tikslumas buvo lygus 98,85 %. Branduolio klasės didžiausias klasifikavimo tikslumas buvo 95,69 %, pasiektas prie 64 dydžio partijos bei 0,1 mokymosi greičio koeficiento. Fono klasė geriausiai buvo išskiriama naudojant didžiausio 128 elementų partiją bei 0,1 mokymosi greitį, jos nustatymo tikslumas buvo lygus 97,85 %. Įbrėžimų klasės klasifikavimo tikslumas didžiausias buvo 92,31 %, pasiektas naudojant 128 elementų partiją bei 0,2 mokymo greičio koeficientą. Dėmių klasės maksimalus tikslumas buvo pasiektas 87 %, prie 128 elementų partijos bei 0,2 mokymosi greičio koeficiento. Didžiausią bendrą tikslumą su *BNInception* baziniu modeliu pasiekusio modelio sumaišymo matrica pateikta 42 pav.

		Nustatyta klasė				
		branduolys	dėmė	įbrėžimas	šaka	fonas
Originali klasė	branduolys	64,66%	10,34%	7,76%	3,45%	13,79%
	dėmė	4,00%	56,00%	15,00%	11,00%	14,00%
	įbrėžimas	1,92%	7,69%	86,54%	3,85%	0,00%
	šaka	0,00%	5,75%	2,30%	91,95%	0,00%
	fonas	2,15%	5,38%	0,00%	0,00%	92,47%

42 pav. *BNInception* rezultatų metodo sumaišymo matrica

Didžiausią bendrą tikslumą pasiekusiam apmokytame modelyje geriausiai buvo nustatomos fono bei šakų klasės, tikslumas atitinkamai 92,47 % bei 91,95 %. Abi klasės labiausiai buvo maišomos su dėmių klase. Pakakamai gerai buvo nustatoma įbrėžimų klasė, kuri pasiekė 86,54 % tikslumą. Ši klasė taip pat labiausiai buvo painiojama su dėmių klase. 7,69 % visų testavimo rinkinio įbrėžimų buvo

klasifikuoti kaip dėmės. Prasčiausiai buvo nustatoma branduolio bei dėmių klasės, atitinkamai 64,66 % bei 56,00 %. 15 % dėmių buvo neteisingai klasifikuota kaip įbrėžimai.

3.8.4. Perkelto mokymosi *ResNet152 ImageNet* modelio tikslumo tyrimas

ResNet152 ImageNet modelis buvo apmokytas 16 kartų naudojant skirtingas partijų dydžio bei mokymosi greičio vertes. Rezultatai pateikti 14 lentelėje.

14 lentelė. *ResNet152* modelio perdavimo mokymo rezultatai

Partijos dydis (nuotraukų kiekis)	Mokymosi greičio koeficientas	Tikslumas pagal klases (%)					Bendras tikslumas (%)
		Šaka	Įbrėžimas	Dėmė	Branduolys	Šaka	
32	0,001	74,71 %	63,46 %	46,00 %	58,62 %	84,95 %	64,80 %
32	0,01	75,86 %	76,92 %	63,00 %	73,28 %	94,62 %	76,40 %
32	0,1	78,16 %	75,96 %	55,00 %	94,83 %	84,95 %	78,20 %
32	0,2	80,46 %	83,65 %	57,00 %	90,52 %	83,87 %	79,40 %
64	0,001	74,71 %	65,38 %	51,00 %	59,48 %	82,80 %	66,00 %
64	0,01	87,36 %	78,85 %	56,00 %	72,41 %	90,32 %	76,40 %
64	0,1	86,21 %	90,38 %	41,00 %	92,24 %	88,17 %	79,80 %
64	0,2	81,61 %	77,88 %	53,00 %	84,48 %	89,25 %	77,20 %
128	0,001	74,71 %	69,23 %	52,00 %	62,07 %	80,65 %	67,20 %
128	0,01	85,06 %	79,81 %	57,00 %	71,55 %	91,40 %	76,40 %
128	0,1	88,51 %	72,12 %	59,00 %	89,66 %	94,62 %	80,60 %
128	0,2	98,85 %	81,73 %	37,00 %	88,79 %	93,55 %	79,60 %

Didžiausias bendras tikslumas buvo pasiektas naudojant 128 dydžio mokymo partiją bei 0,1 mokymosi greičio koeficientą, bendras tikslumas buvo lygus 80,06 %. Didžiausias šakų tikslumas buvo pasiektas naudojant 128 apmokymo partijos elementus bei 0,1 mokymosi koeficientą, šakų klasifikavimo tikslumas buvo lygus 98,85 %. Branduolio klasės didžiausias klasifikavimo tikslumas buvo 94,62 %, pasiektas prie 32 elementų partijos bei 0,01 mokymosi greičio koeficiento. Fono klasė geriausiai buvo išskiriama naudojant 128 elementų partiją bei 0,1 mokymosi greitį, jos nustatymo tikslumas buvo lygus 94,62 %. Įbrėžimų klasės klasifikavimo didžiausias tikslumas buvo 90,38 %, pasiektas naudojant 64 elementų partiją bei 0,1 mokymo greičio koeficientą. Dėmių klasės maksimalus tikslumas buvo pasiektas 63 %, prie 32 elementų partijos bei 0,01 mokymosi greičio koeficiento. Didžiausią bendrą tikslumą su *ResNet152* baziniu modeliu pasiekusio modelio sumaišymo matrica pateikta 43 pav.

		Nustatyta klasė				
		branduolys	dėmė	įbrėžimas	šaka	fonas
Originali klasė	branduolys	89,66%	3,45%	2,59%	0,86%	3,45%
	dėmė	8,00%	59,00%	9,00%	14,00%	10,00%
	įbrėžimas	15,38%	6,73%	72,12%	4,81%	0,96%
	šaka	1,15%	10,34%	0,00%	88,51%	0,00%
	fonas	3,23%	2,15%	0,00%	0,00%	94,62%

43 pav. ResNet152 rezultatų metodo sumaišymo matrica


Didžiausią bendrą tikslumą pasiekusiame ResNet152 pagrindu apmokytame modelyje geriausiai buvo nustatomos fono bei branduolio klasės, tikslumas atitinkamai 94,62 % bei 89,66 %. Fono klasė labiausiai buvo maišoma su branduolio klase, o branduolio klasė labiausiai maišoma su fono klase. Šakų klasė buvo klasifikuojama su 88,51 % tikslumu, kuri labiausiai buvo painiojama su dėmių klase. 10,34 % šakų nuotraukų buvo klasifikuojamos kaip dėmių nuotraukos. Prasčiausiai buvo klasifikuojamos įbrėžimų bei dėmių klasės, atitinkamai 72,12 % ir 59,00 % tikslumu. Įbrėžimų klasė labiausiai buvo painiojama su branduolio klase, 15,38 % įbrėžimų nuotraukų buvo klasifikuotos kaip branduolys. Dėmių klasė buvo labiausiai painiojama su šakų klase, iš testavimo duomenų rinkinio 14 % dėmių buvo neteisingai klasifikuoti kaip šakos.

3.9. Skirtingų mokymo perkėlimo metodu apmokyto modelių palyginimas

Buvo atliktas 4 anksčiau apmokyto modelių palyginimas. Palyginti buvo didžiausią bendrą tikslumą pasiekę modeliai. Palyginimo rezultatai pateikti 15 lentelėje bei 44 paveiksle.


15 lentelė. Skirtingų baziniu modelių, naudotų perdavimo mokyme, įtaka metodo tikslumui.

Modelis	Tikslumas pagal klases					Bendras tikslumas	Greitaveika (ms)
	Šaka	Įbrėžimas	Dėmė	Branduolys	Fonas		
AlexNet	82,76 %	81,73 %	66,00 %	82,76 %	88,17 %	80,20 %	6,76
VGG16	86,21 %	81,73 %	52,00 %	81,90 %	88,17 %	77,80 %	23,044
BNInception	91,95 %	86,54 %	56,00 %	64,66 %	92,47 %	77,40 %	13,128
RestNet152	88,51 %	72,12 %	59,00 %	89,66 %	94,62 %	80,60 %	48,014



44 pav. Modelių bendro tikslumo palyginimas

Didžiausią – bendrą tikslumą pasiekė *ResNet152* apmokytas modelis pasiekęs 80,60 % bendrą tikslumą. *AlexNet* modelis pasiekė vidutinį 80,20 % tikslumą. Šakų klasę geriausiai klasifikavo *BNInception* pagrindu apmokytas modelis, kuris pasiekė 91,95 % šakų klasifikavimo tikslumą. Įbrėžimų klasė geriausiai buvo randama *BNInception* baziniu modeliu apmokyto metodo, kuris pasiekė 86,54 % tikslumą. Geriausiai iš visų klasių buvo nustatoma fono klasė, kurią *ResNet152* modelio pagrindu apmokytas modelis klasifikavo su 94,62 % tikslumu. Branduolio klasę geriausiai klasifikavo *ResNet152* modelis, kuris pasiekė 89,66 % tikslumą. Modelių greitaiveikos palyginimas pateiktas 45 paveiksle.



45 pav. Modelių greitaiveikos palyginimas

AlexNet modelis vieną nuotrauką naudojant vaizdo plokštę vidutiniškai įvertindavo per 6,76 ms, *BNInception* modelis vieną nuotrauką klasifikuodavo per vidutiniškai 13,13 ms. *VGG16* bei *ResNet152* modeliai nuotraukų įvertinime buvo lėtesni paveik dvigubai lėtesni. *VGG16* modelio pagrindu apmokintas modelis vienai nuotraukai užtrukdavo vidutiniškai per 23,04 ms, o *ResNet152* modelis buvo lėčiausias ir vieną nuotrauką klasifikuodavo per vidutiniškai 48,014 ms.

Optimalus modelis medienos defektų klasifikavimui yra *AlexNet* modelio pagrindu apmokytas modelis, kuris pasiekė 80,2 % bendrą tikslumą, kuris yra 0,4 % mažesnis už geriausią *ResNet152* rezultatą, tačiau yra 7,1 karto greitesnis nuotraukos įvertinimo metu. Šis metodas yra 3,45 kartus greitesnis už *VGG16* metodą bei 1,96 kartus greitesnis už *BNInception* metodą.

3.10. Defektų radimo metodo su papildomu klasifikatoriumi tyrimas

Šiame tyrime 3.7 skyriuje aprašytas tiksliausias *Faster R-CNN* metodas randantis neklasifikuotus vienos klasės defektus buvo sujungtas su papildomu *AlexNet* bei *ResNet152* baziniais modeliais apmokytai klasifikatoriais. *AlexNet* papildomas klasifikatorius buvo pasirinktas dėl didžiausios greitaveikos bei didelio tikslumo, *ResNet152* modeliu apmokytas klasifikatorius dėl didžiausio tikslumo. Gauti rezultatai palyginti su didžiausią tikslumą ir greitaveiką pasiekusiu klases nustatančiu *Faster R-CNN* metodu. Tyrimo rezultatai pateikti 16 lentelėje.

16 lentelė. Metodo su papildomu klasifikatoriumi tyrimo rezultatai

Modelis	Radimo tikslumas				Bendras radimo tikslumas	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
Originalus	90,50 %	39,29 %	30,77 %	76,19 %	76,69 %	66,13 %
FR1C + <i>AlexNet</i> TL	82,84 %	40,00 %	17,86 %	70,83 %	69,01 %	79,03 %
FR1C + <i>ResNet152</i> TL	82,50 %	36,67 %	15,38 %	64,29 %	67,92 %	75,81 %

Faster R-CNN metodas su papildomu *AlexNet* klasifikatoriumi, lentelėje pažymėtas „FR1C + *AlexNet* TL“ pasiekė bendrą defektų pozicijos ir klasifikavimo 69 % tikslumą, kuris yra 11,1 % mažesnis už originalaus metodo pasiektą didžiausią tikslumą. Atskirų defektų radime bei klasifikavime metodas pasirodė prasčiau nei originalusis, šakų klasė buvo randama su 82,84 % tikslumu, 9,2 % blogiau nei originalus metodas. Branduolio klasės radimo tikslumas buvo 70,83 %. Įbrėžimų klasė naudojant papildomą klasifikatorių buvo randama tiksliau nei originaliame metode, jos tikslumo radimas buvo 40 %. Vienos nuotraukos įvertinimo trukmė su papildomu *AlexNet* klasifikatoriumi buvo 744 ms.

Faster R-CNN metodas su papildomu *ResNet152* klasifikatoriumi, lentelėje pažymėtas kaip „FR1C + *ResNet152* TL“ pasiekė bendrą defektų radimo tikslumą lygu 67,92 %, kuris yra 12,9 % mažesnis negu originalaus metodo. Šis metodas šakų klasės defektus rado su 82,50 % tikslumu, branduolio klasė buvo randama su 67,92 % tikslumu. Dėmių klasė buvo randama blogiausiai, metodas pasiekė 15,38 % šios klasės radimo tikslumą. Metodas su papildomu *ResNet152* klasifikatoriumi vieną nuotrauką vidutiniškai įvertino per 1228 ms.

Metodas su papildomais klasifikatoriais nepadidino originalaus *Faster R-CNN* metodo randančio bei klasifikuojančio skirtingas klases tikslumo. Naudojant *AlexNet* bei *ResNet152* papildomus klasifikatorius, tikslumas vidutiniškai sumažėjo atitinkamai 11,1 % bei 12,9 %. Metodas su *ResNet152* papildomu klasifikatoriumi buvo 1.57 kartus lėtesnis nei originalus metodas.

Išvados

1. Atlikus literatūros analizę buvo nustatyta, kad panašiam sprendimam yra taikomi gilaus mokymo metodai, tokie kaip *Faster R-CNN* ar sąsukos neuroniniai tinklai klasifikavimui. Remiantis analize tolimesni tyrimai buvo atliekami naudojantis paminėtais metodais.
2. Sintetiniu būdu padidintos duomenų bazės panaudojimas padidino metodo defektų radimo tikslumą 13 %, todėl duomenų bazės didinimas yra tinkamas būdas metodo tikslumui gerinti.
3. Metodas su *VGG16* architektūra buvo tikslesnis nei su *AlexNet* architektūra, tačiau 4.5 kartus lėtesnis ir yra netinkamas realaus laiko sistemos kūrimui su mūsų naudojama įranga.
4. Racionalus mokymo epochų skaičius su *AlexNet* architektūra yra 20 epochų, prie šio epochų skaičiaus metodas pasiekė didelį tikslumą bei greitą apmokymo laiką.
5. Racionalus testavimo atrinktų regionų kiekis yra 300, dėl didelio tikslumo bei tenkinamos greಿತaveikos. Viena nuotrauka buvo įvertinama per 662 ms bei modelis pasiekė bendrą 76,69% tikslumą. Ši greಿತaveika yra tinkama tiriamojo darbo tikslui pasiekti.
6. Didžiausias tikslumas buvo pasiektas naudojant 4, 8 ir 12 slenkančių langų daugiklius, todėl siūloma defektų atpažinimo uždaviniams naudoti paminėtus slenkančio lango daugiklius.
7. Mokymo perdavimo būdu apmokant papildomą klasifikatorių didžiausią klasifikavimo tikslumą pasiekė *ResNet152* naudojantis metodas, tačiau jis buvo lėčiausias, vieną nuotrauką įvertindamas per 48 ms. Geriausias klasifikatorius buvo naudojantis *AlexNet* architektūrą, kuris pasiekė 80,2% tikslumą bei defektus klasifikavo greičiausiai, per 6,67 ms, todėl šį modelį rekomenduojama naudoti tikroje sistemoje.
8. Naudojant *Faster R-CNN* metodo ir papildomo klasifikatoriaus hibridą buvo pasiektas bendras 69,01 % defektų pozicijų radimo tikslumas, tai yra 11% mažiau tikslus negu ne hibridinis *Faster R-CNN* metodas. Tokį rezultatą galima pagrįsti nepakankamai didele mokymo duomenų baze.

Literatūros sąrašas

1. A. LEBEDYS. 2015 Global Forest Products Facts and Figures,2016, Prieiga per:
<http://www.fao.org/3/a-i6669e.pdf>
2. DERVINIS, Donatas. *Vaizdų apdorojimas*, Kaunas,2012, ISBN-978-609-433-107-7
3. R. RAKE, Image Recognition Market Analysis Report By Technique, By Application (Augmented Reality, Security & Surveillance, Scanning & Imaging), By Component, By Deployment Mode, By Vertical, And Segment Forecasts, 2018 – 2025, 2018
4. GARVIN, David, *Managing Quality: The Strategic and Competitive Edge*.Harvard:Simon and Schuster,1988. ISBN- 9780029113806
5. C. A. REEVES and D. A. BEDNAR, DEFINING QUALITY: ALTERNATIVES AND IMPLICATIONS, *Academy of management Review*,1994, 19(3), 419-445
6. J.LEE and P. PARK, Inspection of defect on LCD panel using local mean algorithm based on similarity, *2013 13th International Conference on Control, Automation and Systems (ICCAS 2013)*,2013
7. Y.SHI and X. WEI, A Faster-RCNN Based Chemical Fiber Paper Tube Defect Detection Method, *2017 5th International Conference on Enterprise Systems (ES)*,2017, pp. 173-177. IEEE
8. Y.H. GU and H. ANDERSSON, Automatic Classification of Wood Defects Using Support Vector Machines, *International Conference on Computer Vision and Graphics*, 2008, pp. 356-367. Springer, Berlin, Heidelberg.
9. T. CAREW and O. GHITA, A Vision System for Detecting Paint Faults on Painted Slates, Dublinas,2001
10. Y. A. KARAYIANNIS and R. STOJANOVIC, Defect Detection and Classification on Web Textile Fabric Using Multiresolution Decomposition and Neural Networks, *ICECS'99. Proceedings of ICECS'99. 6th IEEE International Conference on Electronics, Circuits and Systems (Cat. No. 99EX357)*,1999, vol. 2, pp. 765-768.
11. I.DAUBECHIES, The wavelet transform, time-frequency localization and signal analysis. *IEEE transactions on information theory*, 1990, 36.5: 961-1005
12. Y. LI and J.AI, C.SUN, Online Fabric Defect Inspection Using Smart Visual Sensors, *Sensors* 13,2013, no. 4 pp. 4659-4673.
13. I. CETINER and A. A. VAR, Classification of Knot Defect Types Using Wavelets and KNN, *Elektronika ir elektrotechnika*, 2016, 22.6: 67-72.
14. J. LAMPINEN and S. SMOLANDER, Wood Surface Inspection System Based on Generic Visual Features, *Industrial Applications of Neural Networks*, 1998, pp. 35-42.
15. A. KUMAR and G. PANG, Defect detection in textured materials using Gabor filters, *Industry Applications Society. IEEE-IAS Annual Meeting Conference Record*, 2000.
16. X. LIU and W. ZHIJIE, Slub extraction in woven fabric images using Gabor filters, *Textile Research Journal*, 2008, 78(4), 320-325
17. W. LIUA, Z. WANG, A Survey of Deep Neural Network Architectures and Their Applications, *Neurocomputing*,2017, 234, 11-26
18. Convolutional Neural Networks (CNNs / ConvNets). Prieiga per:
<http://cs231n.github.io/convolutional-networks/#overview>
19. J. HOSANG and R. BENENSON. What makes for effective detection proposals?, *IEEE transactions on pattern analysis and machine intelligence*,2015, 38(4), 814-830.
20. R. GIRSHICK and J. DONAHUE. Rich feature hierarchies for accurate object detection and semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognitionm*,2014 (pp. 580-587).

21. R. GIRSHICK. Fast R-CNN. *Proceedings of the IEEE international conference on computer vision*, 2015 (pp. 1440-1448).
22. S.REN and K.HE. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, *Advances in neural information processing systems*, 2015, (pp. 91-99)
23. X. MO and K. TAO, An Efficient Approach for Polyps Detection in Endoscopic Videos Based on Faster R-CNN, *24th International Conference on Pattern Recognition (ICPR)*, 2018, (pp. 3929-3934)
24. Z. HUANG and M. FU, Recognition of Vehicle-Logo Based on Faster-RCNN, *Proceedings of the 4th International Conference on Signal and Information Processing*, 2019.
25. M. FERGUSON and R. AK, Automatic Localization of Casting Defects with Convolutional Neural Networks, *2017 IEEE International Conference on Big Data (Big Data)*, 2017, (pp. 1726-1735)
26. A. KRIZHEVSKY, I. SUTSKEVER and G. E.HINTON, "ImageNet Classification with Deep Convolutional Neural Networks," *Advances in neural information processing systems*, 2012, (pp. 1097-1105).
27. K. SIMONYAN and Z. ANDREW, "Very deep convolutional networks for large-scale image recognition.," *arXiv preprint*, 2014, (pp:1409 - 1556).
28. S. J. PAN, Q and YANG. A Survey on Transfer Learning, *IEEE Transactions on knowledge and data engineering*, 2009, 22(10), 1345-1359
29. L.Y. PRATT. Discriminability-Based Transfer between Neural Networks, *Advances in neural information processing systems*, 1993, (pp. 204-211).
30. J. YOSINSKI and J. CLUNE, How transferable are features in deep neural networks? *Advances in neural information processing systems*, 2014, (pp. 3320-3328)
31. E. RIBEIRO and A. UHL, Exploring Deep Learning and Transfer Learning for Colonic Polyp Classification, *Computational and mathematical methods in medicine*, 2016
32. X. WANG and Y.PENG. ChestX-ray 8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases, *Proceedings of the IEEE conference on computer vision and pattern recognition* , 2017, (pp. 2097-2106).
33. K. HE and X. ZHANG, Deep Residual Learning for Image Recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, (pp. 770-778).
34. C. SZEGEDY and W. LIU, Going Deeper with Convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, (pp. 1-9).
35. M. LIN and Q. CHEN, Network In Network, *arXiv preprint arXiv:1312.4400*, 2013.
36. S. IOFFE and C. SZEGEDY, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *arXiv preprint arXiv:1502.03167*, 2015.
37. Chromasens, Line-scan vs. area-scan cameras: What is right for your machine vision application?, 2017. Prieiga per:
<https://www.automationmag.com/technology/hardware/6989-line-scan-vs-area-scan-cameras-what-is-right-for-your-machine-vision-application>
38. The Microsoft Cognitive Toolkit. Prieiga per: <https://docs.microsoft.com/en-us/cognitive-toolkit/>
39. J. WANG and L.PEREZ, The Effectiveness of Data Augmentation in Image Classification using Deep Learning, *Convolutional Neural Networks Vis. Recognition*, 2017.
40. L. TAYLOR and G. NITSCHKE, Improving Deep Learning using Generic Data Augmentation, *arXiv preprint arXiv:1708.06020*, 2017.

Priedai

1 priedas. Bandymų rezultatų skaitinių reikšmių lentelės

1.1 lentelė. Originalios ir praplėstos sintetiniai duomenimis duomenų bazės įtaka metodo tikslumui

Duomenų bazė	AP@.50				mAP@.50	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
Originali	82,84 %	27,59 %	16,67 %	45,83 %	60,59 %	67,74 %
Padidinta	79,72 %	34,38 %	23,08 %	68,00 %	68,36 %	69,35 %

1.2 lentelė. Originalios ir praplėstos sintetiniai duomenimis duomenų bazės įtaka metodo tikslumui pasikliautinumo intervalai

Duomenų bazė	AP@.50				mAP@.50	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
Originali	[72,28 – 93,41 %]	[11,32 – 43,85 %]	[2,35 – 30,99 %]	[25,9 – 65,77 %]	[50,77 – 70,41 %]	[56,11 – 79,38 %]
Padidinta	[68,7 – 90,74 %]	[17,92 – 50,83 %]	[5,88 – 40,28 %]	[46,62 – 89,38 %]	[59,16 – 77,55 %]	[57,88 – 80,83 %]

1.3 lentelė. AlexNet architektūros pagrindu apmokyto metodo tikslumo priklausomybė nuo epochų skaičiaus

Epochų kiekis	AP@.50				mAP@.50	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
20	57,45 %	0,00 %	0,00 %	0,00 %	31,91 %	33,87 %
50	82,98 %	3,57 %	0,00 %	5,00 %	46,79 %	35,48 %
100	88,27 %	36,67 %	25,00 %	65,38 %	73,16 %	70,97 %
200	87,76 %	44,83 %	17,65 %	56,00 %	70,21 %	72,58 %
500	86,76 %	34,48 %	26,67 %	61,54 %	69,58 %	66,13 %
1000	79,72 %	34,38 %	23,08 %	68,00 %	68,36 %	69,35 %
2000	76,47 %	25,00 %	17,24 %	80,56 %	63,12 %	75,81 %

1.4 lentelė. *AlexNet* architektūros pagrindų apmokyto metodo tikslumo priklausomybė nuo epochų skaičiaus pasikliautinumo intervalai su 95 % tikimybe.

Epochų kiekis	AP@.50				mAP@.50	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
20	[43,31 – 71,58 %]	[0 – 0 %]	[0 – 0 %]	[0 – 0 %]	[21,84 – 41,98 %]	[22,09 – 45,65 %]
50	[72,23 – 93,72 %]	[-3,3 – 10,45 %]	[0 – 0 %]	[-4,55 – 14,55 %]	[36,53 – 57,05 %]	[23,57 – 47,39 %]
100	[78,98 – 97,55 %]	[19,42 – 53,91 %]	[3,78 – 46,22 %]	[47,1 – 83,67 %]	[65,59 – 80,73 %]	[59,67 – 82,27 %]
200	[78,58 – 96,93 %]	[26,73 – 62,93 %]	[-0,47 – 35,77 %]	[36,54 – 75,46 %]	[62,23 – 78,18 %]	[61,48 – 83,69 %]
500	[77,22 – 96,31 %]	[17,18 – 51,78 %]	[4,29 – 49,05 %]	[42,84 – 80,24 %]	[61,2 – 77,97 %]	[54,35 – 77,91 %]
1000	[68,7 – 90,74 %]	[17,92 – 50,83 %]	[0,17 – 45,98 %]	[46,62 – 89,38 %]	[59,16 – 77,55 %]	[57,88 – 80,83 %]
2000	[64,83 – 88,11 %]	[10,85 – 39,15 %]	[3,49 – 30,99 %]	[63,81 – 97,3 %]	[55,49 – 70,75 %]	[65,15 – 86,47 %]

1.5 lentelė. *VGG16* architektūros pagrindų apmokyto metodo tikslumo priklausomybė nuo epochų skaičiaus

Epochų kiekis	AP@.50				mAP@.50	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
20	38,30 %	0,00 %	0,00 %	0,00 %	21,35 %	46,77 %
50	79,69 %	7,41 %	23,08 %	28,57 %	54,77 %	70,97 %
100	89,80 %	39,29 %	28,57 %	67,39 %	75,40 %	79,03 %
200	90,50 %	40,00 %	18,75 %	74,36 %	75,05 %	80,65 %
500	88,50 %	46,88 %	25,00 %	69,33 %	75,72 %	79,03 %
1000	84,80 %	46,88 %	20,00 %	64,81 %	71,41 %	82,26 %
2000	86,27 %	38,71 %	22,22 %	68,75 %	73,41 %	83,87 %

1.6 lentelė. *VGG16* architektūros pagrindų apmokyto metodo tikslumo priklausomybė nuo epochų skaičiaus pasikliautinumo intervalai su 95 % tikimybe.

Epochų kiekis	AP@.50				mAP@.50	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
20	[24,4 – 52,2 %]	[0 – 0 %]	[0 – 0 %]	[0 – 0 %]	[12,52 – 30,18 %]	[34,35 – 59,19 %]
50	[68,08 – 91,3 %]	[-2,47 – 17,29 %]	[0,17 – 45,98 %]	[9,25 – 47,89 %]	[44,61 – 64,93 %]	[59,67 – 82,27 %]
100	[81,32 – 98,27 %]	[21,2 – 57,38 %]	[4,91 – 52,24 %]	[46,86 – 87,92 %]	[67,18 – 83,62 %]	[68,9 – 89,17 %]

200	[82,08 – 98,92 %]	[22,47 – 57,53 %]	[-0,38 – 37,88 %]	[56,84 – 91,88 %]	[67,86 – 82,25 %]	[70,81 – 90,48 %]
500	[79,39 – 97,61 %]	[29,58 – 64,17 %]	[3,78 – 46,22 %]	[50,52 – 88,15 %]	[68,28 – 83,15 %]	[68,9 – 89,17 %]
1000	[74,72 – 94,89 %]	[29,58 – 64,17 %]	[-0,24 – 40,24 %]	[45,74 – 83,89 %]	[63,09 – 79,73 %]	[72,75 – 91,77 %]
2000	[76,83 – 95,72 %]	[21,56 – 55,86 %]	[3,02 – 41,43 %]	[48,9 – 88,6 %]	[65,34 – 81,48 %]	[74,72 – 93,03 %]

1.7 lentelė. Skirtingo regionų pasiūlymų skaičiaus regionų tinklui pritaikant maksimumų atrinkimą mokymo metu įtaka metodo tikslumui

Regionų kiekis	AP@.50				mAP@.50	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
20	76,54 %	18,37 %	4,17 %	62,07 %	37,19 %	61,29 %
50	79,87 %	25,64 %	6,45 %	59,26 %	57,42 %	61,29 %
100	85,71 %	36,36 %	27,78 %	66,67 %	69,83 %	75,81 %
200	88,27 %	36,67 %	25,00 %	65,38 %	73,16 %	70,97 %
500	90,50 %	39,29 %	30,77 %	76,19 %	76,69 %	66,13 %
1000	86,00 %	35,48 %	26,67 %	53,85 %	66,01 %	74,19 %
2000	87,26 %	36,11 %	29,41 %	79,17 %	73,33 %	77,42 %

1.8 lentelė. Skirtingo regionų pasiūlymų skaičiaus regionų tinklui pritaikant maksimumų atrinkimą mokymo metu įtaka metodo tikslumui pasikliautinumo intervalai

Regionų kiekis	AP@.50				mAP@.50	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
20	[64,99 – 88,1 %]	[7,53 – 29,21 %]	[-1,49 – 9,82 %]	[41,99 – 82,15 %]	[30,13 – 44,25 %]	[49,17 – 73,41 %]
50	[68,8 – 90,95 %]	[11,94 – 39,35 %]	[-2,2 – 15,1 %]	[40,73 – 77,79 %]	[49,53 – 65,31 %]	[49,17 – 73,41 %]
100	[75,92 – 95,51 %]	[19,95 – 52,78 %]	[7,09 – 48,47 %]	[47,81 – 85,53 %]	[62,33 – 77,34 %]	[65,15 – 86,47 %]
200	[78,98 – 97,55 %]	[19,42 – 53,91 %]	[3,78 – 46,22 %]	[47,1 – 83,67 %]	[65,59 – 80,73 %]	[59,67 – 82,27 %]
500	[82,08 – 98,92 %]	[21,2 – 57,38 %]	[5,68 – 55,86 %]	[57,97 – 94,41 %]	[68,97 – 84,41 %]	[54,35 – 77,91 %]
1000	[76,38 – 95,62 %]	[18,64 – 52,33 %]	[4,29 – 49,05 %]	[34,68 – 73,01 %]	[57,7 – 74,32 %]	[63,3 – 85,09 %]
2000	[78,05 – 96,47 %]	[20,42 – 51,8 %]	[7,75 – 51,07 %]	[59,23 – 99,1 %]	[66,03 – 80,62 %]	[67,01 – 87,83 %]

1.9 lentelė. Regionų išskyrimo slenkančių langų dydžių įtaka metodo tikslumui, pasikliautinumo intervalai su 95 % tikimybe.

Slenkančio lango daugikliai	AP@.50				mAP@.0,5	Rūšies nustatymo tikslumas
	Šaka	Įbrėžimas	Dėmė	Branduolys		
[1, 2, 4]	[78,98 – 97,55 %]	[21,56 – 55,86 %]	[3,78 – 46,22 %]	[50,76 – 88,37 %]	[62,55 – 78,64 %]	[57,88 – 80,83 %]
[2, 4, 8]	[74,72 – 94,89 %]	[23,77 – 56,23 %]	[-0,24 – 40,24 %]	[36,26 – 76,78 %]	[59,68 – 75,95 %]	[57,88 – 80,83 %]
[2, 8, 16]	[75,64 – 95,11 %]	[16,46 – 50,2 %]	[3,78 – 46,22 %]	[43,53 – 83,74 %]	[63,94 – 79,89 %]	[59,67 – 82,27 %]
[2, 8, 32]	[76,83 – 95,72 %]	[13,15 – 42,41 %]	[8,66 – 45,88 %]	[51,2 – 92,8 %]	[57,63 – 73,22 %]	[59,67 – 82,27 %]
[2, 16, 32]	[74,33 – 94,29 %]	[18,64 – 52,33 %]	[3,49 – 30,99 %]	[54,4 – 89,6 %]	[54,17 – 68,98 %]	[50,88 – 74,93 %]
[4, 8, 12]	[82,08 – 98,92 %]	[21,2 – 57,38 %]	[5,68 – 55,86 %]	[57,97 – 94,41 %]	[68,97 – 84,41 %]	[54,35 – 77,91 %]
[4, 8, 16]	[76,83 – 95,72 %]	[18,64 – 52,33 %]	[3,78 – 46,22 %]	[45,75 – 84,68 %]	[63,53 – 79,44 %]	[63,3 – 85,09 %]
[8, 16, 32]	[81,35 – 98,85 %]	[17,25 – 49,42 %]	[-0,07 – 42,92 %]	[61,4 – 95,12 %]	[64,25 – 79,48 %]	[57,88 – 80,83 %]

1.10 lentelė. Atrinktų regionų testavimo metu kiekio kitimo įtaka metodo tikslumui bei greitimeikai

R.K	AP@.50				mAP@.50	Rūšies nustatymo tikslumas	Įvertinimo laikas (ms)
	Šaka	Įbrėžimas	Dėmė	Branduolys			
10	84,18 %	31,03 %	16,67 %	71,43 %	72,54 %	67,74 %	426
50	90,10 %	30,00 %	20,00 %	72,73 %	70,30 %	62,90 %	470
100	82,69 %	37,93 %	33,33 %	76,19 %	70,55 %	66,13 %	502
200	94,27 %	26,67 %	21,43 %	70,83 %	70,67 %	61,29 %	582
300	90,50 %	39,29 %	30,77 %	76,19 %	76,69 %	66,13 %	662
500	88,50 %	35,48 %	18,75 %	76,00 %	74,50 %	69,35 %	830
1000	88,00 %	34,38 %	20,00 %	54,17 %	69,75 %	66,13 %	1218
2000	90,31 %	31,25 %	23,53 %	65,22 %	69,97 %	70,97 %	1686

1.11 lentelė. Atrinktų regionų testavimo metu kiekio kitimo įtaka metodo tikslumui bei greitimeikai

R.K	AP@.50				mAP@.50	Rūšies nustatymo tikslumas	Įvertinimo laikas (ms)
	Šaka	Įbrėžimas	Dėmė	Branduolys			
10	[73,72 – 94,64 %]	[14,2 – 47,87 %]	[-4,42 – 37,75 %]	[52,11 – 90,75 %]	[63,82 – 81,25 %]	[56,11 – 79,38 %]	[390; 463]
50	[81,35 – 98,85 %]	[13,6 – 46,4 %]	[-0,24 – 40,24 %]	[54,12 – 91,34 %]	[61,94 – 78,65 %]	[50,88 – 74,93 %]	[428; 512]
100	[72,41 – 92,97 %]	[20,27 – 55,59 %]	[9,48 – 57,19 %]	[57,97 – 94,41 %]	[61,96 – 79,14 %]	[54,35 – 77,91 %]	[465; 539]
200	[87,31 – 101,23 %]	[10,84 – 42,49 %]	[-0,07 – 42,92 %]	[52,65 – 89,02 %]	[62,23 – 79,11 %]	[49,17 – 73,41 %]	[546; 619]
300	[82,08 – 98,92 %]	[21,2 – 57,38 %]	[5,68 – 55,86 %]	[57,97 – 94,41 %]	[68,97 – 84,41 %]	[54,35 – 77,91 %]	[626; 698]
500	[79,39 – 97,61 %]	[18,64 – 52,33 %]	[-0,38 – 37,88 %]	[55,92 – 96,08 %]	[66,59 – 82,4 %]	[57,88 – 80,83 %]	[792; 867]
1000	[78,99 – 97,01 %]	[17,92 – 50,83 %]	[-0,24 – 40,24 %]	[34,23 – 74,1 %]	[61,24 – 78,25 %]	[54,35 – 77,91 %]	[969; 1468]
2000	[81,73 – 98,89 %]	[15,19 – 47,31 %]	[3,37 – 43,69 %]	[45,75 – 84,68 %]	[62,03 – 77,91 %]	[59,67 – 82,27 %]	[1640; 1733]

1.12 lentelė. *Faster R-CNN* metodo su viena klase naudojančio *AlexNet* architektūrą tikslumo priklausomybė nuo epochų skaičiaus

Epochų kiekis	AP@.50	AP@.50 PI
1	61,83 %	[49,55 – 74,1 %]
5	88,71 %	[79,65 – 97,77 %]
20	96,10 %	[87,69 – 100 %]
50	95,70 %	[88,63 – 100 %]
100	92,34 %	[85,49 – 99,19 %]
200	95,16 %	[86,88 – 100 %]